

Е.В. Бодянский, Е.А. Винокурова

Составной адаптивный вэйвлон и алгоритм его обучения

Рассмотрена структура составного адаптивного вэйвлона и его алгоритм обучения. Предложен алгоритм, обладающий повышенной скоростью сходимости и обеспечивающий улучшенные аппроксимирующие свойства благодаря настройке всех параметров вэйвлет-функций. Структура адаптивного вэйвлона может быть использована как строительный блок более сложных вычислительных конструкций.

A compartmental adaptive wavelon and its learning algorithm are considered. A learning algorithm is suggested which has an increased convergence rate and provides the improved approximating properties because of the all wavelet parameters tuning. The suggested adaptive wavelon structure can be used as the block of more complex computational architecture.

Розглянуто структуру складеного адаптивного вейвлону та його алгоритм навчання. Запропонований алгоритм має підвищену швидкість збіжності та забезпечує покращені апроксимуючі властивості завдяки налаштуванню усіх параметрів вейвлет-функцій. Структура адаптивного вейвлону може бути використана як будівельний блок більш складних обчислювальних конструкцій.

Введение. Искусственные нейронные сети (ИНС) получили широкое распространение для решения задач обработки информации и прежде всего для идентификации, эмуляции, интеллектуального управления, прогнозирования временных рядов произвольной природы в условиях структурной и параметрической неопределенности.

Альтернативой традиционным многослойным ИНС с сигмоидальными функциями активации являются радиально-базисные нейронные сети (РБНС), имеющие один скрытый слой, образованный так называемыми R -нейронами, при этом обучение этих сетей реализуется на уровне выходного слоя, образованного адаптивными линейными ассоциаторами [1–5]. В отличие от P -нейронов с сигмоидальной функцией активации R -нейроны имеют, как правило, колоколообразную функцию активации $f_j(x)$, аргументом которой является рассогласование (обычно в метрике Евклида) между текущим значением входного сигнала $x(k)$ и центром c_j j -го нейрона. Основное преимущество РБНС – высокая скорость обучения в выходном слое, определяемая тем, что настраиваемые параметры входят в описание сети линейно. Однако остается открытой проблема размещения центров R -нейронов, неудачное решение которой ведет к возникновению «проклятия размерности». Применение

методов кластеризации, хотя и позволяет уменьшить размеры сети, исключает возможность работы в реальном времени. Отметим, что в [6] описана градиентная рекуррентная процедура покомпонентной настройки параметров c_{ji} , однако она характеризуется низкой скоростью сходимости.

Наряду с нейронными сетями для обработки сигналов различной природы последнее время достаточно часто используется теория вэйвлет-преобразования [7–9], обеспечивающая компактное локальное представление сигналов как в частотной, так и во временной области. На стыке теорий ИНС и вэйвлетов возникли вэйвлет-нейронные сети [10–17], подтвердившие эффективность в задачах обработки нестационарных нелинейных сигналов и процессов. Элементарные узлы вэйвлет-нейронных сетей – радиальные вэйвлонны [18], активационными функциями которых являются четные вэйвлеты с аргументом в виде евклидова расстояния между $x(k)$ и центром вэйвлета c_j , при этом каждая компонента расстояния $\|x(k) - c_j\|^2$ нормируется на параметр ширины σ_j^2 . Рецепторные поля таких вэйвлоннов представляют собой гиперэллипсоиды с осями коллинеарными координатным осям пространства X .

Итак, статья посвящена вопросам синтеза составного адаптивного вэйвлона и его алгорит-

ма обучения, обладающего повышенной скоростью сходимости и обеспечивающего улучшенные аппроксимирующие свойства для использования в качестве узла нейронной сети, в частности, как нейрона МГУА-нейронной сети [19–23].

Составной адаптивный вэйвлон

Рассмотрим двухслойную структуру составного адаптивного вэйвлона, приведенную на рис. 1 и совпадающую по сути с упрощенной радиально-базисной нейронной сетью с одним выходом.




Рис. 1. Структура составного адаптивного вэйвлона

Нулевой слой структуры – рецепторный, и в момент времени k на него подается входной сигнал в форме вектора $x(k) = (x_1(k), x_2(k), \dots, x_n(k))^T$. Скрытый слой в отличие от радиально-базисных сетей образован не R -нейронами, а вэйвлонами с многомерными активационными функциями-вэйвлетами вида

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

в которых вместо параметров растяжений σ_{ji} в (1) используется матрица Q_j^{-1} , т.е. используется не евклидова метрика, а расстояние Итакура–Сайто [24]. Это приводит к тому, что рецепторные поля вэйвлонов (2) могут иметь произвольную ориентацию относительно координатных осей пространства X , что расширяет функциональные возможности составного адаптивного вэйвлона.

Основываясь на вэйвлет-функции «Mexican Hat» [8], введем новую настраиваемую активационную функцию в структуру составного адаптивного вэйвлона, имеющую вид

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

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

Уточняемый параметр α_j позволяет настраивать форму активационной функции в процессе обучения составного адаптивного вэйвлона, при $\alpha = 0$ получаем гауссову функцию активации, при $\alpha = 1$ получаем вэйвлет-функцию «Mexican Hat», а при $0 < \alpha < 1$ – гибридную функцию активации. На рис. 2 приведены формы двумерных активационных функций вэйвлонов (2) при различных матрицах Q_j^{-1} и параметре α_j .

И, наконец, выход составного вэйвлона представляет собой обычный адаптивный линейный ассоциатор с настраиваемыми синаптическими весами w_j

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

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

Настраиваемыми параметрами структуры составного адаптивного вэйвлона, подлежащими определению в процессе обучения, будем полагать $h+1$ синаптических весов w_j , h ($n \times 1$) – параметров векторов c_j , h ($n \times n$) – элементов матриц Q_j^{-1} и h – параметров α_j . Всего такая структура содержит $h(2+n+n^2)+1$ уточняемых параметров.

Алгоритм обучения составного адаптивного вэйвлона

Поскольку $(h+1) \times 1$ вектор синаптических весов w входит в описание сети линейно, для

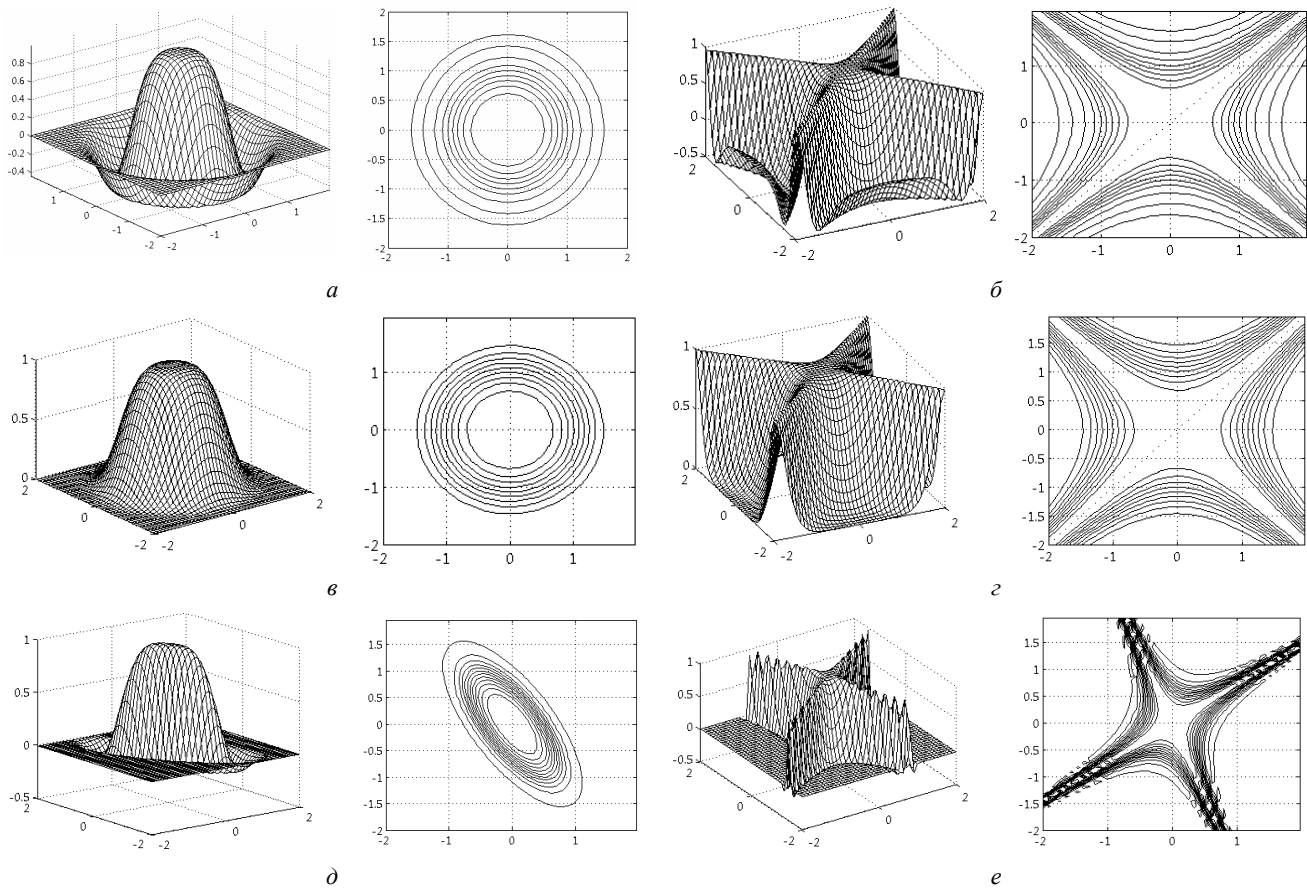


Рис. 2. Активационные функции вэйвлонов при разных матрицах Q_j^{-1} и параметре α : $a - Q_j^{-1} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$, $\alpha = 1$; $б - Q_j^{-1} = \begin{pmatrix} -1 & 0 \\ 0 & 1 \end{pmatrix}$,

$$\alpha = 1; в - Q_j^{-1} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}, \alpha = 0; з - Q_j^{-1} = \begin{pmatrix} -1 & 0 \\ 0 & 1 \end{pmatrix}, \alpha = 0; д - Q_j^{-1} = \begin{pmatrix} 4 & 3 \\ 1 & 2 \end{pmatrix}, \alpha = 0.5; е - Q_j^{-1} = \begin{pmatrix} -4 & 3 \\ 1 & 2 \end{pmatrix}, \alpha = 0.5$$

его уточнения может использоваться любой из алгоритмов адаптивной идентификации [25] и, прежде всего, традиционный рекуррентный метод наименьших квадратов:

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

обладающий фильтрующими свойствами.

Для настройки параметров вэйвлонов (векторов c_j , матриц Q_j^{-1} , параметра α_j) будем использовать градиентную минимизацию локального критерия

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

при этом в отличие от покомпонентного обучения, рассмотренного в [6], введем уточнение в векторно-матричной форме, что, во-первых, проще с вычислительной точки зрения, а, во-вторых, позволит оптимизировать процесс обучения по быстродействию.

В общем случае алгоритм обучения может быть записан в виде

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

где $\nabla_{c_j} E$, $\nabla_{\alpha_j} E$ – $(n \times 1)$ -векторы-градиенты критерия (5) по c_j и α_j соответственно; $\{\partial E(k)/\partial Q_j^{-1}\}$ – $(n \times n)$ -матрица, образованная частными производными E по компонентам Q_j^{-1} ; η_{c_j} , $\eta_{Q_j^{-1}}$ и η_{α_j} – параметры шага алгоритма обучения.

Для функции активации (2) можно записать

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

где $\phi'_j(\bullet)$ – производная j -го вэйвлета по аргументу, заданному метрикой Итакуры–Сайто $(x(k) - c_j(k))^T Q_j^{-1}(k)(x(k) - c_j(k))$.

Тогда алгоритм обучения вэйвлонов скрытого слоя с учетом (7) принимает форму

$$\left\{ \begin{array}{l} c_j(k+1) = c_j(k) - \eta_{c_j} e(k) 2w_j(k) \phi'_j((x(k) - \\ \quad - c_j(k))^T Q_j^{-1}(k)(x(k) - c_j(k))) \cdot \\ \quad \cdot Q_j^{-1}(k)(x(k) - c_j(k)) = \\ \quad = c_j(k) - \eta_{c_j} e(k) J_{c_j}(k), \\ Q_j^{-1}(k+1) = Q_j^{-1}(k) + \eta_{Q_j^{-1}} e(k) w_j(k) \phi'_j((x(k) - \\ \quad - c_j(k))^T Q_j^{-1}(k)(x(k) - c_j(k))) \cdot \\ \quad \cdot (x(k) - c_j(k))(x(k) - c_j(k))^T = \\ \quad = Q_j^{-1}(k) + \eta_{Q_j^{-1}} e(k) J_{Q_j^{-1}}(k), \\ \alpha_j(k+1) = \alpha_j(k) + \eta_{\alpha_j} e(k) w_j(k) \tau_j^2(x(k)) \cdot \\ \quad \cdot \exp(-\tau_j^2(x(k))/2) = \alpha_j(k) + \eta_{\alpha_j} e(k) J_{\alpha_j}(k), \end{array} \right. \quad (8)$$

при этом скорость сходимости к оптимальным значениям c_j и Q_j^{-1} полностью определяется параметрами шага η_{c_j} и $\eta_{Q_j^{-1}}$.

Повышение скорости сходимости достигается использованием более сложных, нежели

градиентные, процедур типа Хартли или Марквардта, записанные для настройки параметров c_j и α_j в обобщенной форме [26]:

$$\left\{ \begin{array}{l} c_j(k+1) = c_j(k) - \lambda_c (J_{c_j}(k) J_{c_j}^T(k) + \\ \quad + \eta_c I)^{-1} J_{c_j}(k) e(k), \\ \alpha_j(k+1) = \alpha_j(k) + \lambda_\alpha (J_{\alpha_j}(k) J_{\alpha_j}^T(k) + \\ \quad + \eta_\alpha I)^{-1} J_{\alpha_j}(k) e(k), \end{array} \right. \quad (9)$$

где I – $(n \times n)$ -единичная матрица, $\lambda_c, \lambda_\alpha$ – положительные демпфирующие параметры, η_c, η_α – параметры регуляризации.

Воспользовавшись леммой обращения матриц, после достаточно простых преобразований можно получить простой и эффективный алгоритм обучения центров вэйвлонов и параметра a_j в виде:

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

который совпадает (при $\lambda_c = 1, \eta_c = 0, \lambda_\alpha = 1, \eta_\alpha = 0$) с оптимальным по быстродействию алгоритмом Качмажа–Уидроу–Хоффа.

Для настройки матриц Q_j^{-1} можно воспользоваться матричной модификацией алгоритма (10) в виде [27]

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

где $\lambda_{Q_j^{-1}}, \eta_{Q_j^{-1}}$ имеют тот же смысл, что и соответствующие параметры в (9).

Таким образом, окончательно алгоритм обучения параметров вэйвлонов скрытого слоя в оптимальном по быстродействию варианте может быть записан

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

Известно, что одношаговые алгоритмы типа Качмажа, имея высокое быстродействие, не обладают фильтрующими свойствами, т.е. плохо работают в условиях интенсивных возмущений и помех. Для придания процессу обучения сглаживающих свойств, используя подход, предложенный в [28], можно ввести следующую процедуру обучения:

$$\left\{ \begin{array}{l} c_j(k+1) = c_j(k) - \lambda_{c_j} \frac{e(k) J_{c_j}(k)}{\eta_{c_j}(k)}, \\ \eta_{c_j}(k+1) = \gamma_c \eta_{c_j}(k) + \left\| J_{c_j}(k+1) \right\|^2, \\ Q_j^{-1}(k+1) = Q_j^{-1}(k) + \lambda_{Q_j^{-1}} \frac{e(k) J_{Q_j^{-1}}(k)}{\eta_{Q_j^{-1}}(k)}, \\ \eta_{Q_j^{-1}}(k+1) = \gamma_{Q_j^{-1}} \eta_{Q_j^{-1}}(k) + \\ + \text{Tr} \left(J_{Q_j^{-1}}^T(k+1) J_{Q_j^{-1}}(k+1) \right), \\ \alpha_j(k+1) = \alpha_j(k) + \lambda_{\alpha_j} \frac{e(k) J_{\alpha_j}(k)}{\eta_{\alpha_j}(k)}, \\ \eta_{\alpha_j}(k+1) = \gamma_{\alpha_j} \eta_{\alpha_j}(k) + \left\| J_{\alpha_j}(k+1) \right\|^2, \end{array} \right. \quad (13)$$

(здесь $0 \leq \gamma_c \leq 1, 0 \leq \gamma_{Q_j^{-1}} \leq 1, 0 \leq \gamma_{\alpha_j} \leq 1$ – параметры взвешивания устаревшей информации), являющуюся нелинейным гибридом алгоритма Качмажа–Уидроу–Хоффа и Гудвина–Рэмеджа–Кэйнеса и обладающую как отслеживающими, так и фильтрующими свойствами.

Экспериментальное моделирование

Эффективность предложенного подхода была продемонстрирована при решении задачи эмуляции динамического объекта [29], описываемого уравнением

$$y(k+1) = 0,3y(k) + 0,6y(k-1) + f(u(k)), \quad (14)$$

где $f(u)$ имеет вид: $f(u) = 0,6 \sin u + 0,3 \sin 3u + 0,1 \sin 5u$.

Для эмуляции динамического объекта в реальном времени применялся составной адаптивный вэйвлон с количеством входов $n=3$. Количество вэйвлет-активационных функций в скрытом слое и их начальные параметры получены с помощью метода субтрактивной кластеризации [30], позволяющего получить не только исходную матрицу координат центров кластеров, но также вектор, компоненты которого определяют диапазон влияния центра кластера.

Для обучения использовался сигнал $u(k) = \sin 2k/250$ для $k=1 \dots 20000$. После 20000 шагов обучение было остановлено. В качестве проверочного использовался сигнал $u(k) = \sin 2k/250$, $k=20001 \dots 20500$ и $u(k) = 0,5 \sin 2k/250 + 0,5 \sin 2k/25$, $k=2001 \dots 2500$. Количество вэйвлет-активационных функций было принято $h=6$. Начальные значения синнаптических весов были нулевыми.

В качестве критерия качества прогноза использована нормированная среднеквадратическая ошибка (NRMSE). Результаты эмуляции динамического объекта (14) показаны на рис. 3. Как видно, две кривые, представляющие реальные (пунктирная линия) и модельные (сплошная линия) значения, практически идентичны.

В таблице представлен сравнительный анализ процесса эмуляции на основе составного адаптивного вэйвлона с настройкой всех его параметров с составным адаптивным вэйвлонном с обучением только синнаптических весов и результатами стандартной радиально-базисной нейронной сети.

Сравнительный анализ результатов эмуляции динамического объекта в реальном времени

Нейронная сеть / Алгоритм обучения	NRMSE
Составной адаптивный вэйвлон / РМНК (4) + Предложенный алгоритм обучения всех параметров вэйвлон (13)	0,0334
Составной адаптивный вэйвлон / РМНК (4)	0,1955
Стандартная радиально-базисная нейронная сеть / РМНК (4)	0,2211

Из приведенных на рис. 3 результатов следует, что предложенная структура составного адаптивного вэйвлона и алгоритм обучения всех ее параметров обеспечивают более высокую точность эмуляции в реальном времени по сравнению с подобной структурой с фиксированными параметрами активационных функций, а также со стандартной радиально-базисной нейронной сетью.




Рис. 3. Результаты эмуляции динамического объекта (14)

Заключение. Предложен численно простой и эффективный алгоритм обучения составного адаптивного вэйвлона, обладающий отслеживающими и фильтрующими свойствами и позволяющий в реальном времени обрабатывать нестационарные нелинейные сигналы и процессы. Структура составного адаптивного вэйвлона может быть использована в качестве узла МГУА-нейронных сетей и в дальнейшем позволит расширить размерность вектора входов нейронов таких сетей. Настройка всех параметров вэйвлонных позволила улучшить аппроксимирующие свойства сети. Проведено экспериментальное моделирование на различных типах сигналов, подтверждающее результаты преимущества предложенного подхода.

1. *Moody J., Darken C. J.* Fast learning in networks of locally-tuned processing units // *Neural Comp.* – 1989. – N 1. – P. 281–294.
2. *Park J., Sandberg I.W.* Universal approximation using radial-basis-function networks // *Ibid.* – 1991. – N 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. – N 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 // *Ibid.* – 1994. – N 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. P. № 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.* – NY: Academic, 1992. – 264 p.
8. *Daubechies I.* *Ten Lectures on Wavelets.* – Philadelphia, PA: SIAM., 1992. – 228 p.
9. *Meyer Y.* *Wavelets: Algorithms and Applications.* – *Ibid.* – 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.* – 2005. – 16 (4). – P. 862–874.
11. *Zhang Q.H., Benveniste A.* Wavelet networks // *Ibid.* – 1992. – 3 (6). – P. 889–898.
12. *Wavelet neural networks for function learning / J. Zhang, G.G. Walter, Y. Miao et al.* // *IEEE Trans. on Signal Process.* – 1995. – 43(6). – P. 1485–1497.
13. *Zhang Q.H.* Using wavelet network in nonparametric estimation // *IEEE Trans. on Neural Networks.* – 1997. – 8(2). – 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. K. Markov, K. Ivanova, I. Mitov.* – Intern. Book Series «Information Science and Computing», N 2. – Sofia: Inst. of Inform. Theories and Appl. 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. J. on Inform. Theory and Appl.* – 2008. – 15. – N 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. *Анализ клинических данных в медицинских исследованиях на основе методов вычислительного интеллекта / В.В. Бойко, Е.В. Бодянский, Е.А. Винокурова и др.* // Харьков: ТО Эксклюзив, 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. *Ивахненко А.Г.* Долгосрочное прогнозирование и управление сложными системами. – Киев: Техніка, 1975. – 311 с.
20. *Ивахненко А.Г., Степашко В.С.* Помехоустойчивость моделирования. – Киев: Наук. думка, 1985. – 216 с.

21. *Степанко В.С.* Анализ эффективности критериев структурной идентификации прогнозирующих моделей // Проблемы управления и информатики. – 1994. – № 3–4. – С. 13–21.
22. *Степанко В.С.* Теоретичні аспекти МГУА як методу індуктивного моделювання // УСИМ. – 2003. – № 2. – С. 31–44.
23. *Bodyanskiy Ye., Vynokurova O.* Hybrid radial-basis neuro-fuzzy wavelon in the non-stationary sequences forecasting problems // Proc. 2nd Int. Conf. on Inductive Modelling. – Sept. 15–19. – 2008. – Kyiv. – P. 144–147.
24. *Itakura F.* Maximum prediction residual principle applied to speech recognition // IEEE Trans. on Acoustics, Speech, and Signal Processing. – 1975. – 23. – P. 67–72.
25. *Льюнг Л.* Идентификация систем. Теория для пользователя. – М.: Наука. ГРФМЛ, 1991. – 432 с.
26. *Бодянский Е.В.* Адаптивные алгоритмы идентификации нелинейных объектов управления // АСУ и приборы автоматизи. – Харьков: Выща шк., 1987. – 81. – С. 43–46.
27. *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.
28. *Bodyanskiy Ye., Kolodyazhnyi 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.
29. *Narendra K.S., Parthasarathy K.* Identification and control of dynamic systems using neural networks // IEEE Trans. on Neural Networks. – 1990 – 1. – N 1. – P. 4–26.
30. *Chiu S.* Fuzzy model identification based on cluster estimation // J. of Intelligent and Fuzzy Systems. – 1994. – 2. – № 3. – P. 267–278.

© Е.В. Бодянский, Е.А. Винокурова, 2009

Окончание статьи Ю.А. Прокопчука

На новом уровне описания находится решение. Если решения нет, то модели знаний необходимо скорректировать. Отметим, что наличие или отсутствие решения может зависеть от субъективной оценки истинности моделей знаний (представительности выборок на том или ином уровне общности).

Заключение. Приведенные результаты относятся к случаю фиксированного D (множества заключений). Для теста τ_d также можно построить граф доменов. Домены заключений на более высоком уровне общности необходимо строить таким образом, чтобы исключить артефакты предыдущего уровня (путем объединения заключений, приводящих к артефактам). Для каждого уровня общности по заключениям выполняется описанная в статье процедура построения истинных предельных моделей знаний многоуровневого описания действительности.

На практике данный метод применялся, в основном, для решения медицинских задач диагностики, прогнозирования и оптимизации стратегии лечения. Максимальное количество тестов равнялось 34 (в задаче прогнозирования отдаленных результатов после инфаркта

миокарда). Среднее количество тестов в решаемых задачах – 10–15. В настоящее время с помощью магистров кафедры информационных технологий и кибернетики Украинского государственного химико-технологического университета предпринимаются попытки значительного расширения сферы применения метода (программная реализация метода – одна из лабораторных работ по курсу «Экспертные системы»).

1. *Прокопчук Ю.А.* Интеллектуальные медицинские системы: формально-логический уровень. – Дн-ск: ИТМ НАНУ, 2007. – 259 с.
2. *Информационные технологии в образовании и здравоохранении / А.А. Алпатов, Ю.А. Прокопчук, О.В. Юденко и др.* – Дн-ск: ИТМ НАНУ, 2008. – 287 с.
3. *Клещев А.С.* Задачи индуктивного формирования знаний в терминах непримитивных онтологий предметных областей. – Владивосток: ИАПУ ДВО РАН, 2003. – 35 с. – (Препринт/ ИАПУ ДВО РАН; № 6).
4. *Ларичев О.И.* Вербальный анализ решений. – М.: Наука, 2006. – 245 с.
5. *Мейер Д.* Теория реляционных баз данных. – М.: Мир, 1987. – 608 с.

© Ю.А. Прокопчук, 2009