

УДК 004.032.26

Е.В. Бодянский, Е.А. Викторов, И.П. Плисс
**САМООРГАНИЗАЦИЯ АРХИТЕКТУРЫ НЕО-ФАЗЗИ-НЕЙРОННОЙ
СЕТИ ПРИ ПОМОЩИ МЕТОДА ГРУППОВОГО УЧЁТА
АРГУМЕНТОВ**

Аннотация. В статье рассматривается решение проблемы оптимизации структуры нео-фаззи-нейронной сети при помощи метода группового учёта аргументов, а также приводятся экспериментальные результаты и их сравнительная характеристика для сети, синтезированной при помощи МГУА, и полной сети.

Ключевые слова: нейронные сети, нечёткая логика, метод группового учёта аргументов, самоорганизация, нео-фаззи нейрон.

Введение. В последнее время искусственные нейронные сети всё чаще и чаще используются для обработки сигналов, порождённых теми или иными нестационарными, стохастическими или хаотическими системами. Это обусловлено как хорошими аппроксимирующими свойствами обученных нейронных сетей, так и их способностью работать в параллельном режиме с зашумлёнными. Традиционно под обучением понимается процесс настройки весовых коэффициентов нейронной сети, на основе той или иной процедуры оптимизации принятого критерия обучения [1, 2]. Однако, для повышения точности решения рассматриваемой задачи можно настраивать не только веса, но и архитектуру нейронной сети путём либо увеличения количества нейронов относительно исходной простой архитектуры, либо путём уменьшения их числа в исходной избыточной архитектуре. Настройка архитектуры позволяет добиться максимально эффективного решения рассматриваемой задачи, а, соответственно, вопрос об оптимальности используемой архитектуры приобретает значимость для практического применения искусственных нейронных сетей.

Как было показано ранее, использование метода группового учёта аргументов (МГУА) позволяет получить оптимальную архитектуру нейронной сети для решаемой задачи [3] посредством того, что в формировании целевого выходного сигнала принимают

© Бодянский Е.В., Викторов Е.А., Плисс И.П., 2009

участие только те входные параметры, которые улучшают его качество. В статье рассматривается использование МГУА для самоорганизации нео-фаззи-нейронной сети, которая является гибридной системой, а соответственно обладает существенным преимуществом по сравнению с традиционными нейронными сетями – возможностью реализовывать нечёткий вывод, что позволяет интерпретировать получаемые на выходе результаты [4]. Как известно, неинтерпретируемость результатов является недостатком большинства нейро-архитектур, зачастую ограничивающим их использование при решении тех или иных задач. Использование МГУА для синтеза архитектуры нео-фаззи-нейронной сети позволит повысить точность выходного сигнала и, вместе с тем, сохранит все положительные свойства нейро-нечётких систем.

Нео-фаззи-нейрон. Архитектура нео-фаззи-нейрона впервые была предложена Такеши Ямакавой и его соавторами [5-7], которые отмечают, что основными преимуществами этого нейрона являются высокая скорость обучения, вычислительная простота, возможность нахождения глобального минимума критерия обучения в реальном режиме времени, а также то, что функционирование этого элемента может быть описано набором лингвистических «если-то» правил. Нео-фаззи-нейрон – это многовходовая нелинейная система с одним выходом, представленная на рис. 1 и реализующая отображение вида

$$\hat{y} = \sum_{i=1}^n f_i(x_i), \quad (1)$$

где x_i – i -ый вход ($i = 1, 2, \dots, n$), а \hat{y} – выход системы. «Строительными» блоками нео-фаззи-нейрона являются нелинейные синапсы NS_i , осуществляющие преобразование i -го входного сигнала

$$f_i(x_i) = \sum_{j=1}^h w_{ji} \mu_{ji}(x_i)$$

и реализующие нечёткий логический вывод

$$\text{IF } x_i \text{ IS } x_{ji} \text{ THEN THE OUTPUT IS } w_{ji},$$

где x_{ji} – нечёткое множество с функцией принадлежности μ_{ji} , w_{ji} – синглтон (синаптический вес) в консеквенте [6]. Несложно заметить, что фактически нелинейный синапс реализует нечёткий вывод Такаги-Сугено нулевого порядка.

Традиционно функции принадлежности $\mu_{ji}(x_i)$ в antecedенте имеют сопряженно-треугольный вид, как показано на рис. 2.




Рисунок 1 - Нео-фаззи-нейрон

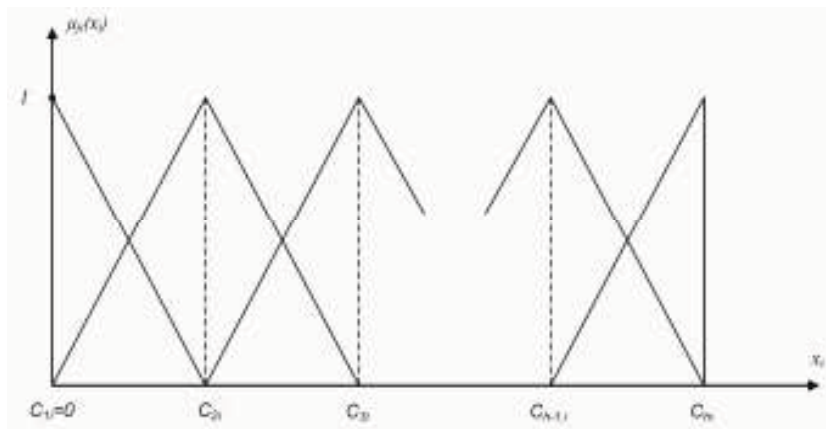


Рисунок 2 - Треугольные функции принадлежности

Для предварительно преобразованных входных переменных x_i (обычно $0 \leq x_i \leq 1$), функции принадлежности могут быть записаны в виде:

$$\mu_{j_i}(x_i) = \begin{cases} \frac{x_i - c_{j-1,i}}{c_{j_i} - c_{j-1,i}}, & x \in [c_{j-1,i}, c_{j_i}], \\ \frac{c_{j+1,i} - x_i}{c_{j+1,i} - c_{j_i}}, & x \in [c_{j_i}, c_{j+1,i}], \\ 0 - \text{иначе,} \end{cases}$$

где c_{j_i} – центры соответствующих функций принадлежности, выбираемые достаточно произвольным образом, однако, обычно равномерно распределённые на интервале $[0,1]$, что позволяет упростить процесс нечёткого вывода, поскольку входной сигнал x_i одновременно активирует только две соседних функции принадлежности, сумма значений которых равна единице (разбиение Руспини), т.е. $\mu_{j_i}(x_i) + \mu_{j+1,i}(x_i) = 1$.

Мы предлагаем использовать кубические сплайны в роли функций принадлежности, которые описываются следующей системой уравнений

$$\mu(x) = \begin{cases} 0.25 \left(2 + 3 \frac{2x - x_i - x_{i-1}}{x_i - x_{i-1}} - \left(\frac{2x - x_i - x_{i-1}}{x_i - x_{i-1}} \right)^3 \right), & x \in [x_{i-1}, x_i], \\ 0.25 \left(2 - 3 \frac{2x - x_{i+1} - x_i}{x_{i+1} - x_i} + \left(\frac{2x - x_{i+1} - x_i}{x_{i+1} - x_i} \right)^3 \right), & x \in (x_i, x_{i+1}] \end{cases}$$

и изображены на рис. 3.

Использование кубических сплайнов позволяет добиться более высокого качества аппроксимации существенно нелинейных функций, и при этом предложенные функции принадлежности также удовлетворяют требованию разбиения Руспини, что уменьшает вычислительную сложность алгоритма настройки весовых коэффициентов. Результат нечёткого вывода, получаемый при помощи дефаззификации по методу центра тяжести, может быть представлен в достаточно простой форме:

$$f_i(x_i) = w_{j_i} \mu_{j_i}(x_i) + w_{j+1,i} \mu_{j+1,i}(x_i),$$

а результат (1) – \hat{y} вычисляется путём суммирования $f_i(x_i)$.




Рисунок 3 - Кубические сплайны

При подаче на вход нео-фаззи-нейрона векторного сигнала $x(k) = (x_1(k), x_2(k), \dots, x_n(k))^T$ (где $k = 1, 2, \dots$ – дискретное время), его выход определяется функциями принадлежности $\mu_{ji}(x_i(k))$ и настраиваемыми весовыми коэффициентами $w_{ji}(k-1)$, полученными в предыдущий момент обучения:

$$\hat{y}(k) = \sum_{i=1}^n f_i(x_i(k)) = \sum_{i=1}^n \sum_{j=1}^h w_{ji}(k-1) \mu_{ji}(x_i(k)),$$

при этом нео-фаззи-нейрон содержит $h \cdot n$ весов, подлежащих определению.

Критерием обучения является стандартная квадратичная функция ошибки (целевая функция):

$$E(k) = \frac{1}{2} (y(k) - \hat{y}(k))^2 = \frac{1}{2} e(k)^2 = \frac{1}{2} \left(y(k) - \sum_{i=1}^n \sum_{j=1}^h w_{ji} \mu_{ji}(x_i(k)) \right)^2,$$

минимизируемая при помощи традиционного градиентного алгоритма, в данном случае приобретающего форму:

$$\begin{aligned} w_{ji}(k+1) &= w_{ji}(k) + \eta e(k+1) \mu_{ji}(x_i(k+1)) = \\ &= w_{ji}(k) + \eta \left(y(k+1) - \sum_{i=1}^n \sum_{j=1}^h w_{ji}(k) \mu_{ji}(x_i(k+1)) \right) \mu_{ji}(x_i(k+1)), \end{aligned}$$

где $y(k)$ – значение выходного сигнала, η – параметр шага поиска, определяющий скорость сходимости процесса обучения.

С целью увеличения скорости обучения в [8, 9] был использован одношаговый оптимальный алгоритм Качмажа-Уидроу-Хоффа [10-12] в форме

$$w(k+1) = w(k) + \frac{y(k+1) - w^T(k)\mu(x(k+1))}{\|\mu(x(k+1))\|^2} \mu(x(k+1)), \quad (2)$$

где

$\mu(x(k+1)) = (\mu_{h_1}(x_1(k+1)), \dots, \mu_{h_1}(x_1(k+1)), \dots, \mu_{h_2}(x_2(k+1)), \dots, \mu_{j_i}(x_i(k+1)), \dots, \mu_{h_n}(x_n(k+1)))^T$, $w(k) = (w_{h_1}(k), \dots, w_{h_1}(k), \dots, w_{h_2}(k), \dots, w_{j_i}(k), \dots, w_{h_n}(k))^T$ – $(hn) \times 1$ -векторы, образованные соответствующими переменными, и его экспоненциально взвешенная модификация

$$\begin{cases} w(k+1) = w(k) + r^{-1}(k+1)(y(k+1) - w^T(k)\mu(x(k+1)))\mu(x(k+1)), \\ r(k+1) = \alpha r(k) + \|\mu(x(k+1))\|^2, 0 \leq \alpha \leq 1, \end{cases} \quad (3)$$

обладающая как фильтрующими, так и сглаживающими свойствами.

Если же обучающая выборка задана априори, настройка может производиться в пакетном режиме за одну эпоху с помощью обычного метода наименьших квадратов.

Далее нео-фаззи-нейрон используется нами в качестве строительного блока для, так называемой, нео-фаззи-нейронной сети.

Нео-фаззи-нейронная сеть и самоорганизация её архитектуры при помощи МГУА. Нео-фаззи-нейронная сеть – это многослойная архитектура с прямым распространением сигнала, состоящая из нео-фаззи-нейронов. Трёхслойная нео-фаззи-нейронная сеть [13] с n входами и m выходами представлена на рис. 4.

Предлагаемая архитектура структурно полностью совпадает с архитектурой трёхслойного персептрона за исключением того, что в ней в качестве узлов используются нео-фаззи-нейроны вместо элементарных персептронов Розенблатта. Использование нео-фаззи-нейронов наряду с применением МГУА для синтеза архитектуры сети позволяет избежать применения методов, основанных на обратном распространении ошибки (как в случае с многослойным персептроном), которые, как известно, являются весьма сложными с вычислительной точки зрения и влекут за собой существенные временные затраты на настройку весовых коэффициентов сети.

В случае, если используются двухвходовые нео-фаззи-нейроны, традиционный МГУА может быть применён для синтеза оптимальной архитектуры нео-фаззи-нейронной-сети.




Рисунок 4 - Нео-фаззи-нейронная сеть

Основная идея МГУА-алгоритма лежит в последовательном наращивании слоёв в сети до того момента, пока внешний критерий не начинает возрастать [14-18]. Пошагово процедура выглядит следующим образом:

1) формирование пар выходов нео-фаззи-нейронов текущего слоя (на первом этапе используется множество входных сигналов). Каждая полученная пара сигналов подаётся на вход соответствующему нео-фаззи-нейрону;

2) настройка весовых коэффициентов каждого нео-фаззи-нейрона, используя обучающую выборку;

3) вычисление внешнего критерия для каждого нео-фаззи-нейрона, используя тестовую выборку:

$$\varepsilon_p^{[s]} = \frac{1}{N_{nep}} \sum_{i=1}^{N_{nep}} (y(i) - \xi_p^{[s]}(i))^2, \quad (4)$$

где N_{nep} - размер тестовой выборки, s - номер слоя, p - номер нейрона в текущем слое $p = \overline{1, n_s}$, $\xi_p^{[s]}(i)$ - выходной сигнал p -го нейрона s -го слоя полученный в результате подачи на вход сети i -го входного вектора;

4) нахождение минимального значения внешнего критерия, принимая во внимание все нео-фаззи-нейроны текущего слоя:

$$\varepsilon^{[s]} = \min_p \varepsilon_p^{[s]};$$

5) проверка условия

$$\varepsilon^{[s]} > \varepsilon^{[s-1]}, \quad (5)$$

где $\varepsilon^{[s]}, \varepsilon^{[s-1]}$ - минимальные значения внешнего критерия для s -го и $(s-1)$ -го слоёв соответственно. В случае, если условие (5) выполняется, то необходимо вернуться к предыдущему слою и оставить один единственный нео-фаззи-нейрон с минимальным внешним критерием (4), удалив при этом все остальные. Выход этого нейрона будет считаться выходом сети. В противоположном случае, необходимо выбрать F «лучших» нейронов с минимальными значениями критерия (4) и вернуться к шагу 1 для добавления следующего слоя нейронов;

б) определение окончательной структуры нейронной сети, последовательно продвигаясь от выходного нео-фаззи-нейрона ко входному слою, сохраняя нейроны, выходы которых используются в следующих слоях, и удаляя остальные.

После окончания работы алгоритма МГУА мы получаем оптимальную архитектуру нео-фаззи-нейронной сети для решения данной конкретной задачи. Несложно заметить, что результатом является не только оптимальная архитектура, но и обученная нейронная сеть в целом, способная обрабатывать новые входные данные. Одним из наиболее важных преимуществ использования МГУА для синтеза нео-фаззи-архитектуры является возможность использования простых и высокоскоростных процедур обучения для настройки весовых коэффициентов нео-фаззи-нейронов, поскольку обучение сети происходит слой за слоем.

Имитационное моделирование. Мы применили предложенную нео-фаззи-нейронную сеть, синтезированную при помощи МГУА, для решения стандартной задачи классификации рака молочной железы. Использовалась выборка, содержащая 699 примеров (<ftp://ftp.cs.wisc.edu/math-prog/cpo-dataset/machine-learn/cancer/cancer1/datacum>). 16 примеров из этой выборки содержали пропущенные значения, поэтому были удалены из исходного множества. Оставшиеся 683 примера были разделены на обучающую (70% - 478 примеров) и тестовую (30% - 205 примеров) выборки.

Каждый пример содержал 9 параметров – показания медицинских анализов и один целевой атрибут, определяющий характер опухоли – доброкачественная или злокачественная. Формально задача ставилась следующим образом: синтезировать и

обучить нейро-фаззи нейронную сеть, которая бы, используя показания медицинских анализов, смогла ставить диагноз о характере заболевания. Все данные из выборки были нормализованы на интервал $[-1; 1]$.

Для сравнения подобная задача решалась при помощи трёхслойной нео-фаззи-нейронной сети с полной архитектурой: 9 нео-фаззи-нейронов в первом слое, 3 – во втором и 1 выходной. Полученные результаты классификации приводятся в таблице 1.

Когда выходной сигнал находится в пределах $[0.3; 0.7]$, вероятность правильной классификации уменьшается, поэтому количество таких случаев также учитывалось при анализе результатов. Классифицированные таким образом примеры помечались, как «вне зоны доверия», и статистика по ним также приведена в таблице 1.

Таблица 1

Сравнительные результаты классификации

Архитектура ИНС	Точность на обуч. выборке / примеры «вне зоны доверия»	Точность на тест. выборке / примеры «вне зоны доверия»
Нео-фаззи-нейронная сеть синтезированная МГУА	99,8% / 1	98% / 4
Полная нео-фаззи-нейронная сеть	98% / 3	94% / 15

Как видно из результатов, нео-фаззи-нейронная сеть, синтезированная при помощи МГУА, позволяет добиться достаточно высокого качества классификации и существенно улучшить результаты по сравнению с полной архитектурой, особенно на тестовой выборке. Это можно объяснить тем, что полная архитектура, очевидно, является более сложной моделью, а, как известно, излишняя сложность модели может привести к потере обобщающих свойств, а, следовательно, и понижению качества классификации. МГУА позволяет синтезировать оптимальную структуру сети, в которой игнорируются входы, не вносящие существенного вклада в

получение правильного выходного сигнала. На рис. 5 показана структура нео-фаззи-нейронной сети, синтезированная при помощи МГУА. Легко заметить, что она значительно проще, чем полная сеть, однако при этом позволяет добиться более высоких результатов.




Рисунок 5 - Нео-фаззи-нейронная сеть, синтезированная при помощи МГУА

Выводы. В статье рассмотрен способ автоматизированного синтеза оптимальной архитектуры нео-фаззи-нейронной сети, основанный на методе группового учёта аргументов. Теоретические обоснования и результаты экспериментов подтверждают эффективность развиваемого подхода к структурной самоорганизации нео-фаззи-нейронной сети.

ЛИТЕРАТУРА

1. Cichocki A., Unbehauen R. Neural Networks for Optimization and Signal Processing. – Stuttgart: Teubner, 1993.
2. Haykin S. Neural Networks. A Comprehensive Foundation. – Upper Saddle River, N.J.: Prentice Hall, 1999. – 864 p.
3. Bodyanskiy Ye., Zaychenko Yu., Pavlikovskaya E., Samarina M., Viktorov Ye. The neo-fuzzy neural network structure optimization using the GMDH for the solving forecasting and classification problems // Proc. 3rd International Workshop on Inductive Modeling, Poland, Krynica. – 2009. – CD. – P. 77-89.

4. Jang Jr. S. R., Sun C. T., Mizutani E. Neuro-Fuzzy and Soft Computing. A Computational Approach to Learning and Machine Intelligence. – N.J.: Prentice Hall, 1997. – 614 p.
5. Yamakawa T., Uchino E., Miki T., Kusanagi H. A neo fuzzy neuron and its applications to system identification and prediction of the system behavior // Proc. 2-nd Int. Conf. on Fuzzy Logic and Neural Networks “IIZUKA-92”. Iizuka, Japan. – 1992. – P. 477–483.
6. Uchino E., Yamakawa T. Soft computing based signal prediction, restoration and filtering // Intelligent Hybrid Systems: Fuzzy Logic, Neural Networks and Genetic Algorithms. Ed. Da Ruan. – Boston: Kluwer Academic Publisher. – 1997. – P. 331–349.
7. Miki T., Yamakawa T. Analog implementation of neo-fuzzy neuron and its on-board learning // Computational Intelligence and Applications. Ed. N. E. Mastorakis. – Piraeus: WSES Press. – 1999. – P. 144–149.
8. Bodyanskiy Ye., Kokshenev I., Kolodyazhniy V. An adaptive learning algorithm for a neo-fuzzy neuron // Proc. 3rd Int. Conf. of European Union Soc. for Fuzzy Logic and Technology (EUSFLAT 2003). – Zittau, Germany. – 2003. – P. 375–379.
9. Kolodyazhniy V., Bodyanskiy Ye., Otto P. Universal approximator employing neo-fuzzy neurons // In “Computational Intelligence: Theory and Applications.” Ed. by B. Reusch. – Berlin-Heidelberg: Springer. – 2005. – P. 631–640.
10. Kaczmarz S. Angenaeherte Ausloesung von Systemen Linearer Gleichungen // Bull. Int. Acad. Polon. Sci. – 1937. – Let. A. – S. 355–357.
11. Kaczmarz S. Approximate solution of systems of linear equations // Int. J. Control. – 1993. – 53. – P. 1269–1271.
12. Widrow B., Hoff Jr. M. E. Adaptive switching circuits // 1960 IRE WESCON Convention Record. – N.Y.: IRE. – 1960. – Part 4. – P. 96–104.
13. Bodyanskiy Ye., Kolodyazhniy V. Adaptive nonlinear control using neo-fuzzy model / Eds. by O. Sawodny, P. Scharff “Synergies between Information Processing and Automation”. – Aachen: Shaker Verlag, 2004. – P. 122-127.

14. Zaychenko Yu. The fuzzy group method of data handling and its application for economical processes forecasting // Scientific Inquiry. - 2006. - 7. - №1. - P. 83-96.
15. Zaychenko Yu. Fuzzy method of inductive modeling in problems of macroeconomic indexes forecasting // System Researches and Informational Technologies. - 2003. - №3. - P. 25-45.
16. Zaychenko Yu. P., Zayetz I.O. The synthesis and adaptation of fuzzy forecasting model based of self-organization method // Science News of NTUU “KPI”. - 2001. - 2.
17. Zaychenko Yu. P., Zayetz I.O. Research of different types of partial descriptions in problems of synthesis of fuzzy forecasting models // Science Works of Donetsk NTU. - 2005. - 47. - P. 341-349.
18. Zaychenko Yu. P. Comparative analysis of forecasting models built using distinct and fuzzy GMDH with different algorithms of fuzzy forecasting models generation // Materials of international seminar of inductive modeling IWIM 2005. - 2005.

Получено 25.09.2009г.