

УДК 518.9

**ИССЛЕДОВАНИЕ КАСКАДНЫХ НЕО-ФАЗЗИ НЕЙРОННЫХ
СЕТЕЙ В ЗАДАЧАХ ПРОГНОЗИРОВАНИЯ
В ФИНАНСОВОЙ СФЕРЕ**

Ю.П. ЗАЙЧЕНКО

Рассмотрена проблема прогнозирования финансовых процессов на рынках ценных бумаг. Для ее решения предложено применение каскадных нео-фаззи нейронных сетей. Описана архитектура этих сетей, рассмотрены алгоритмы обучения — градиентный и Уидроу-Хоффа. Рассмотрена проблема синтеза структуры нео-фаззи каскадной сети и предложен алгоритм МГУА для ее решения. Проведены экспериментальные исследования точности прогнозирования биржевых индексов с применением указанных методов обучения в зависимости от числа каскадов, числа входных переменных и их лингвистических значений и оценена их эффективность. Проведенные исследования показали, что каждый алгоритм имеет свои сильные и слабые стороны. Градиентный метод может давать более точные прогнозы, но при этом время его работы достаточно большое. Алгоритм Уидроу-Хоффа, наоборот, дает прогноз за очень короткое время, но имеет довольно большие отклонения от реальных значений. В целом, каскадная нео-фаззи нейронная сеть является хорошим инструментом для прогнозирования финансовых процессов на фондовых рынках в условиях неопределенности и неполноты информации. При этом ее прогноз значительно точнее в сравнении с классическими нечеткими нейронными сетями ANFIS и TSK, а также ННС с выводом Мамдани.

ВВЕДЕНИЕ

В последние годы нечеткие нейронные сети (ННС) все шире используются в задачах прогнозирования в макроэкономике и финансовой сфере. Их отличительными особенностями является возможность прогнозирования нелинейных нестационарных процессов, гибкость, широкий арсенал алгоритмов обучения параметров сети, возможности учета экспертной информации при формулировании базы нечетких правил вывода, использование кроме количественной и качественной информации. Вместе с тем обычные процедуры обучения, основанные на использовании градиента, обладают медленной сходимостью, что не позволяет использовать их для обучения и прогнозирования в режиме онлайн. Трудоемкость процесса обучения связана, в частности, с тем, что кроме линейных параметров сети-весов приходится также настраивать и нелинейные параметры функций принадлежности соответствующих правил. Это типично для ННС типа TSK (Takagi, Sugeno,

Kang) [1]. Поэтому в последние годы появились новые архитектуры ННС, в частности, нео-фаззи нейронные сети, основным структурным элементом которых является нео-фаззи нейрон [1, 2]. В такой сети веса связей представляют некоторые вейвлет-функции с использованием стандартных вейвлетов, которые не адаптируются, а в процессе обучения сети изменяются только линейные параметры — веса связей [2].

Цель работы — исследование нео-фаззи нейронных сетей в задачах прогнозирования на рынках ценных бумаг и сравнительный анализ эффективности различных методов их обучения.

НЕО-ФАЗЗИ НЕЙРОН

Рассмотрим нео-фаззи нейрон с несколькими входами и единственным выходом, который изображен на рис. 1 [1, 2]. Он реализуется отображением:

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

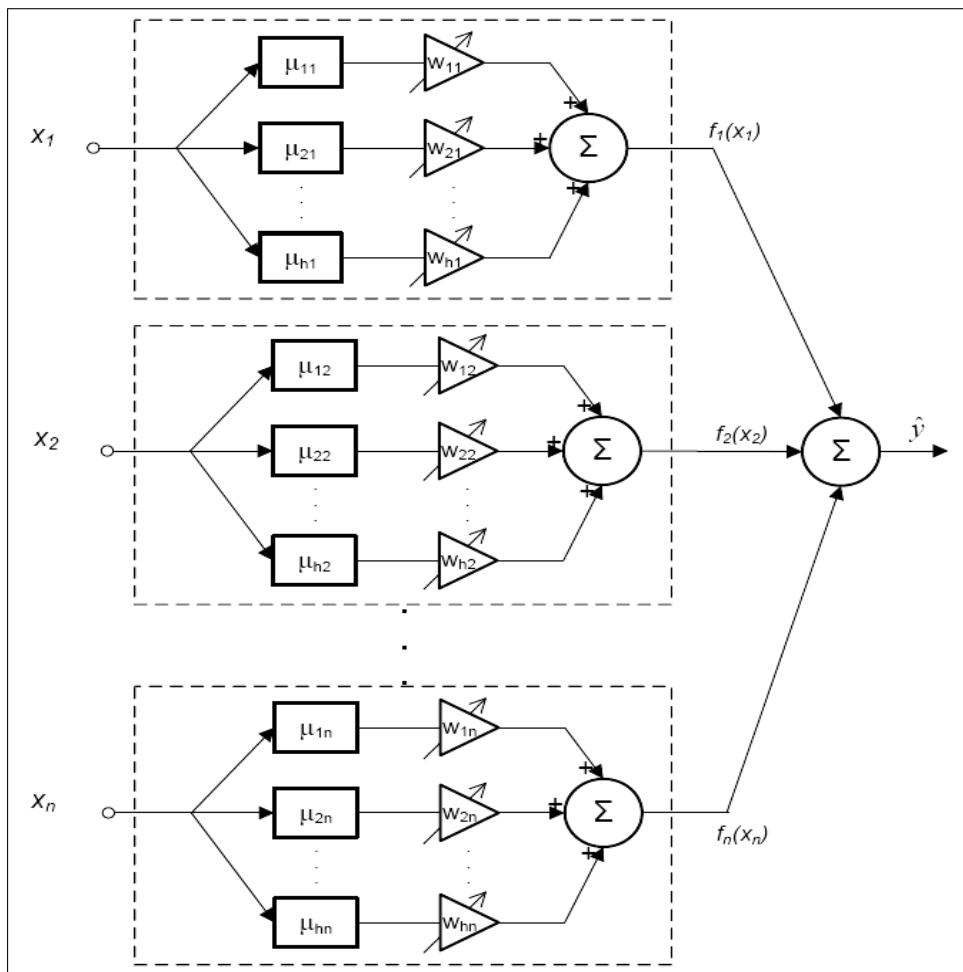


Рис. 1. Архитектура нео-фаззи нейрона

где x_i — i -й вход ($i=1,2,\dots,n$), \hat{y} — выход системы. Структурные блоки нео-фаззи нейрона является нелинейным синапсом, который переводит i -й входной сигнал в форму:

$$f_i(x_i) = \sum_{j=1}^h w_{ji} \mu_{ji}(x_i) \quad (2)$$

и выполняет нечеткий вывод: Если X_i есть x_i , то выход есть w_{ji} , где x_{ji} — нечеткое число, функция принадлежности которого μ_{ji} , w_{ji} — синаптический вес. Очевидно, что нелинейный синапс фактически реализует нечеткий вывод Такаги-Сугено нулевого порядка.

Когда векторный сигнал $x(k) = (x_1(k), x_2(k), \dots, x_n(k))^T$ (k — дискретное время) подается на вход нео-фаззи нейрона, выход этого нейрона определяется обеими функциями принадлежности $\mu_{ji}(x_i(k))$ и настраиваемыми синаптическими весами $w_{ji}(k-1)$, которые были получены в предыдущей эпохе обучения:

$$\hat{y}(k) = \sum_{i=1}^n f_i(x_i(k)) = \sum_{i=1}^n \sum_{j=1}^h w_{ji}(k-1) \mu_{ji}(x_i(k)). \quad (3)$$

Таким образом, нео-фаззи нейрон содержит hn синаптических веса, которые необходимо определить.

Обычно функции принадлежности μ_{ji} являются элементарными треугольными функциями, как показано на рис. 2.




Рис. 2. Треугольные функции принадлежности

Для предварительно нормированных входных переменных x_i (по обыкновению от 0 до 1) функция принадлежности может быть описана в виде

$$\mu_{ij}(x_i) = \begin{cases} \frac{x_i - c_{j-1,i}}{c_{ji} - c_{j-1,i}}, & x \in [c_{j-1,i}, c_{ji}], \\ \frac{c_{j+1,i} - x_i}{c_{j+1,i} - c_{ji}}, & x \in [c_{ji}, c_{j+1,i}], \\ 0, & \text{в других случаях,} \end{cases} \quad (4)$$

где c_{ij} — случайно выбранные центры соответствующих функций принадлежности.

Как лингвистические значения, они равномерно распределены на интервале $[0,1]$. Это способствует упрощению процессов обработки информации, поскольку

$$\mu_{ji}(x_i) + \mu_{j+1,i}(x_i) = 1. \quad (5)$$

Таким образом, исходный сигнал нелинейного синапса может быть описан в довольно простой форме:

$$f_i(x_i) = \mu_{ji}(x_i)w_{ji} + \mu_{j+1,i}(x_i)w_{j+1,i}. \quad (6)$$

Выходной сигнал нео-фаззи нейрона в целом имеет такой вид:

$$\hat{y} = \sum_{i=1}^n f(x_i(k)) = \sum_{i=1}^n \sum_{j=1}^h w_{ji}(k-1) \mu_{ji}(x_i(k)). \quad (7)$$

Суммируя $f_i(x_i)$, находим выход y согласно формулы (7). Когда вектор сигнала $x(k) = (x_1(k), x_2(k), \dots, x_n(k))$ (здесь $k = 1, 2, \dots, n$ является дискретным моментом времени) подается на вход нео-фаззи нейрона, выход этого нейрона определяется, как взвешенные функции принадлежности $\mu_{ji}(x_i(k))$, и использует настроенные синаптические веса w_{ji} , которые были получены на предыдущих этапах работы

Среди наиболее важных преимуществ нео-фаззи нейрона можно отметить высокую скорость обучения, вычислительную простоту, возможность нахождения глобального минимума критерия обучения в режиме реального времени. Критерием обучения (целевой функцией) есть стандартная локальная квадратичная функция ошибки:

$$E(k) = \frac{1}{2} (y(k) - \hat{y}(k))^2 = \frac{1}{2} e^2 (y(k) - \sum_{i=1}^n \sum_{j=1}^h w_{ji} \mu_{ji}(x_i(k)))^2, \quad (8)$$

которую минимизируем с помощью обычного градиентного пошагового алгоритма (9):

$$\begin{aligned} w_{ji}(k+1) &= w_{ji}(k) + \eta e(k+1) \mu_{ji}(x_i(k)) = \\ &= w_{ji}(k) + \eta ((y(k) - \sum_{i=1}^n \sum_{j=1}^h w_{ji} \mu_{ji}(x_i(k))) \mu_{ji}(x_i(k))), \end{aligned} \quad (9)$$

где $y(k)$ — целевое значение выходной переменной, η является скалярным параметром-скорость обучения.

С целью увеличения скорости обучения возможно использовать одношаговый алгоритм Уидроу-Хоффа [2]

$$w(k+1) = w(k) + \frac{y(k+1) - W^T \mu(x(k+1))}{\|\mu(x(k+1))\|^2} \mu(x(k+1)), \quad (10)$$

где

$$\begin{aligned} \mu(x(k+1)) &= \\ &= \mu_{11}(x_1(k+1)), \dots, \mu_{h1}(x_1(k+1)), \dots, \mu_{1n}(x_n(k+1)), \dots, \mu_{hn}(x_n(k+1)) \end{aligned}$$

или его його модификации.

АРХИТЕКТУРА КАСКАДНОЙ НЕО-ФАЗЗИ НЕЙРОННОЙ СЕТИ

Архитектура каскадной нео-фаззи нейронной сети показана на рис. 3, характеризующее ее отображении имеет следующую форму [1]:

- нео-фаззи нейрон первого каскада:

$$\hat{y}^{[1]} = \sum_{i=1}^n \sum_{j=1}^h w_{ji}^{[1]} \mu_{ji}(x_i); \quad (11)$$

- нео-фаззи нейрон 2-го каскада:

$$\hat{y}^{[2]} = \sum_{i=1}^n \sum_{j=1}^h w_{ji}^{[2]} \mu_{ji}(x_i) + \sum_{j=1}^h w_{j,n+1}^{[2]} \mu_{j,n+1}(\hat{y}^{[1]}); \quad (12)$$

- нео-фаззи нейрон 3-го каскада:

$$\hat{y}^{[3]} = \sum_{i=1}^n \sum_{j=1}^h w_{ji}^{[3]} \mu_{ji}(x_i) + \sum_{j=1}^h w_{j,n+1}^{[3]} \mu_{j,n+1}(\hat{y}^{[1]}) + \sum_{j=1}^h w_{j,n+2}^{[3]} \mu_{j,n+2}(\hat{y}^{[2]});$$

- нео-фаззи нейрон m -го каскада:

$$\hat{y}^{[m]} = \sum_{i=1}^n \sum_{j=1}^h w_{ji}^{[m]} \mu_{ji}(x_i) + \sum_{l=n+1}^{n+m-1} \sum_{j=1}^h w_{j,l}^{[m]} \mu_{j,l}(\hat{y}^{[l-n]}). \quad (13)$$

Следовательно, каскадная нео-фаззи нейронная сеть содержит $h(n + \sum_l^{m-1} l)$ настраиваемых параметров и, что важно, что все они линейно включены в описание (13).

Пусть μ -вектор функций принадлежности m -го нео-фаззи нейрона размерности $h(n + m - 1)$ имеет вид

$$\begin{aligned} \mu^{[m]} = & (\mu_{11}(x_1), \dots, \mu_{h1}(x_1), \mu_{12}(x_2), \dots, \mu_{h2}(x_2), \dots, \mu_{ij}(x_i), \dots \\ & \dots, \mu_{hn}(x_n), \mu_{1,n+1}(\hat{y}^{[1]}), \dots, \mu_{h,n+1}(\hat{y}^{[1]}), \dots, \mu_{h,n+m-1}(\hat{y}^{[m-1]})). \end{aligned}$$

И соответствующий вектор синаптических весов:

$$\begin{aligned} w^{[m]} = & w_{11}^{[m]}, w_{21}^{[m]}, \dots, w_{h1}^{[m]}, w_{12}^{[m]}, \dots, w_{h2}^{[m]}, \dots, w_{ji}^{[m]}, \dots, \\ & \dots, w_{hn}^{[m]}, w_{1,n+1}^{[m]}, \dots, w_{h,n+1}^{[m]}, \dots, w_{h,n+m-1}^{[m]} \end{aligned}^T,$$

который имеет ту же размерность. Тогда мы можем представить выражение (13) в векторном виде:

$$\hat{y}^{[m]} = w^{[m]T} \mu^{[m]}. \quad (14)$$

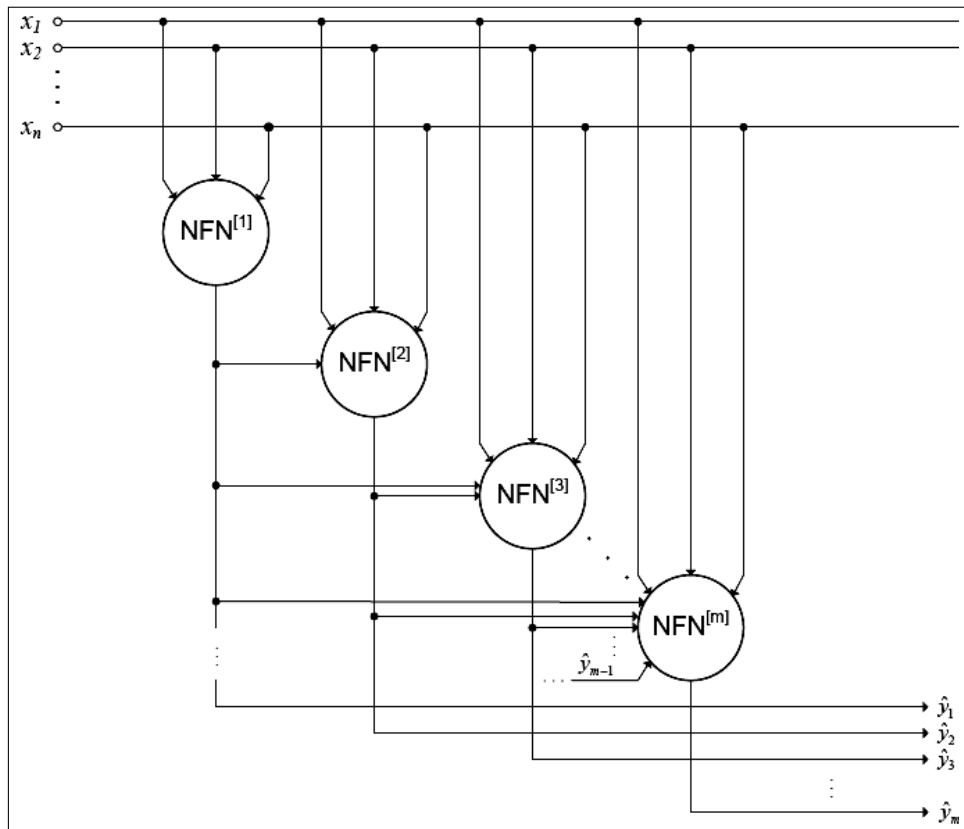


Рис. 3. Архитектура каскадной нео-фаззи нейронной сети

ОБУЧЕНИЕ КАСКАДНОЙ НЕО-ФАЗЗИ НЕЙРОННОЙ СЕТИ

Обучение каскадной нео-фаззи нейронной сети, может быть выполнено как в пакетном режиме, так и в режиме последовательной обработки информации (адаптивные настройки весов).

Во-первых, пусть рассматривается ситуация, когда обучающая выборка определена априорно, то есть мы имеем выборку значений

$$X(1), y(1); x(2), y(2); \dots; x(k), y(k); x(N), y(N).$$

Для нео-фаззи нейрона первого каскада $NFN[1]$ выборка значений функций принадлежности $\mu^{[1]}(1), \mu^{[1]}(2), \dots, \mu^{[1]}(k), \dots, \mu^{[1]}(N)$ вектора определяется таким образом:

$$\begin{aligned} \mu^{[1]}(k) = & \mu_{11}(x_1(k)), \dots, \mu_{h_1}(x_1(k)), \mu_{12}(x_2(k)), \dots, \mu_{h_2}(x_2(k)), \dots \\ & \dots, \mu_{ji}(x_i(k)), \dots, \mu_{hn}(x_n(k)). \end{aligned} \quad (15)$$

Затем, минимизируя критерий обучения:

$$E_N^{[1]} = \frac{1}{2} \sum_{k=1}^N (e^{[1]}(k)) = \frac{1}{2} \sum_{k=1}^N (y(k) - \hat{y}^{[1]}(k))^2,$$

вектор синаптических весов может быть определен так:

$$w^{[1]}(N) = \left(\sum_{k=1}^N (\mu^{[1]}(k) \mu^{[1]T}(k)) \right)^+ \sum_{k=1}^N \mu^{[1]}(k) y(k) = P^{[1]}(N) \sum_{k=1}^N \mu^{[1]}(k) y(k), \quad (16)$$

где $(\bullet)^+$ означает псевдоинверсию Мура-Пенроуза [2].

В случае последовательной обработки данных используется рекуррентный метод наименьших квадратов [1]:

$$\begin{cases} w^{[1]}(k+1) = w^{[1]}(k) + \frac{P^{[1]}(k)(y(k+1) - \mu^{[1]T}(k)w^{[1]}(k+1))}{1 + \mu^{[1]}(k+1)P^{[1]}(k)\mu^{[1]}(k+1)} \mu^{[1]}(k+1), \\ P^{[1]}(k+1) = P^{[1]}(k) - \frac{P^{[1]}(k)(\mu^{[1]}(k+1)\mu^{[1]T}(k+1)P^{[1]}(k))}{1 + \mu^{[1]}(k+1)P^{[1]}(k)\mu^{[1]}(k+1)} P^{[1]}(0) = \beta I, \end{cases} \quad (17)$$

где β — большое положительное число, а I является единичной матрицей с соответствующей размерностью.

С целью увеличения скорости обучения существует возможность использования одношагового алгоритма Уидроу-Хоффа (10) или его модификации [1, 2].

Использование алгоритмов адаптации (10) или (17) приводит к сокращению вычислительной сложности процесса обучения. В любом случае использование процедур (10) и (17) существенно сокращают время обучения, по сравнению с градиентным методом, лежащим в основе алгоритма Back Propagation.

После первого каскада обучающего соревнования синаптические веса нео-фаззи нейрона первого каскада $NFN[1]$ становится «замороженным», все значения $\hat{y}^{[1]}(1), \hat{y}^{[1]}(2), \dots, \hat{y}^{[1]}(k), \dots, \hat{y}^{[1]}(N)$ оказываются определенными и получаем второй каскад сети, который состоит из единственного нео-фаззи нейрона $NFN[2]$. Он имеет один дополнительный вход для сигнала выхода первого каскада. Затем снова используем процедуру (16) или (17) для настройки вектора весовых коэффициентов $w^{[2]}$, размерность которого $h(n+1)$.

В онлайн режиме нейроны обучаются последовательно, т.е. на основании входных сигналов $x(k)$. Пусть оценены синаптические веса $w^{[1]}(x)$ и получен вектор выходов $\hat{y}^{[1]}(k)$, затем используя вектор входов второго каскада $(x^T(k), \hat{y}^{[1]}(k))$ вычисляются веса $w^{[2]}(x)$ и выходы $\hat{y}^{[2]}(k)$. Для этой цели могут использоваться алгоритмы (16) и (17) одинаково хорошо.

Процесс роста нейронной сети (наращивание числа каскадов) продолжается до тех пор, пока мы не получим требуемую точность решения, а для настройки весовых коэффициентов последнего m -го каскада используются выражения:

- в пакетном режиме

$$\begin{aligned}
 w^{[m]}(N) &= \left(\sum_{k=1}^N (\mu^{[m]}(k) \mu^{[m]T}(k)) \right)^+ \sum_{k=1}^N \mu^{[m]}(k) y(k) = \\
 &= P^{[m]}(N) \sum_{k=1}^N \mu^{[m]}(k) y(k), \quad (18)
 \end{aligned}$$

$$\left\{ \begin{aligned}
 w^{[m]}(k+1) &= w^{[m]}(k) + \frac{P^{[m]}(k)(y(k+1) - w^{[m]T}(k)w^{[m]}(k+1))}{1 + \mu^{[m]T}(k+1)P^{[m]}(k)\mu^{[m]}(k+1)} \mu^{[m]}(k+1), \\
 P^{[m]}(k+1) &= P^{[m]}(k) - \frac{P^{[m]}(k)(\mu^{[m]}(k+1)\mu^{[m]T}(k+1)P^{[m]}(k))}{1 + \mu^{[m]T}(k+1)P^{[m]}(k)\mu^{[m]}(k+1)} P^{[m]}(0) = \beta I;
 \end{aligned} \right. \quad (19)$$

- в последовательном режиме (онлайн)

$$\left\{ \begin{aligned}
 w^{[m]}(k+1) &= w^{[m]}(k) + (r^{[m]}(k+1))^{-1} (y(k+1) - \\
 &\quad - w^{[m]T}(k)\mu^{[m]}(k+1))\mu^{[m]}(k+1), \quad (20) \\
 r^{[m]}(k+1) &= \alpha r^{[m]}(k) + \|\mu^{[m]}(k+1)\|, \quad 0 \leq \alpha \leq 1.
 \end{aligned} \right.$$

Таким образом, предложенная архитектура сети CNFNN значительно превосходит обычную архитектуру нейросети в скорости обучения и может обучаться как в пакетном режиме, так и в последовательном(онлайн) режиме. Лингвистическая интерпретация полученных результатов значительно расширяет функциональные средства каскадной нео-фаззи нейронной сети.

ПРИМЕНЕНИЕ МЕТОДА МГУА ДЛЯ СИНТЕЗА ОПТИМАЛЬНОЙ СТРУКТУРЫ НЕО-ФАЗЗИ КАСКАДНОЙ НЕЙРОННОЙ СЕТИ

Важной задачей, которую приходится решать при использовании каскадных нейронных нео-фаззи сетей является задача выбора числа каскадов и синтеза структуры такой сети. Такую задачу целесообразно решать с использованием метода эвристической самоорганизации МГУА [3].

Рассмотрим этот метод и приведем соответствующие результаты экспериментальных исследований.

Алгоритм МГУА для синтеза структуры каскадной нео-фаззи сети

Если использовать нео-фаззи нейроны с двумя входами, то можно применить метод МГУА для синтеза оптимальной структуры нео-фаззи нейронной сети. Основная идея алгоритма МГУА состоит в том, что идет последовательное наращивание слоев нейронной сети, пока внешний критерий не начнет возрастать.

Описание алгоритма синтеза.

1. Формируем пары из выходов нейронов текущего слоя (на первой итерации мы используем множество входных сигналов). Каждая пара подается на входы нео-фаззи нейрона.

2. Используя обучающую выборку, настраиваем весовые коэффициенты связей каждого нео-фаззи нейрона.

3. Используя проверочную выборку, вычисляем значение внешнего критерия регулярности для каждого нео-фаззи нейрона

$$\varepsilon_p^{[s]} = \frac{1}{N_{np}} \sum_{i=1}^{N_{np}} (y(i) - \hat{y}_p^{[s]}(i))^2, \quad (21)$$

где N_{np} — размер проверочной выборки, а s -номер слоя, $\hat{y}_p^{[s]}(i)$ — выходной сигнал нейрона p , s -го слоя на i -й входной сигнал.

4. Найдем минимальное значение внешнего критерия для всех нейронов текущего слоя

$$\varepsilon^{[s]} = \min_p \varepsilon_p^{[s]}. \quad (22)$$

Проверка условия

$$\varepsilon^{[s]} > \varepsilon^{[i-1]}, \quad (23)$$

где $\varepsilon^{[s]}$, $\varepsilon^{[i-1]}$ — значение критериев у лучших нейронов s -го и $(s-1)$ -го слоев соответственно.

Если условие выполняется, то конец синтеза структуры возвратиться на предыдущий слой, найти наилучший нейрон с минимальным значением критерия и перейти на шаг 5, иначе выбрать F лучших нейронов в соответствии с критерием (22), и перейти на шаг 1 для конструирования следующего слоя нейронов.

5. Определить конечную структуру сети. Для этого двигаемся в обратном направлении от наилучшего нейрона по его входным связям и, последовательно проходя все слои нейронов, сохраняем в конечной структуре сети только те нейроны, которые используются на следующем слое.

6. После окончания работы алгоритма МГУА будет синтезирована оптимальная структура сети. Как нетрудно заметить, мы получаем не только оптимальную структуру сети, а и обученную нейронную сеть, которая готова обрабатывать новые данные. Одним из важных преимуществ использования МГУА для синтеза архитектуры каскадной сети является его способность использовать очень быстрые обучающие процедуры для весов нео-фаззи нейронов, поскольку обучение происходит по слоям (слой за слоем).

ЭКСПЕРИМЕНТАЛЬНЫЕ ИССЛЕДОВАНИЯ НЕО-ФАЗЗИ НЕЙРОННОЙ СЕТИ В ЗАДАЧАХ ПРОГНОЗИРОВАНИЯ

Для исследования эффективности алгоритмов обучения нейронной сети с различными алгоритмами обучения была разработана соответствующая программа и проведены ее исследования в задачах прогнозирования индекса РТС на рынке ценных бумаг РТС НП «Торговая система» [4]. Ниже приводятся результаты некоторых экспериментов.

Анализ зависимости результатов градиентного метода от числа каскадов

Для градиентного метода построим зависимость точности от количества каскадов. Будем использовать выборку со значениями индекса РТС.

Описание эксперимента. Метод — градиентный, число лингвистических значений — 3; количество входов — 3; количество каскадов — 2...8. Размер обучающей выборки — 73 значения.

Результаты приведены в табл. 1 и на рис. 4.

Таблица 1. Критерии прогнозирования зависимости от числа каскадов

MSE	MAPE	Число каскадов
21387,5	8,86	2
19230,71	8,02	3
15259,73	7,27	4
11168,92	5,67	5
11661,22	5,79	6
12057,06	6,12	7
7174,436	4,36	8

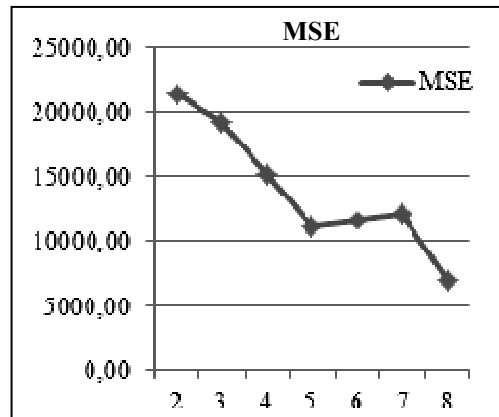


Рис. 4. Зависимость СКО от числа каскадов

Из полученных значений и построенной зависимости следует, что с ростом количества каскадов значения ошибки прогноза для градиентного метода обучения немонокотонно уменьшается. Минимум достигается при числе каскадов равном 8.

Анализ зависимости результатов градиентного метода от количества значений лингвистических переменных

Для градиентного метода построим зависимость точности от количества лингвистических значений. Будем использовать ту же выборку индекса РТС.

Описание эксперимента. Количество лингвистических значений — 2...8; количество входов — 4; количество каскадов — 4; размер выборки — 73 значения. Соответствующие результаты приведены в табл. 2 и на рис. 5.

Таблица 2. Значение критериев качества от числа значений лингвистических переменных

MSE	MAPE	Число значений лингвистических переменных
13352,9	6,83	2
17095,93	7,11	3
16772,39	7,22	4
10903,83	5,38	5
9556,977	5,27	6
7110,85	4,22	7
9152,762	4,87	8




Рис. 5. Зависимость СКО от числа значений лингвистических переменных

Из полученных значений и построенной зависимости следует, что с ростом количества лингвистических значений СКО постепенно монотонно уменьшается, достигает своего минимума, а потом начинает возрастать.

Анализ зависимости результатов градиентного метода от количества входов

Для градиентного метода построим зависимость точности от количества входов. Будем использовать ту же самую выборку со значениями РТС.

Количество лингвистических значений — 2; количество входов — 2...8; количество каскадов — 2; размер обучающей выборки — 73 значения.

Результаты приводятся в табл. 3 и на рис. 6.

Таблица 3. Значения критериев качества от числа входов

MSE	MAPE	Число входов
25015,88	9,44	2
21240,41	8,49	3
20252,93	7,70	4
18272,35	7,87	5
15827,28	7,03	6
18981,93	7,72	7
15359,55	6,95	8




Рис. 6. Зависимость СКО от числа входов

Из полученных значений и построенной зависимости следует, что с ростом количества входов значения погрешности прогноза сначала уменьшаются, достигают локального минимума, потом происходит выброс и значения снова уменьшаются. Наблюдается 2 локальных минимума в точках 6 и 8.

Анализ зависимости результатов метода Уидроу-Хоффа от количества каскадов

Далее были проведены экспериментальные исследования метода обучения Уидроу-Хоффа. В первой серии экспериментов проводилось исследование зависимости точности прогноза от числа каскадов.

Количество лингвистических значений — 4; количество входов — 4; количество каскадов — 2...8; размер учебной выборки — 73 значения. Соответствующие результаты приведены в табл. 4 и на рис. 7.

Из полученных значений и построенной зависимости следует, что с ростом количества каскадов точность прогноза уменьшается, достигает минимума, а потом начинает увеличиваться.

Таблица 4. Значение критериев качества от числа каскадов

MSE	MAPE	Число каскадов
20776,75	8,13	2
15227,94	6,38	3
15080,51	6,75	4
12308,18	6,09	5
8721,465	5,11	6
11596,16	5,63	7
14428,51	6,50	8




Рис. 7. Зависимость СКО от числа каскадов

Анализ зависимости результатов метода Уидроу-Хоффа от количества значений лингвистических переменных

Для метода Уидроу-Хоффа была исследована зависимость точности от числа лингвистических значений переменных. Используем ту же самую выборку со значениями индекса РТС.

Количество лингвистических значений — 2...8; количество входов — 4; количество каскадов — 4; размер обучающей выборки — 73 значения.

Результаты приведены в табл. 5 и на рис. 8.

Таблица 5. Значение критериев от числа значений лингвистических переменных

MSE	MAPE	Число лингвистических значений
32925,8	6,83	2
26439,58	7,11	3
25351,85	7,22	4
21506,81	5,38	5
22353,98	5,27	6
19999,69	4,22	7
20049,69	4,87	8

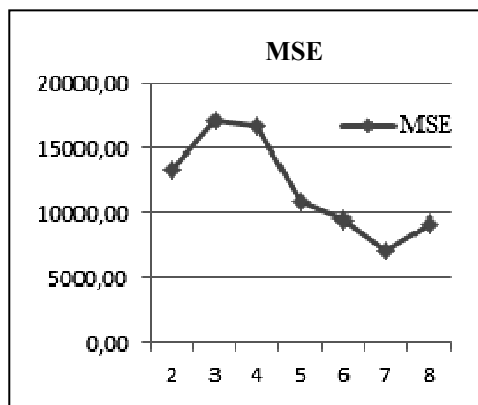


Рис. 8. Зависимость СКО от числа лингвистических значений переменных

Из полученных значений и построенной зависимости следует, что с ростом числа лингвистических значений переменных значения точности постепенно немонотонно уменьшается, достигает своего минимума, а потом возрастает.

Анализ зависимости результатов метода Уидроу-Хоффа от количества входов

Для метода Уидроу-Хоффа была получена зависимость точности от количества входов. Была использована та же самая выборка со значениями индекса РТС.

Количество лингвистических значений — 4; количество входов — 2...8; количество каскадов — 4; размер обучающей выборки — 73 значения.

Результаты приведены в табл. 6 и на рис. 9.

В целом, сравнивая результаты приведенных экспериментов можно сделать такие выводы:

- Для каждого класса прогнозируемых финансовых процессов имеется свое значение оптимального числа каскадов. При дальнейшем их увеличении ошибка прогноза либо перестает изменяться, либо начинает расти.
- С ростом числа значений лингвистических переменных ошибка прогноза сначала падает, достигает минимума, а затем начинает возрастать. Такая же зависимость прослеживается и для числа входов модели.
- В пределе градиентный метод обучения имеет несколько более высокую точность прогноза, в сравнении с методом Уидроу-Хоффа, однако имеет значительно меньшую скорость сходимости процесса обучения, что подтверждает теоретические положения. Поэтому метод Уидроу-Хоффа более предпочтителен для прогнозирования в режиме онлайн.

Таблица 6. Значение критериев от числа входов

MSE	MAPE	Число входов
19781,98	7,84	2
15513,84	6,78	3
15080,51	6,75	4
12736,06	5,93	5
10490,04	5,18	6
10459,34	5,14	7
13044,13	5,87	8

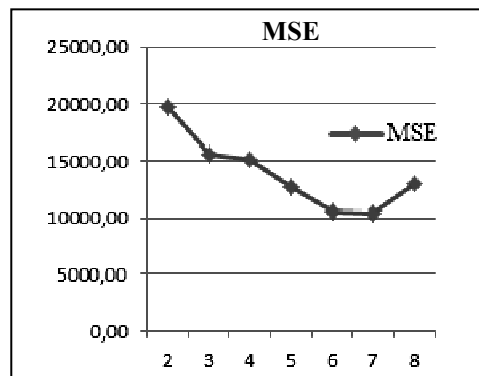


Рис. 9. Зависимость СКО от числа входов

ВЫВОДЫ

В работе дано описание каскадной нео-фаззи нейронной сети. Рассмотрены алгоритмы ее обучения: градиентный и Уидроу-Хоффа.

Проведены экспериментальные исследования алгоритмов обучения каскадной сети в задачах прогнозирования индекса РТС на рынке ценных бумаг. Исследования показали, что каскадная нео-фаззи нейронная сеть вполне конкурентно способна и ее целесообразно использовать для прогнозирования финансовых показателей на рынках ценных бумаг.

Проведенные исследования показали, что каждый алгоритм имеет свои сильные и слабые стороны. Градиентный метод может давать более точные прогнозы (для 42-х вариантов комбинаций значений количества каскадов, лингвистических значений и входов среднее значение среднеквадратичной погрешности для градиентного метода составляло 13771, а для алгоритма Уидроу-Хоффа — 15472), но при этом, скорость его работы достаточно большая.

Алгоритм Уидроу-Хоффа, наоборот, дает прогноз за очень короткое время, но имеет довольно большие отклонения от реальных значений. Наилучший результат получен при 6 каскадах, 7 лингвистических значениях, 7 входах. При этом $MSE = 8721,4$ и $MAPE = 5,11$; $R2 = 0,95$.

В целом, каскадная нео-фаззи нейронная сеть является хорошим инструментом для прогнозирования финансовых процессов на фондовых рынках в условиях неопределенности и неполноты информации. При этом ее прогноз значительно точнее в сравнении с классическими нечеткими нейронными сетями ANFIS и TSK, а также ННС с выводом Мамдани.

Была исследована зависимость результатов точности прогноза градиентного алгоритма и алгоритма Уидроу-Хоффа от числа каскадов, числа лингвистических значений и количества входов. Результаты этих экспериментов показали, что существуют оптимальные значения этих параметров.

ЛИТЕРАТУРА

1. Бодянский Е. В. Каскадная эволюционная нейронная сеть с нео-фаззи нейронами в качестве. — http://www.nbuu.gov.ua/portal/natural/Vejpt/2011_4_3/2011_4_3/55-58.pdf.
2. Згуровский М.З., Зайченко Ю.П. Основы вычислительного интеллекта. — К.: Наукова думка, 2013. — 406 с.
3. Нео-фаззи нейронная сеть в анализе и прогнозировании фондового рынка. — <http://sait.kpi.ua/eproc/2011/2/2034.pdf>.
4. Индекс цен РТС. — <http://www.rts.ru/ru/index/stat/dailyhistory.html?code=RTSI>.

Поступила 25.02.2014