

Krassimir Markov, Vitalii Velychko, Oleksy Voloshin  
(editors)

**Information Models  
of  
Knowledge**

**ITHEA<sup>®</sup>  
KIEV – SOFIA  
2010**

**Krassimir Markov, Vitalii Velychko, Oleksy Voloshin (ed.)**

**Information Models of Knowledge**

ITHEA®

Kiev, Ukraine – Sofia, Bulgaria, 2010

ISBN 978-954-16-0048-1

First edition

Recommended for publication by The Scientific Council of the Institute of Information Theories and Applications FOI ITHEA  
ITHEA IBS ISC: 19.

This book maintains articles on actual problems of research and application of information technologies, especially the new approaches, models, algorithms and methods for information modeling of knowledge in: Intelligence metasynthesis and knowledge processing in intelligent systems; Formalisms and methods of knowledge representation; Connectionism and neural nets; System analysis and synthesis; Modelling of the complex artificial systems; Image Processing and Computer Vision; Computer virtual reality; Virtual laboratories for computer-aided design; Decision support systems; Information models of knowledge of and for education; Open social info-educational platforms; Web-based educational information systems; Semantic Web Technologies; Mathematical foundations for information modeling of knowledge; Discrete mathematics; Mathematical methods for research of complex systems.

It is represented that book articles will be interesting for experts in the field of information technologies as well as for practical users.

General Sponsor: Consortium FOI Bulgaria ([www.foibg.com](http://www.foibg.com)).

Printed in Ukraine

**Copyright © 2010 All rights reserved**

© 2010 ITHEA® – Publisher; Sofia, 1000, P.O.B. 775, Bulgaria. [www.ithea.org](http://www.ithea.org) ; e-mail: [info@foibg.com](mailto:info@foibg.com)

© 2010 Krassimir Markov, Vitalii Velychko, Oleksy Voloshin – Editors

© 2010 Ina Markova – Technical editor

© 2010 For all authors in the book.

® ITHEA is a registered trade mark of FOI-COMMERCE Co., Bulgaria

**ISBN 978-954-16-0048-1**

C/o Jusautor, Sofia, 2010

## ИССЛЕДОВАНИЕ МОДИФИКАЦИИ FOTSK НЕЧЕТКОЙ НЕЙРОННОЙ СЕТИ TSK В ЗАДАЧАХ ПРОГНОЗИРОВАНИЯ

Юлия Проскурня, Богдан Гривко

**Аннотация:** Существуют ситуации, когда нужно получить не только точечный прогноз, но еще и доверительный интервал к нему. Примером такой ситуации может выступить задача составления нечеткого инвестиционного портфеля, входными параметрами которой, в том числе, являются нижняя граница доходности, наиболее ожидаемое значение доходности и верхняя граница доходности ценных бумаг. Кроме того, доверительный интервал позволяет оценить точность прогноза.

В данной статье предложена модификация нечеткой нейронной сети TSK (Takagi, Sugeno и Kang'a), получившая название FOTSK (Fuzzy Output TSK), позволяющая получать на выходе нечеткое число вида: {нижняя граница; наиболее ожидаемое значение; верхняя граница}. Изменения затронули гибридный алгоритм обучения нечеткой нейронной сети TSK, а именно, его первый этап – расчет линейных параметров. В нечеткой нейронной сети FOTSK линейные параметры находятся из решения задачи линейного программирования, что, вдобавок, лишает нейронную сеть проблемы плохой обусловленности матрицы.

Также, авторами предложен алгоритм поиска оптимальной структуры нечеткой нейронной сети TSK (оптимального количества используемых нейронной сетью правил), который позволяет избежать перерегулирования.

В экспериментальных исследованиях было рассмотрено применение предложенной модификации FOTSK в задачах прогнозирования и произведено ее сравнение с оригинальной нечеткой нейронной сетью TSK, а также с НМГУА (Нечеткий Метод Индуктивного Моделирования). Исследования проводились в задачах прогнозирования курсов акций компаний IBM, Google, Apple, Coca-Cola и McDonald's на 28.05.2010. Выборки данных были сформированы по курсам акций вышеупомянутых компаний, взятых за период с 27.05.2009 по 27.05.2010.

**Ключевые слова:** нечеткие нейронные сети, прогнозирование, FOTSK, TSK.

**ACM Classification Keywords:** I.2.6 Learning – Connectionism and neural nets.

**Раздел конференции:** Neural and Growing Networks.

---

### Введение

Среди множества существующих методов прогнозирования особое место занимают нечеткие нейронные сети (ННС), а также методы индуктивного моделирования (МИМ), которые отличаются высоким качеством прогнозов и позволяют решать задачи принятия решений в условиях неопределенности.

Ярким представителем ННС и МИМ, соответственно, являются ННС TSK и нечеткий метод группового учета аргументов (НМГУА).

Однако выходом ННС TSK, в отличие от НМГУА, является четкое число (точечный прогноз), а в ряде случаев (напр., формирование нечеткого портфеля инвестора) необходимо иметь доверительный интервал, который характеризует точность прогноза. Для решения данной проблемы была разработана уникальная модификация ННС TSK с выходом модели в виде нечеткого числа, которая получила название FOTSK (Fuzzy Output TSK).

Целью данной статьи является рассмотрение и анализ модификации FOTSK ННС TSK в задачах прогнозирования, а также, сравнение результатов прогнозирования посредством данной модификации с результатами прогнозирования ННС TSK и НМГУА.

### Основные принципы и идея нечеткой нейронной сети TSK

Согласно [Зайченко, 2008] ННС TSK (Takagi, Sugeno и Kang'a) является обобщением нейронной сети ANFIS. Обобщенную схему вывода в модели TSK при использовании  $M$  правил и  $N$  переменных  $x_j$  можно представить в следующем виде:

$$R_1: \text{если } x_1 \in A_1^{(1)}; x_2 \in A_2^{(1)}, \dots, x_n \in A_n^{(1)} \text{ то } y_1 = p_{10} + \sum_{j=1}^N p_{1j} x_j;$$

$$R_M: \text{если } x_1 \in A_1^{(M)}; x_2 \in A_2^{(M)}, \dots, x_n \in A_n^{(M)} \text{ то } y_M = p_{M0} + \sum_{j=1}^N p_{Mj} x_j;$$

где  $A_j^{(k)}$  – значение лингвистической переменной  $x_j$  для правила  $R_k$  с функцией принадлежности (ФП)

$$\mu_A^{(k)}(x_j) = \frac{1}{1 + \left( \frac{x_j - c_j^{(k)}}{\sigma_j^{(k)}} \right)^{2b_j^{(k)}}} \quad (1)$$

$$i = \overline{1, N}; k = \overline{1, M}.$$

В нечеткой сети TSK пересечение условий правила  $R_k$  определяется ФП в форме произведения, то есть

$$\mu_A^{(k)}(x) = \prod_{j=1}^N \left[ \frac{1}{1 + \left( \frac{x_j - c_j^{(k)}}{\sigma_j^{(k)}} \right)^{2b_j^{(k)}}} \right] \quad (2)$$

При  $M$  правилах вывода композиция выходных результатов сети определяется по следующей формуле:

$$y(x) = \frac{\sum_{k=1}^M w_k y_k(x)}{\sum_{k=1}^M w_k} \quad (3)$$

где  $y_k(x) = p_{k0} + \sum_{j=1}^N p_{kj} x_j$ . Присутствующие в этом выражении веса  $w_k$  интерпретируются как степень

выполнения условий правила:  $w_k = \mu_A^{(k)}(x)$ , которые задаются формулой (2).

Нечёткая сеть TSK, которая реализует вывод (3), задается многослойной структурой сети, представленной на рис. 1. В такой сети выделяют 5 слоев.

1. Первый слой выполняет раздельную фаззификацию каждой переменной  $x_j, i = 1, 2, \dots, N$ , определяя для каждого  $k$ -го правила вывода значения функций принадлежности  $\mu_A^{(k)}(x_j)$ , соответственно, к функции фаззификации, которая применяется. Этот параметрический слой с параметрами  $c_j^{(k)}, \sigma_j^{(k)}, b_j^{(k)}$ , которые подлежат адаптации в процессе обучения.

2. Второй слой выполняет агрегирование отдельных переменных  $x_j$ , определяя результирующую степень принадлежности  $w_k = \mu_A^{(k)}(x)$  для вектора  $x$  условиям  $k$ -го правила. Это не параметрический слой.




Рис. 1. Структура нечеткой нейронной сети TSK

3. Третий слой представляет собой генератор функций TSK, в котором рассчитывается значение  $y_k(x) = p_{k0} + \sum_{j=1}^N p_{kj} x_j$ . В этом слое происходит также произведение функций  $y_k(x)$  на  $w_k$ , сформированных на предыдущем слое. Это параметрический слой, в котором адаптации подлежат линейные параметры (веса)  $p_{k0}, p_{kj}$  для  $j = \overline{1, N}, k = \overline{1, M}$ , которые определяют функции следствий правил.
4. Четвертый слой составляют 2 нейрона-сумматора, один из которых рассчитывает взвешенную сумму сигналов  $y_k(x)$ , а второй определяет сумму весов  $\sum_{k=1}^M w_k$ .
5. Последний, пятый слой, состоит из единого выходного нейрона. В нем веса поддаются нормализации и вычисляется выходной сигнал  $y(x)$  соответствующий выражению:

$$y(x) = \frac{f_1}{f_2} = \frac{\sum_{k=1}^M w_k y_k(x)}{\sum_{k=1}^M w_k} \quad (4)$$

Это тоже не параметрический слой.

Из приведенного описания следует, что нечеткая нейронная сеть TSK содержит только два параметрических слоя (первый и третий), параметры которых уточняются в процессе обучения. Параметры первого слоя  $\{c_j^{(k)}, \sigma_j^{(k)}, b_j^{(k)}\}$  будем называть нелинейными, а параметры третьего слоя  $\{p_{kj}\}$  – линейными весами.

Общее выражение для функциональной зависимости (4) для сети TSK задается так:

$$y(x) = \frac{1}{\sum_{k=1}^M \sum_{j=1}^N \mu_A^{(k)}(x_j)} \sum_{k=1}^M \left( p_{k0} + \sum_{j=1}^N p_{kj} x_j \right) \prod_{j=1}^N \mu_A^{(k)}(x_j) \quad (5)$$

Если принять, что в конкретный момент времени параметры условий фиксированы, то функция  $y(x)$  является линейной относительно переменной  $x_j$ .

При наличии  $N$  входных переменных каждое правило  $R_k$  формирует  $(N+1)$  переменную  $p_j^{(k)}$  линейной зависимости  $y_k(x)$ . При  $M$  правилах вывода имеем  $M(N+1)$  линейных параметров сети. В свою очередь каждая функция принадлежности использует три параметра  $(c, \sigma, b)$ , которые подлежат адаптации. При  $M$  правилах вывода получаем  $3MN$  нелинейных параметров. В сумме это дает  $M(4N+1)$  линейных и нелинейных параметров, значения которых должны определяться в процессе обучения. Это очень большая величина. С целью сокращения числа параметров, которые подлежат адаптации, оперируют с меньшим числом независимых ФП. В частности, можно принять, что часть параметров ФП одной переменной  $\mu_A^{(k)}(x_j)$  фиксируется, например,  $\sigma_j^{(k)}$  и/или  $b_j^{(k)}$ .

### Гибридный алгоритм обучения ННС TSK

В [Зайченко, 2008] описан гибридный алгоритм обучения, согласно которому параметры, которые подлежат адаптации, разделяют на две группы. Первая из них состоит из линейных параметров  $p_{kj}$  третьего слоя, а вторая группа – из параметров нелинейной ФП первого слоя. Уточнение параметров проводится в два этапа.

На первом этапе при фиксации отдельных значений параметров ФП (в первом цикле – это значения, которые получены путем инициализации), решая систему линейных уравнений, рассчитывая линейные параметры  $p_{kj}$  полинома TSK. При известных значениях ФП зависимость для выхода можно представить в виде линейной формы относительно параметров  $p_{kj}$

$$y_k(x) = \sum_{k=1}^M w'_k \left( p_{k0} + \sum_{j=1}^N p_{kj} x_j \right) \quad (6)$$

где

$$w'_k = \frac{\prod_{j=1}^N \mu_A^{(k)}(x_j)}{\sum_{r=1}^M \prod_{j=1}^N \mu_A^{(r)}(x_j)}, k = \overline{1, M}. \quad (7)$$

При размерности обучающей выборки  $L(x^{(l)}, d^{(l)})$ ,  $(l=1, 2, \dots, L)$  и замене выходного сигнала сети ожидаемым значением  $d^{(l)}$  получаем систему из  $L$  линейных уравнений вида:

$$\begin{bmatrix} w'_{11} & w'_{11}x_1^{(1)} & w'_{11}x_N^{(1)} & w'_{1M} & w'_{1M}x_1^{(1)} & w'_{1M}x_N^{(1)} \\ w'_{21} & w'_{21}x_1^{(2)} & w'_{21}x_N^{(2)} & w'_{2M} & w'_{2M}x_1^{(2)} & w'_{2M}x_N^{(2)} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ w'_{L1} & w'_{L1}x_1^{(L)} & w'_{L1}x_N^{(L)} & w'_{LM} & w'_{LM}x_1^{(L)} & w'_{LM}x_N^{(L)} \end{bmatrix} \times \begin{bmatrix} p_{10} \\ p_{11} \\ \dots \\ p_{1N} \\ \dots \\ p_{M0} \\ p_{M1} \\ \dots \\ p_{MN} \end{bmatrix} = \begin{bmatrix} d^{(1)} \\ d^{(2)} \\ \dots \\ d^{(L)} \end{bmatrix} \quad (8)$$

где  $w'_{\ell i}$  означает уровень активации (вес) условия  $i$ -го правила при представлении  $\ell$ -го входного вектора  $x^\ell$ . Это выражение можно записать в матричном виде:  $Ap = d$ .

Размерность матрицы  $A$  равна  $L(N+1)M$ . При этом количество строк  $L$  обычно бывает значительно большим, чем количество столбцов  $(N+1)M$ . Решение этой системы уравнений можно получить как обычным методом, так и за один шаг, используя псевдоинверсную матрицу  $A$ :  $p = A^+d$ , где  $A^+$  - псевдоинверсная матрица.

На втором этапе после фиксации линейных параметров  $p_{kj}$  рассчитываются фактические выходные сигналы  $y^{(\ell)}$ ,  $\ell = 1, 2, \dots, L$ , для чего используется линейная зависимость  $y^{(L)} = Ap$ .

После этого рассчитывается вектор ошибки  $\varepsilon = (y - d)$  и критерий

$$E = \frac{1}{2} \sum_{\ell=1}^L (y(x^{(\ell)}) - d^{(\ell)})^2 \quad (9)$$

Сигналы ошибок направляются через сеть в обратном направлении соответственно методу Back propagation, до первого слоя, где могут быть рассчитаны компоненты вектора градиента целевой функции относительно параметров  $c_j^{(k)}, \sigma_j^{(k)}, b_j^{(k)}$ . После вычисления вектора градиента делается шаг спуска по градиентному методу. Соответствующие формулы обучения (для самого простого метода быстрого спуска) принимают вид:

$$c_j^{(k)}(n+1) = c_j^{(k)}(n) - \eta_c \frac{\partial E(n)}{\partial c_j^{(k)}} \quad (10)$$

$$\sigma_j^{(k)}(n+1) = \sigma_j^{(k)}(n) - \eta_\sigma \frac{\partial E(n)}{\partial \sigma_j^{(k)}} \quad (11)$$

$$b_j^{(k)}(n+1) = b_j^{(k)}(n) - \eta_b \frac{\partial E(n)}{\partial b_j^{(k)}} \quad (12)$$

где  $n$  – номер итерации.

После уточнения нелинейных параметров снова запускается процесс адаптации линейных параметров функции TSK (первый этап) и нелинейных параметров (второй этап). Этот цикл повторяется до тех пор, пока не стабилизируются все параметры процесса.

Формулы (10)-(12) требуют расчета градиента целевой функции относительно параметров ФП. Окончательный вид этих формул зависит от вида ФП. Соответствующие формулы градиента целевой функции для одной пары данных  $(x, d)$  принимают вид:

$$\frac{\partial E}{\partial c_j^{(k)}} = (y(x) - d) \sum_{r=1}^M \left( p_{r0} + \sum_{j=1}^N p_{rj} x_j \right) \cdot \frac{\partial w'_r}{\partial c_j^{(k)}} \quad (14)$$

$$\frac{\partial E}{\partial \sigma_j^{(k)}} = (y(x) - d) \sum_{r=1}^M \left( p_{r0} + \sum_{j=1}^N p_{rj} x_j \right) \cdot \frac{\partial w'_r}{\partial \sigma_j^{(k)}} \quad (15)$$

$$\frac{\partial E}{\partial b_j^{(k)}} = (y(x) - d) \sum_{r=1}^M \left( p_{r0} + \sum_{j=1}^N p_{rj} x_j \right) \cdot \frac{\partial w'_r}{\partial b_j^{(k)}} \quad (16)$$

### Поиск оптимальной структуры ННС TSK

В ННС TSK, как и в любой другой НС, используют некоторую выборку данных для обучения и получения прогноза. Но из теоремы неполноты Геделя следует, что выборка всегда неполна. Способом преодоления неполноты выборки данных является принцип внешнего дополнения. В качестве внешнего дополнения используется проверочная выборка, точки которой не участвовали в обучении НС.

Основываясь на сказанном выше, авторами предлагается следующий способ синтезирования ННС TSK оптимальной структуры (т.е. поиск оптимального количества используемых в НС правил):

1. Вся выборка делится на обучающую и проверочную выборки:  $N_{выб} = N_{обуч} + N_{пров}$ .
2. На обучающей выборке  $N_{обуч}$  синтезируется нейронная сеть.
3. На проверочной выборке  $N_{пров}$  по определенному критерию отбирается НС с наилучшей структурой.

### Модификация FOTSK

Модификация ННС TSK под названием FOTSK (Fuzzy Output TSK) разработана авторами для получения не только точечных прогнозов, но и доверительного интервала, который характеризует точность прогноза. ННС FOTSK имеет ту же структуру, что и ННС TSK, только на третьем слое в качестве линейных параметров  $p_{k0}, p_{kj}$  для  $j = \overline{1, N}, k = \overline{1, M}$ , которые определяют функции следствий правил, выступают нечеткие числа треугольного вида, описываемые тройкой параметров  $(\alpha, c_1, c_2)$ , где  $\alpha$  – центр интервала;  $c_1$  – расстояние от центра до нижней границы;  $c_2$  – расстояние от центра до верхней границы;  $c_1, c_2 \geq 0$ .

В гибридном алгоритме обучения НС изменения затронули его первый этап – расчет линейных параметров. Так как  $p_{kj}$  нечеткое треугольное число, то (8) теперь будет иметь следующий вид:



$$\begin{bmatrix} w'_{11} & w'_{11}x_1^{(1)} & w'_{11}x_N^{(1)} & w'_{1M} & w'_{1M}x_1^{(1)} & w'_{1M}x_N^{(1)} \\ w'_{21} & w'_{21}x_1^{(2)} & w'_{21}x_N^{(2)} & w'_{2M} & w'_{2M}x_1^{(2)} & w'_{2M}x_N^{(2)} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ w'_{L1} & w'_{L1}x_1^{(L)} & w'_{L1}x_N^{(L)} & w'_{LM} & w'_{LM}x_1^{(L)} & w'_{LM}x_N^{(L)} \end{bmatrix} \times \begin{bmatrix} \alpha_{10} \\ \alpha_{11} \\ \dots \\ \alpha_{1N} \\ \dots \\ \alpha_{M0} \\ \alpha_{M1} \\ \dots \\ \alpha_{MN} \end{bmatrix} = \begin{bmatrix} d^{(1)} \\ d^{(2)} \\ \dots \\ d^{(L)} \end{bmatrix} \quad (21)$$

или в матричном виде:  $A\alpha = d$ .

Чтобы построенная модель была адекватной, необходимо, чтобы действительное значение выходного сигнала  $d$  принадлежало интервалу неопределенности. Это можно записать следующими неравенствами:

$$\begin{cases} A\alpha - |A|c_1 \leq d \\ A\alpha + |A|c_2 \geq d \end{cases} \quad (22)$$

Для нахождения вектора линейных параметров  $p$  необходимо найти такие значения  $(\alpha, c_1, c_2)$ , которые бы удовлетворяли условиям (22),  $c_1, c_2 \geq 0$ , а суммарная ширина оценочного интервала была бы минимальна. Данные требования сводятся к следующей задаче линейного программирования:

$$\min \left( \text{sum}([|A| \quad |A|]) \times \begin{bmatrix} c_1 \\ c_2 \end{bmatrix} \right) \quad (23)$$

при условиях:

$$\begin{bmatrix} A & -|A| & A_0 \\ -A & A_0 & -|A| \end{bmatrix} \times \begin{bmatrix} \alpha \\ c_1 \\ c_2 \end{bmatrix} \leq \begin{bmatrix} d \\ -d \end{bmatrix} \quad (24)$$

$$c_1, c_2 \geq 0 \quad (25)$$

где  $A_0$  – матрица идентичной размерности с матрицей  $A$ , состоящая из нулевых элементов; sum – оператор переводящий матрицу в вектор, состоящий из сумм всех элементов строк каждого столбца исходной матрицы.

### Экспериментальные исследования FOTSK в задачах прогнозирования

Для сравнительного анализа исследуемого метода прогнозирования с ННС TSK и с НМГУА были использованы данные с сайта Google Finance по курсу акций компаний IBM, Google, Apple, Coca-Cola и McDonald's, взятые за период с 27.05.2009 по 27.05.2010. Обучающая выборка бралась в размере 0.7 от общей выборки. Прогнозирование производилось на одну эпоху вперед по данным за текущую эпоху.

Полученные прогнозные значения доходностей акций в процентах на 28.05.2010 приведены в табл. 1.

Таблица 1. Результаты применения ННС FOTSK, ННС TSK и НМГУА для решения задач прогнозирования курсов акций.

Метод	Нижняя граница	Центр	Верхняя граница	Реальное значение	Отклонение	СКО внутр.	СКО внешн.	Сложность модели
<b>IBM:</b>								
FOTSK	-3.8064	-1.0902	1.6274	-0.8941	0.1961	1.5100	1.8461	2
TSK	—	-0.2766	—		0.6175	1.2745	1.4415	2
НМГУА	-4.7376	-1.5988	1.4976		0.7047	1.6457	2.1105	1
<b>GOOG:</b>								
FOTSK	-2.3696	0.8376	4.0192	-0.9848	1.8224	6.7583	10.4567	2
TSK	—	0.3489	—		1.3337	6.1955	10.1617	2
НМГУА	-3.2555	0.4508	4.1554		1.4356	7.3152	10.3253	1
<b>AAPL:</b>								
FOTSK	-6.3546	-2.9473	0.4882	1.3933	4.3406	3.2696	6.6176	3
TSK	—	-0.9410	—		2.3344	2.8006	5.0065	3
НМГУА	-0.4310	-0.2806	11.1851		1.6739	3.2572	8.6604	1
<b>KO:</b>								
FOTSK	-1.3660	0.9485	3.2631	0.3318	0.6166	0.6840	0.7755	2
TSK	—	0.3098	—		0.0221	0.5190	0.5889	2
НМГУА	-2.4786	0.1325	2.3320		0.1993	0.5917	0.6981	2
<b>MCD:</b>								
FOTSK	-2.8613	0.3110	3.3783	-0.4911	0.8021	0.9776	1.0751	2
TSK	—	-0.7862	—		0.2951	0.5719	0.8129	3
НМГУА	-1.3899	1.5207	4.4363		2.0118	0.8073	1.2498	3
<b>Суммарно:</b>								
FOTSK	Ширина оценочного интервала: 29.5342				7.7779	13.1994	20.771	
TSK	—				4.6027	11.3615	18.0114	
НМГУА	Ширина оценочного интервала: 35.8990				6.0253	13.6170	23.044	

Как видно из табл. 1, и ННС FOTSK, и НМГУА сошлись в направлении движения курсов акций, правда правильными оказались лишь направления для двух видов ЦБ – IBM и KO. ННС TSK выдала отличное от ННС FOTSK и НМГУА направление прогноза для акций MCD и оказалась права, в сумме правильно определив направление движения курсов для трех ценных бумаг с пяти.

Внешние СКО ННС FOTSK и НМГУА практически одинаковы (в среднем немного ниже у FOTSK). То же справедливо и по отношению к внутреннему СКО. А вот отклонение от реального значения курса у НМГУА получилось меньше. Лидером по трем показателям оказалась ННС TSK, с большим отрывом обогнав конкурентов по отклонению от реального значения курса акций. Но стоит отметить, что все пять точечных прогнозов, сделанных на ННС TSK, попали в соответствующие доверительные интервалы построенные ННС FOTSK и НМГУА.

Ширина доверительного интервала у ННС FOTSK на 17.7 % меньше, чем у НМГУА.

Наибольшую ожидаемую доходность ННС FOTSK отдала акциям компании Coca-Cola и при этом правильно определила направление. НМГУА спрогнозировал, что наиболее доходными являются акции компании McDonald's, но направление определил не правильно, а значит, в случае инвестирования в данный вид ЦБ инвестор понесет большие потери. ННС TSK также прогадала, спрогнозировав наибольшую доходность акциям компании Google, которые в действительности показали отрицательное значение прироста доходности, когда наступил момент, на который производился прогноз (28.05.2010).

---

### Заключение

Авторами была разработана ННС FOTSK, дающая не только точечный прогноз, но еще и оценочный интервал к нему. Также, был предложен простой, но эффективный алгоритм, позволяющий определить оптимальное количество используемых правил в ННС TSK/FOTSK для конкретной выборки данных.

С помощью программной реализации ННС FOTSK, ННС TSK и НМГУА были получены прогнозы курсов акций для пяти компаний. По результатам данных экспериментов можно сделать следующие выводы:

1. Представленная модификация хорошо показала себя в решении задач прогнозирования.
2. По величине СКО (как внутреннего, так и внешнего), а также по ширине оценочного интервала ННС FOTSK показала себя лучше НМГУА, но уступила ННС TSK.
3. По суммарному отклонению прогнозных значений от реальных ННС FOTSK уступила и ННС TSK, и НМГУА. Но при этом стоит отметить, что в «акциях-фаворитах» ННС FOTSK, в отличие от ННС TSK и НМГУА, правильно определила направление, что имеет огромное значение при инвестировании.
4. Как показали исследования, большое значение в задачах прогнозирования, особенно курсов ЦБ, играет правильное определение направления. В связи с этим авторы считают, что в дальнейшем при разработке улучшений и модификаций алгоритмов прогнозирования необходимо уделить данному моменту максимальное внимание.
5. При сравнении качества прогнозов от разных методов нужно учитывать не только расхождение с реальными данными, но и то, правильно ли определено направление движения курса акций. Последнее, на взгляд авторов, – приоритетней.

---

### Литература

[Зайченко, 2008] Ю.П. Зайченко. Нечеткие модели и методы в интеллектуальных системах. Учебное пособие для студентов высших учебных заведений. – К.: «Издательский дом «Слово», 2008. – 344с.

---

### Информация об авторах



**Богдан Гривко** – студент 6 курса НТУУ «КПИ», факультет «Институт Прикладного Системного Анализа», 02225, ул. Каштановая, 13, кв. 102, Киев, Украина;

e-mail: bogdan.grivko@gmail.com

Основная область научных исследований: нейронные сети, искусственный интеллект, портфельная теория



**Юлия Проскурня** – студентка 6 курса НТУУ «КПИ», факультет «Институт Прикладного Системного Анализа», 02225, ул. Каштановая, 13, кв. 102, Киев, Украина;

e-mail: julia.proskurnya@gmail.com

Основная область научных исследований: нейронные сети, искусственный интеллект, портфельная теория