

---

---

## ПРОГНОЗИРОВАНИЕ РИСКА БАНКРОТСТВА КОРПОРАЦИЙ В УСЛОВИЯХ НЕОПРЕДЕЛЕННОСТИ С ИСПОЛЬЗОВАНИЕМ НЕЧЕТКИХ НЕЙРОННЫХ СЕТЕЙ

Ови Нафас Агаи аг Гамиш, Юрий Зайченко

**Аннотация:** В статье рассматривается проблема анализа риска банкротства корпораций в условиях неопределенности. Для ее решения предлагается применение каскадных нео-фаззи нейронных сетей. Приводится структура каскадной нео-фаззи нейросети, описаны ее свойства и алгоритмы обучения в пакетном и оперативном режимах. Приводятся результаты экспериментального исследования их применения в задаче прогнозирования риска банкротства предприятий Украины и сравнительный анализ с результатами использования классических методов Альтмана и Давыдовой-Беликова, также нечеткими нейронными сетями Мамдани и Цукамото.

**Ключевые слова:** прогнозирование риска банкротства корпораций, каскадные нео-фаззи нейронные сети, нечеткие нейронные сети Мамдани, Цукамото.

**ACM Classification Keywords:** I.2 Artificial Intelligence; I.5.1 Models; Neural Nets

---

### Введение

Одной из актуальных проблем, связанных со стратегическим менеджментом является анализ финансового состояния и оценка риска банкротства предприятий (корпораций).

Своевременное выявление признаков возможного банкротства позволяет руководству принимать срочные меры по исправлению финансового состояния и снижению риска банкротства.

В течение многих лет классические статистические методы широко использовались для прогнозирования рисков банкротства. Они включают процедуру классификации, которая относит ту или другую компанию к группе потенциальных банкротов или к группе компаний с благоприятным финансовым положением с определенной мерой точности. Применяя эти модели, могут возникать два типа ошибок. Ошибка первого типа возникает тогда, когда фирма-банкрот классифицировалась как фирма с благоприятным финансовым положением. Ошибка второго типа возникает тогда, когда предприятие с нормальным финансовым состоянием классифицируется как потенциальный банкрот. Обе ошибки могут привести к серьезным последствиям и убыткам. Например, если кредитное учреждение откажет компаниям со „здоровой” финансовой ситуацией в предоставлении кредита в связи с допущением ошибки 2-го типа, то это может привести к потерям будущей прибыли этой компанией. Такую ошибку часто называют „коммерческим риском”. И наоборот, если кредитное учреждение примет решение о предоставлении кредита компании, которая является потенциальным банкротом (ошибка 1-го типа), то это может привести к потерям процентов по кредиту, значительной части ссудных средств, и др. Поэтому такую ошибку называют „кредитным риском”.

В настоящее время существует несколько общепризнанных статистических методов и методик оценки риска банкротства. Наиболее известной и широко применяемой является методика профессора Альтмана [Altman, 1968; Altman, 1983]. Вместе с тем, модель Альтмана имеет ряд недостатков, и ее применение для экономики Украины сопряжено с определенными трудностями. Поэтому в последние

годы разрабатываются альтернативные подходы и методы, учитывающие специфику анализа и принятия решений в условиях неопределенности. К их числу относятся аппарат нечетких множеств и нечеткие нейронные сети. В работе [Згуровский & Зайченко, 2013] были исследованы нечеткие нейронные сети с выводом Мамдани и Цукамото, а также нечетко-множественный „матричный” метод [Недосекин & Максимов, 2003; Недосекин, 2003] в задаче прогнозирования риска банкротства корпораций.

Целью настоящей работы является рассмотрение и сравнительный анализ эффективности применения классических методов и нового класса нечетких нейронных сетей – каскадных нео-фаззи нейросетей для прогнозирования риска банкротства предприятий применительно к экономике Украины.

### **Модели оценки риска банкротства на основе многомерного дискриминантного анализа**

К числу наиболее известных и распространенных моделей оценки риска банкротства относится модель профессора Е. Альтмана [Altman, 1983]. Модель Альтмана построена с использованием аппарата мультипликативного дискриминантного анализа (МДА), который позволяет подобрать такие показатели, дисперсия которых между группами была бы максимальной, а внутри группы минимальной. В данном случае классификация проводилась по двум группам компаний, одни из которых позднее обанкротились, а другие, наоборот, смогли выстоять и упрочить свое финансовое положение.

В результате применения МДА была построена модель Альтмана (Z-счет), имеющая следующий вид [Altman, 1968]:

$$Z = 1.2 K_1 + 1.4 K_2 + 3.3 K_3 + 0.6 K_4 + 1.0 K_5 \quad (1)$$

где  $K_1$  = собственный оборотный капитал/ сумма активов;  $K_2$  = нераспределенная прибыль/ сумма активов;  $K_3$  = прибыль до уплаты процентов/ сумма активов;  $K_4$  = рыночная стоимость собственного капитала/ стоимость заемного капитала;  $K_5$  = объем продаж/ сумма активов.

В результате подсчета Z – показателя для конкретного предприятия делается заключение:

если  $Z < 1,81$  – очень высокая вероятность банкротства;

если  $1,81 \leq Z \leq 2,7$  – высокая вероятность банкротства;

если  $2,7 \leq Z \leq 2,99$  – возможно банкротство;

если  $Z \geq 3,0$  – вероятность банкротства крайне мала.

Модель Альтмана дает достаточно точный прогноз вероятности банкротства с временным интервалом 1 – 2 года.

В результате проведения дискриминантного анализа по группе предприятий, которые заявили о своем банкротстве, по финансовым показателям, взятым за год до дефолта, был верно смоделирован этот факт в 31 случае из 33 (94,5%), и в 2 – сделана ошибка (6%). По второй группе предприятий, которые не обанкротились, модель ошибочно спрогнозировала банкротство только в 1 случае (3%), а в оставшихся 32 (97%) была допущена очень низкая вероятность банкротства. Соответствующие результаты приведены в Таблице 1.

Учитывая то, что вышеприведенный z-счет пригодный лишь для больших предприятий, акции которых котируются на бирже, в 1985 году Е. Альтман предложил новую модель, которая позволяет исправить данный недостаток. Ниже приведена формула для определения вероятности прогнозирования банкротства для предприятий, акции которых не представлены на бирже [Altman, 1968]:

$$Z = 0.717 K_1 + 0.847 K_2 + 3.107 K_3 + 0.42 K_4 + 0.995 K_5 \quad (2)$$

где  $K_1 - K_5$  - те же самые показатели, что и в модели (1).

**Таблица 1.** Результаты прогноза по модели Альтмана за год до банкротства

Группа	Количество компаний	Прогноз: принадлежность к 1 группе	Прогноз: принадлежность к 2 группе
Группа 1 (обанкротившиеся компании)	33	31 (94,0%)	2 (6,0%)
Группа 2 (компании не обанкротились)	33	1 (3,0%)	32 (97,0%)

При  $Z < 1.23$  риск банкротства очень большой. Подход Альтмана был многократно использован самим Альтманом и его последователями во многих странах (Великобритания, Франция, Бразилия, Китай, и др.). В последние годы были выполнены исследования по применению модели Альтмана для стран СНГ с переходной экономикой. При этом коэффициенты модели должны быть скорректированы с учетом специфики данного типа экономики. К числу наиболее успешных моделей относится модель Давыдовой-Беликова, разработанная для экономики России [Давыдова & Беликов, 1999].

**Модель Давыдовой – Беликова** имеет вид:

$$R = 8.38 K_1 + K_2 + 0.054 K_3 + 0.63 K_4 \quad (3)$$

где  $K_1$  - отношение оборотного капитала к сумме всех активов;  $K_2$  - отношение чистой прибыли к сумме собственного капитала;  $K_3$  - отношение объема продаж (выручки от реализации) к сумме активов (коэффициент оборачиваемости);  $K_4$  - отношение чистой прибыли к себестоимости.

При  $R < 0$  - вероятность банкротства максимальна (90-100 %);  $0 < R < 0,18$  - вероятность банкротства высока (60-80%);  $0,18 < R < 0,32$  - вероятность банкротства средняя (35-50%);  $0,32 < R < 0,42$  - вероятность банкротства низкая (15-20%);  $R < 0,42$  - вероятность банкротства минимальна.

Слабая сторона модели Альтмана состоит в том, что модель является чисто эмпирической, подогнанной по выборке, и не имеет под собой самостоятельной теоретической базы. Кроме того, приведенные коэффициенты должны определяться для различных отраслей промышленности и будут естественно, различаться.

В экономике Украины модель Альтмана пока не получила широкого применения по следующим причинам:

- 1) Требуется вычисление соответствующих коэффициентов при показателях  $K_i$ ,  $i = 1, 2, 3, 4$ , которые, естественно, отличаются от их значений для зарубежных стран;
- 2) Информация о финансовом состоянии анализируемых предприятий, как правило, недостоверна, руководство ряда предприятий „сознательно” подправляет свои показатели в финансовых отчетах, что делает невозможным найти достоверные оценки коэффициентов в Z- модели.

Поэтому задача оценки вероятности риска банкротства должна решаться в условиях неопределенности, неполноты исходной информации, и для ее решения предлагается использовать адекватный аппарат принятия решений – нечеткие нео-фаззи нейронные сети.

**Нео-фаззи нейрон**

Рассмотрим нео-фаззи нейрон с несколькими входами и единственным выходом, который изображен на Рис.1 [Бодянский, 2011]. Он реализуется следующим отображением:

$$\hat{y} = \sum_{i=1}^n f_i(x_i) \tag{4}$$

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

$$f_i(x_i) = \sum_{j=1}^h w_{ji} \mu_{ji}(x_i) \tag{5}$$

и выполняет нечеткий вывод: если  $x_i$  есть  $x_{ji}$  то выход есть  $w_{ji}$ , где  $x_{ji}$  – нечеткое число, функция принадлежности которого  $\mu_{ji}$ , а  $w_{ji}$  – 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 (этапе) обучения:

$$\hat{y}(k) = \sum_{i=1}^n f_i(x_i(k)) = \sum_{i=1}^n \sum_{j=1}^h w_{ji}(k-1) \mu_{ji}(x_i(k)), \tag{6}$$

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




Рис. 1. Структура нео-фаззи нейрона

Обычно функции принадлежности  $\mu_j$  являются элементарными треугольными функциями, как показано на рис. 2.




Рис. 2. Треугольные функции принадлежности

Для предварительно нормированных входных переменных  $x_i$  (обычно от 0 до 1) функция принадлежности может быть описана в следующем виде:

$$\mu_{ij}(x_i) = \begin{cases} \frac{x_i - c_{j-1,i}}{c_{ji} - c_{j-1,i}}, & x \in [c_{j-1,i}, c_{ji}] \\ \frac{c_{j+1,i} - x_i}{c_{j+1,i} - c_{ji}}, & x \in [c_{ji}, c_{j+1,i}] \\ 0, & \text{в других случаях} \end{cases} \quad (7)$$

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

$$\mu_{ji}(x_i) + \mu_{j+1,i}(x_i) = 1 \quad (8)$$

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

$$f_i(x_i) = \mu_{ji}(x_i) w_{ji} + \mu_{j+1,i}(x_i) w_{j+1,i} \quad (9)$$

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

$$\hat{y} = \sum_{i=1}^n f_i(x_i(k)) = \sum_{i=1}^n \sum_{j=1}^h w_{ji}^{(k-1)} \mu_{ji}(x_i(k)) \quad (10)$$

Суммируя  $f_i(x_i)$ , находим выход  $y$  согласно формулы (10). 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  $x_i(k)$ , 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:

$$E(k) = \frac{1}{2} (y(k) - \hat{y}(k))^2 = \frac{1}{2} e^2 = \frac{1}{2} (y(k) - \sum_{i=1}^n \sum_{j=1}^h w_{ji} \mu_{ji}(x_i(k)))^2 \quad (11)$$

Функцию ошибки минимизируем с помощью обычного градиентного пошагового алгоритма:

$$W_{ji}(k+1) = W_{ji}(k) + \eta e(k+1) \mu_{ji}(x_i(k)) = W_{ji}(k) + \eta (y(k) - \sum_{i=1}^n \sum_{j=1}^h w_{ji} \mu_{ji}(x_i(k))) \mu_{ji}(x_i(k)) \quad (12)$$

где  $y(k)$  – целевое значение выходной переменной,  $\eta$  является скалярным параметром – скорость обучения.

С целью увеличения скорости обучения возможно использовать одношаговый алгоритм Уидроу-Хоффа [Бодянский, 2011]:

$$w(k+1) = w(k) + \frac{y(k+1) - \mathbf{W}^T \mu(x(k+1))}{\|\mu(x(k+1))\|^2} \mu(x(k+1)) \quad (13)$$

где  $\mu(x(k+1)) = \mu_{11}(x_1(k+1)), \dots, \mu_{h1}(x_1(k+1)), \dots, \mu_{1n}(x_n(k+1)), \dots, \mu_{hn}(x_n(k+1))$  или его модификации.

### Каскадная нео-фаззи нейронная сеть

Архитектура каскадной нео-фаззи нейронной сети (CNFNN) показана на рис. 3, а характеризующее ее отображение имеет следующую форму [Бодянский, 2011]:

- нео-фаззи нейрон первого каскада:

$$\hat{y}^{[1]} = \sum_{i=1}^n \sum_{j=1}^h w_{ji}^{[1]} \mu_{ji}(x_i); \quad (14)$$

- нео-фаззи нейрон второго каскада:

$$\hat{y} = \sum_{i=1}^n \sum_{j=1}^h w_{ji}^{[2]} \mu_{ji}^{[2]}(x_i) + \sum_{j=1}^h w_{j,n+1}^{[2]} \mu_{j,n+1}^{[2]}(\hat{y}); \quad (15)$$

- нео-фаззи нейрон 3-го каскада:

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

- нео-фаззи нейрон  $m$ -го каскада:

$$\hat{y} = \sum_{i=1}^n \sum_{j=1}^h w_{ji}^{[m]} \mu_{ji}^{[m]}(x_i) + \sum_{l=n+1}^{n+m-1} \sum_{j=1}^h w_{j,l}^{[m]} \mu_{j,l}^{[m]}(\hat{y}). \quad (16)$$

Следовательно, каскадная нео-фаззи нейронная сеть содержит  $h(n + \sum_{l=1}^{m-1} l)$  настраиваемых параметров и, что важно, что все они линейно включены в описание (16).

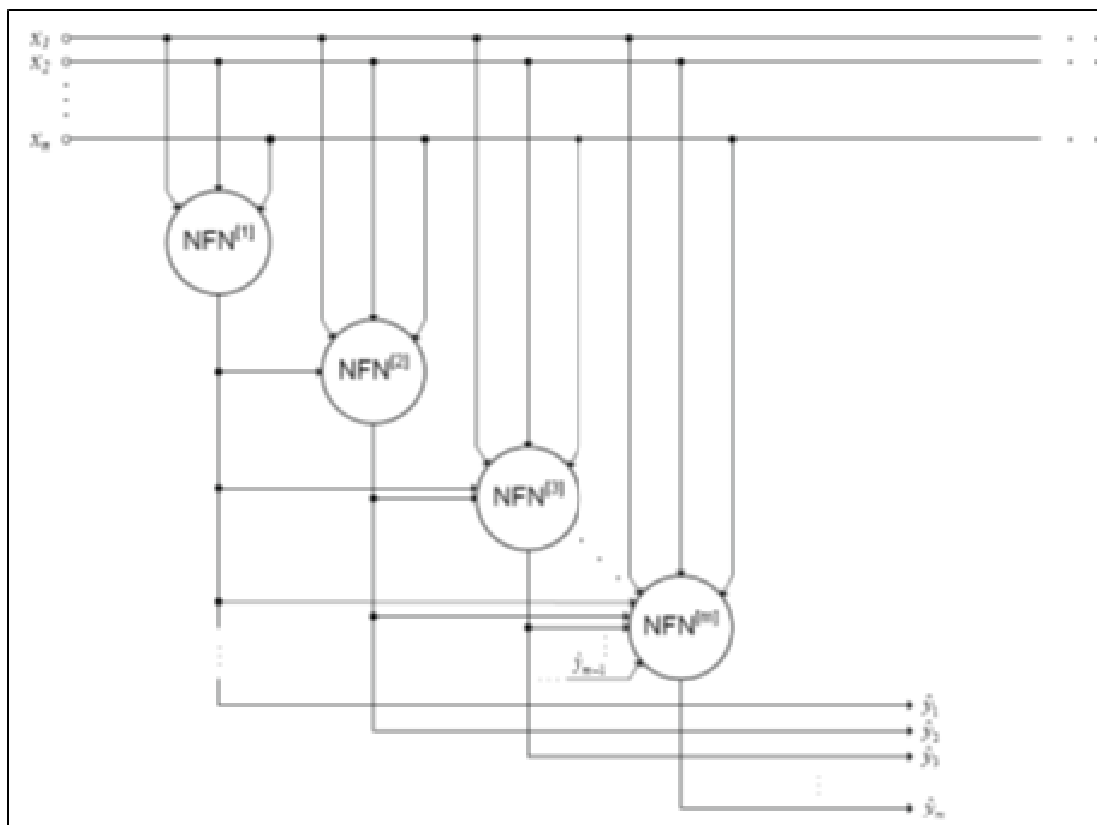


Рис. 3. Каскадная нео-фаззи нейронная сеть

Пусть  $\mu$ -вектор функций принадлежности  $m$ -го нео-фаззи нейрона размерности  $h(n+m-1) \times 1$

$$\mu^{[m]} = (\mu_{11}(x_1), \dots, \mu_{h1}(x_1), \mu_{12}(x_2), \dots, \mu_{h2}(x_2), \dots, \mu_{ji}(x_i), \dots, \mu_{hn}(x_n), \mu_{1,n+1}^{[1]}(y), \dots, \mu_{h,n+1}^{[1]}(y), \dots, \mu_{h,n+m-1}^{[1]}(y))^T$$

а соответствующий вектор синаптических весов:

$$W^{[m]} = (W_{11}^{[m]}, W_{21}^{[m]}, \dots, W_{h1}^{[m]}, W_{12}^{[m]}, \dots, W_{h2}^{[m]}, \dots, W_{ji}^{[m]}, \dots, W_{hn}^{[m]}, W_{1,n+1}^{[m]}, \dots, W_{h,n+1}^{[m]}, \dots, W_{h,n+m-1}^{[m]})^T,$$

который имеет ту же размерность. Тогда мы можем представить выражение (16) в векторном виде:

$$\hat{y}^{[m]} = W^{[m]T} \mu^{[m]} \quad (17)$$

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 следующим образом:

$$\mu^{[1]}(k) = (\mu_{11}(x_1(k)), \dots, \mu_{h1}(x_1(k)), \mu_{12}(x_2(k)), \dots, \mu_{h2}(x_2(k)), \dots, \mu_{ji}(x_i(k)), \dots, \mu_{hn}(x_n(k)))^T \quad (18)$$

Затем, минимизируя критерий обучения:

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

вектор синаптических весов может быть определен так:

$$W^{[1]}(N) = \left( \sum_{k=1}^N (\mu^{[1]}(k) \mu^{[1]T}(k)) \right)^+ + \sum_{k=1}^N \mu^{[1]}(k) y(k) = P^{[1]}(N) \sum_{k=1}^N \mu^{[1]}(k) y(k), \quad (19)$$

где  $(\bullet)^+$  означает псевдоинверсию Мура-Пенроуза (Moore-Penrose) [Бодянский, 2011].

В случае последовательной обработки данных используется рекуррентный метод наименьших квадратов [Бодянский, 2011]:

$$\left\{ \begin{array}{l} W^{[1]}(k+1) = W^{[1]}(k) + \frac{P^{[1]}(k)(y(k+1) - W^{[1]T}(k)W^{[1]}(k+1))}{1 + \mu^{[1]T}(k+1)P^{[1]}(k)\mu^{[1]}(k+1)} \mu^{[1]}(k+1) \\ P^{[1]}(k+1) = P^{[1]}(k) - \frac{P^{[1]}(k)(\mu^{[1]}(k+1)\mu^{[1]T}(k+1)P^{[1]}(k))}{1 + \mu^{[1]T}(k+1)P^{[1]}(k)\mu^{[1]}(k+1)}, P^{[1]}(0) = \beta I, \end{array} \right. \quad (20)$$

где  $\beta$  большое положительное число, а  $I$  является единичной матрицей с соответствующей размерностью.

С целью увеличения скорости обучения существует возможность использования одношагового алгоритма Уидроу-Хоффа (13) или его модификации [Бодянский, 2011].



Использование алгоритмов адаптации (13) или (20) приводит к сокращению вычислительной сложности процесса обучения. В любом случае использование процедур (13) и (20) существенно сокращают время обучения, по сравнению с градиентным методом, лежащим в основе алгоритма Back Propagation [Згуровский & Зайченко, 2013].

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-fuzzy нейрона  $NFN[2]$ .

Он имеет один дополнительный вход для сигнала выхода первого каскада. Затем снова используем процедуру (19) или (20) 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  $y^{[1]}(k)$ , затем используя вектор входов второго каскада  $(x^T(k), y^{[1]}(k))$  вычисляются веса  $W^{[2]}(x)$  и выходы  $y^{[2]}(k)$ . Для этой цели могут использоваться алгоритмы (19) и (20) одинаково успешно.

Процесс роста нейронной сети (наращивание числа каскадов) продолжается до тех пор, пока мы не получим требуемую точность решения, либо пока значение критерия не начнет возрастать.

### Экспериментальные исследования алгоритмов прогнозирования риска банкротства

Для анализа разных методов оценки риска банкротства был разработан программный комплекс, в котором реализованы классический метод дискриминантного анализа Альтмана, метод Давыдовой-Беликова, и нечеткие нео-фаззи каскадные нейронные сети. Используя разработанный программный комплекс, были проведены прогнозирования банкротства для пятидесяти восьми предприятий Украины, 29 из которых в 2011 году арбитражным судом были признаны банкротами.

Входными данными для расчетов были финансовые коэффициенты, которые исчислялись на основе данных из бухгалтерских отчетов (баланса и отчета о финансовых результатах) за 2009 и 2010 годы. Прогнозирование проводилось с помощью моделей Альтмана, Давыдовой-Беликова, нео-фаззи нейронных сетей. Анализ проводился на основе только количественных показателей.

В таблицах 2 - 3 приводятся результаты прогнозирования - процент ошибочной классификации банкротства предприятий за год до банкротства для статистических методов Альтмана, и Давыдовой-Беликова соответственно. В таблице 4 приведены результаты классификации с помощью каскадных нео-фаззи нейронных сетей.

**Таблица 2.** Результаты прогнозирования методом Альтмана за год до банкротства

	Альтман
Доля ошибок первого типа	0.3
Доля ошибок второго типа	0.344
Количество ошибок первого типа	9
Количество ошибок второго типа	10
Относительное количество ошибок	0.327

**Таблица 3.** Результаты прогнозирования риска моделью Давыдовой-Беликова за год до банкротства

	Модель Давыдовой-Беликова
Ошибка первого типа	0.206
Ошибка второго типа	0.31
Количество ошибок первого типа	6
Количество ошибок второго типа	9
Относительное количество ошибок	0.258

Таким образом, выборка состояла из 58 предприятий. По финансовым данным за 1 год до банкротства методом Альтмана 22 предприятия было признано банкротами, 8 предприятий - с большим риском банкротства и 26 предприятий - с удовлетворительным финансовым состоянием. По модели Давыдовой-Беликова – 26 признано банкротами, 5 предприятий – с большим риском банкротства и 29 предприятий – с удовлетворительным финансовым состоянием.

**Таблица 4.** Результаты прогнозирования риска банкротства за год до банкротства с использованием каскадной нео-фаззи нейронной сети

	Учебная выборка	Тестовая выборка
Ошибка первого типа	0.128	0.143
Ошибка второго типа	0.0632	0.143
Количество ошибок первого типа	2	2
Количество ошибок второго типа	1	2
Относительное количество ошибок	0.096	0.143

Таким образом, методом, который спрогнозировал банкротство с наибольшей точностью за год до банкротства, оказался метод с использованием каскадных нео-фаззи нейронных сетей. Точность прогнозирования составила 90% за год до банкротства и 85% за 2 года до банкротства. Такой результат целиком закономерный, поскольку нечеткие нейронные сети, который базируется на использовании теории систем с нечеткой логикой, лучше прогнозирует при условиях неопределенности, неоднородности данных, а также учитывает субъективные оценки экспертов. Погрешность 10% и 15% обусловлена входными данными. Мы не имеем 100% уверенности в правильной разбивке всей выборки на банкроты и успешные предприятия. Ведь проверочная выборка может иметь определенные неточности, которые влияют на величину ошибок.

Как, видим, статистическая модель Альтмана показала довольно большую ошибку прогнозирования, которая равна 32.7% (за 1 год) и 38% (за два года). Это ставит под вопрос целесообразность использования этих моделей для анализа финансового состояния украинских предприятий. Основными причинами такой погрешности есть: неадаптированность моделей к условиям украинской экономики, предположение относительно однородности, независимости и стационарности данных, которые в нашем случае не выполняются, а также то, что статистические модели лишь анализируют текущее финансовое состояние предприятий и не учитывают динамики изменения показателей во времени.

---

В работе [Згуровский & Зайченко, 2013] были исследованы матричный метод Недосекина [Недосекин, 2003], а также нечеткие нейронные сети с выводом Мамдани и Цукамото в задаче прогнозирования риска банкротства. Были получены следующие результаты: точность прогнозирования за год до банкротства составила: для матричного метода - 86% , для ННС Мамдани - 90,5%, для ННС Цукамото - 85%. За два года до банкротства точность прогнозирования составила: для матричного метода - 81%, для ННС Мамдани - 86%, для ННС Цукамото - 82,2%. Как видим, точность прогнозирования риска банкротства для каскадной нео-фаззи нейронной сети приближается к ННС Мамдани, но при этом нео-фаззи каскадные сети имеют преимущества:

- 1) *Не нужно разрабатывать и настраивать базу правил;*
- 2) *Значительно более высокая скорость обучения.*

---

### **Заключение**

В статье рассмотрены методы прогнозирования риска банкротства предприятий: классические методы дискриминантного анализа Альтмана и Давыдовой – Беликова, а также предлагаемый метод на основе каскадных нео-фаззи нейронных сетей. Проведены экспериментальные исследования указанных методов для прогнозирования риска банкротства предприятий Украины.

Проведенные исследования показали, что наиболее высокую точность прогнозирования риска банкротства применительно к экономике Украины дают нечеткие нейронные сети.

---

### **Acknowledgement**

The paper is published with financial support by the project ITHEA XXI of the Institute of Information Theories and Applications FOI ITHEA ([www.ithea.org](http://www.ithea.org)) and the Association of Developers and Users of Intelligent Systems ADUIS Ukraine ([www.aduis.com.ua](http://www.aduis.com.ua)).

---

### **Литература**

- [Altman, 1968] Altman E.I., "Discriminant Analysis and the prediction of Corporate Bankruptcy", *Financial Ratios, Journal of Finance*, September 1968, pp. 589-609.
- [Altman, 1983] Altman E. I., "Corporate Financial Distress", New York, John Wiley, 1983, 192 p.
- [Бодянский, 2011] Е. В. Бодянский, "Каскадная эволюционная нейронная сеть с нео-фаззи нейронами в качестве", [Электронный ресурс], Режим доступа: [http://www.nbu.gov.ua/portal/natural/Vejpt/2011\\_4\\_3/2011\\_4\\_3/55-58.pdf](http://www.nbu.gov.ua/portal/natural/Vejpt/2011_4_3/2011_4_3/55-58.pdf)
- [Давыдова & Беликов, 1999] Давыдова Г.В., Беликов А.Ю., "Методика количественной оценки риска банкротства предприятий", *Управление риском*, № 3, 1999, с. 13 - 20.
- [Згуровский & Зайченко, 2013] Згуровский М. З., Зайченко Ю.П., "Основы вычислительного интеллекта", К.: Наукова Думка, 2013, 406 с.
- [Недосекин & Максимов, 2003] Недосекин А.О., Максимов О.Б., "Анализ риска банкротства предприятия. Метод. Указания по курсу „Антикризисное управление“", 2003 [Электронный ресурс], Недосекин А.О. Максимов О.Б., Павлов Г.С., Режим доступа к журн: [http://sedok.narod.ru/sc\\_group.htm](http://sedok.narod.ru/sc_group.htm).
- [Недосекин, 2003] Недосекин А.О. Система оптимизации фондового портфеля от Сименс Бизнес Сервисес, *Банковские технологии*, 2003, № 5, Также на сайте: <http://www.finansy.ru/publ/fin/004.htm>

---

---

**Информация об авторах**

---

**Ови Нафас Агаи аз Гамиш (Иран)** - аспирант НТУУ „КПИ“; 03056, Киев-56, Украина;  
e-mail: ovinafas@yahoo.com



**Зайченко Юрий** - д.т.н., профессор ННК „Институт прикладного системного анализа“, 03056, Киев-56, проспект Победы, 37, Украина, тел: 38044 -4068393;  
e-mail: baskervil@voliacable.com,

**Области научных исследований:** теория принятия решений в условиях неопределенности, модели и методы вычислительного интеллекта в задачах прогнозирования и анализа в экономике и финансовой сфере, моделирование и оптимизация компьютерных сетей

### **Bankruptcy risk forecasting under uncertainty with application of fuzzy neural networks**

**Ovi Nafas Aghae agh Gamish, Yuriy Zaychenko**

**Abstract:** *The problem of corporations' bankruptcy risk forecasting under uncertainty is considered in this paper. The application of neo-fuzzy cascade neural networks is suggested. The experimental investigations of cascade neo-fuzzy networks for bankruptcy risk forecasting for Ukrainian corporations were carried out and their efficiency was estimated and compared with fuzzy neural networks with algorithms of Mamdani, Tsukamoto and classical statistical methods.*

**Keywords:** *bankruptcy risk forecasting, cascade neo-fuzzy network, fuzzy networks of Mamdani and Tsukamoto.*