

# **ФИНАНСЫ РЫНОК ТРУДА И ЭКОНОМИКА ОБРАЗОВАНИЯ**

## **LABOR MARKET AND ECONOMIC EDUCATION AND BUSINESS**

УДК 336.004+519.7

DOI:10.18413/2411-3808-2018-45-1-47-58

### **МЕТОД ПОСТРОЕНИЯ ДИНАМИЧЕСКОЙ МОДЕЛИ БАНКРОТСТВ ЭКОНОМИЧЕСКИХ ОБЪЕКТОВ**

### **A METHOD OF CONSTRUCTING A DYNAMIC MODEL OF BANKRUPTCIES OF ECONOMIC ENTITIES**

**Л.И. Касимова, А.Н. Бирюков**  
**L.I. Kasimova, A.N. Biryukov**

ФГБОУ ВО «Башкирский государственный университет» Стерлитамакский филиал,  
Россия, 453103, Республика Башкортостан, г. Стерлитамак, проспект Ленина, 49

"Bashkir state University" branch Sterlitamak,  
Russia, 453103, Republic of Bashkortostan, Sterlitamak, Lenin's Avenue, 49

E-mail: biryukov\_str@mail.ru

#### **Аннотация**

Объектом рассмотрения настоящей работы является весьма глубокое проникновение требований эффективного обучения нейросетей в алгоритмы предпроцессорной обработки. Разработан метод оценки адекватности нейросетевых моделей в отсутствие каких-либо априорных сведений о законе распределения шумов в данных. Именно это и является научной новизной данной статьи, так как данный метод позволяет взаимосвязано управлять качеством предпроцессорной обработки финансовых данных и качеством их аппроксимации в нейросети для оценки риска банкротства экономического объекта. Главной целью всех алгоритмов предпроцессорной обработки данных является повышения однородности данных и улучшение их качества (информативности) в аспекте обучения нейросети. Итогом является построение основной нейросетевой динамической модели восстановления многомерной «обобщенной производственной функции» на основе байесовского подхода. Управление качеством нейросетевой модели необходимо для нахождения горизонта прогноза риска банкротства экономического объекта, оценивания стадии развивающегося процесса кризиса объекта во времени. Достижимый эффект от указанных теоретических предложений – повышение эффективности (в аспекте достижения компромисса между точностью предсказания и робастностью) нейросетевой модели для сложных условий моделирования (сильной зашумленности данных и дефицита наблюдений).

#### **Abstract**

The object of the consideration of this work is very deep penetration requirements for an effective neural network learning algorithms in preprocessing processing. Developed a method to assess the adequacy of neural network models in the absence of any a priori information about the distribution law of noise in the data. This is the scientific novelty of this article, as this method allows interrelated to control the quality of preprocessing financial data processing and their quality of approximation in neural networks for assessing the risk of bankruptcy of an economic object. The main purpose of all algorithms preprocessing data processing is to improve the homogeneity of the data and improving their quality (information value) in the aspect of neural network learning. The result is the construction of a basic neural network dynamic recovery model, the



multivariate "generalized production functions" on the basis of the Bayesian approach. The quality control neural network model is necessary for finding the projection horizon the risk of bankruptcy of the entity, the evaluation stage of the developing process of the crisis of the object in time. The effect from these theoretical proposals – improving the efficiency (in terms of compromise between prediction accuracy and robustness) neural network model for a complex simulation (strong noise in the data and lack of observations).

**Ключевые слова:** нейросетевые модели, вероятность риска банкротств, блоки алгоритма, бухгалтерская отчетность, управленческое решение.

**Key words:** neural network model, the probability of the risk of bankruptcies, the blocks of the algorithm, accounting and reporting, managerial decision.

## Введение

Построение моделей оценки вероятности риска банкротств остается актуальной задачей в настоящее время в связи со многими приложениями в реальном и финансовом секторах экономики. К таким задачам относятся: задачи оценки банкротств корпораций; оценки финансово-экономического состояния корпораций в сделках; оценки инвестиционной привлекательности предприятий; обеспечения экономической безопасности предприятий путем мониторинга их финансового состояния; оценки банком кредитоспособности заемщиков. Из перечисленных задач наиболее распространенными являются задачи корпоративного финансового менеджмента, в которых разработка моделей банкротств, прежде всего, актуальна с точки зрения повышения качества корпоративного и финансового управления. Система мониторинга риска банкротства корпорации, должна использовать интеллектуальные информационные технологии, в частности нейросетевые для достижения эффективности корпоративного управления [Miroliubova Tatiana, Alexander Viryukov., 2015].

Методы исследований. До настоящего времени не исследованы нейросетевые прогнозные динамические модели оценки вероятности риска банкротств, которые представляют наибольший практический интерес. Знание динамики развивающегося во времени процесса банкротства корпорации позволяет в каждый момент времени определить стадию банкротства и применить упреждающие управляющие воздействия [Горбатков С.А., Полупанов Д.В., Макеева Е.Ю., Бирюков А.Н., 2012].

На пути создания динамических моделей риска банкротства предприятий возникают труднопреодолимые препятствия в виде неполноты данных.

Проблема «неполноты данных» в рассматриваемом классе задач оценки риска банкротства со спецификой самой модели, в которой индикатором риска банкротства является вероятность  $P$  этого риска, моделируемая логистической функцией вида:

$$P = 1/[1 + \exp(-\hat{y}(\vec{x}(t), t))]; P \in [0; 1], \quad (1)$$

где  $t$  - текущее время;  $\hat{y}(\vec{x}(t), t)$  – показатель экспоненты, представляющий собой нелинейную агрегирующую функцию от вектора факторов  $\vec{x}(t) = (x_1(t), x_2(t), \dots, x_n(t))$  и времени  $t$ . Вектор факторов  $\vec{x}(t)$  тоже зависит нелинейно от времени  $t$ .

2) Вторая причина неполноты данных связана со спецификой юридического характера. Корпорация может быть признана банкротом ( $P = 1$ ) только в трех случаях: по решению арбитражного суда; по решению налоговых органов; по заявлению о банкротстве самой корпорации. В остальных случаях корпорация в рамках модели (1) не считается банкротом, т.е. для нее  $P = 0$ .

Проблема «неполноты данных» порождается взаимодействием указанных выше двух причин. С одной стороны, в текущих «временных срезах»  $t_k = t_1, t_2, \dots, t_{R-1}$  для части объектов в выборке обучающих примеров известны только значения аргументов функции  $\hat{y}(\vec{x}, t)$ , т.е. вектор  $\vec{x}_k$  и  $t_k$ , а значение выходной переменной  $\hat{y}_k$  (либо  $P_k$ ) неизвестны. Эту «неполноту данных» решено назвать «динамическая неполнота», поскольку она может

изменяться в разных временных срезах ( $t_k = var$ ) – в одних срезах она имеет место, а в других нет.

Идея предлагаемого метода направлена на устранение, либо существенное ослабление влияния сформулированных выше «неполноты данных» на качество модели банкротства вида (1) – (2), обладающей способностью экстраполяции прогноза для непрерывного временного аргумента  $t$  в рамках заданного горизонта прогноза  $t = t_{нп} > t_R$ .

### Основные результаты исследования

Алгоритм динамического метода оценки вероятности риска банкротства разрабатывался для решения класса задач диагностики и прогнозирования банкротств. Некоторые процедуры и блоки алгоритма являются универсальными, другие имеют некоторые отличия в реализации в зависимости от объекта моделирования отрасли экономики.

Ниже при описании отдельных блоков алгоритму, при необходимости даются подробные пояснения к используемым операциям и приводятся обозначения всех величин.

Согласно, разработанному алгоритму процесс построения нейросетевой динамической логистической модели банкротств можно разделить на четыре этапа (Рис. 1):

1. Предрегуляризация модели (Подмодель I);
2. Построение статической нейросетевой модели (СНСМ) (Подмодель II);
3. Построение квазистатической нейросетевой подмодели (КСНСМ) с дискретным временем (Подмодель III);
4. Построение финишной нейросетевой логистической динамической модели (НЛДМ) с непрерывным временем (Модель IV).

#### Подмодель I.

**Блок I.1.** На основе данных бухгалтерской отчетности некоторой примерно однородной совокупности предприятий (из одной отрасли и примерно одинакового масштаба) формируется исходная база данных – кортежи вида  $D = (\vec{x}_i, y_i), i = \overline{1, N}, j = \overline{1, n}$ , где  $\vec{x}_i$  – вектор строки значений факторов  $X_j$ ;  $y_i$  – значения выходной величины показателя экспоненты в (1);  $i = \overline{1, N}$  – номер наблюдения.

**Блок I.2.** В теории нейросетей под «парадигмой» подразумевается способ обработки информации (сигналов) в нейросети. При построении были использованы нейросети типа многослойный перцептрон (MLP) с алгоритмом обучения типа «обратного распространения ошибки» (Back Propagation (BP)) [Ясницкий Л.Н., 2016]. Архитектура нейросети и активационные функции варьировались для каждой нейросети  $h_q$ , выбираемой в качестве альтернативной априорной гипотезы байесовского ансамбля:  $h_q \in H, q = \overline{1, Q}$ , где  $Q$  – число нейросетей в ансамбле,  $H$  – класс моделей, единый для всех нейросетей  $\{h_q\}$  в ансамбле. В предлагаемом алгоритме в качестве  $H$  использовались MLP BP сети. В качестве активационных функций используются сигмоид и гиперболический тангенс; число скрытых слоев нейросети от 1 до 10. Использовался программный продукт Brain Maker Pro 3.11. В качестве расчетных величин нейросетевой модели использовались усредненные на отфильтрованном байесовском ансамбле значения [Горбатков С.А., Полупанов Д.В., Макеева Е.Ю., Бирюков А.Н., 2012].

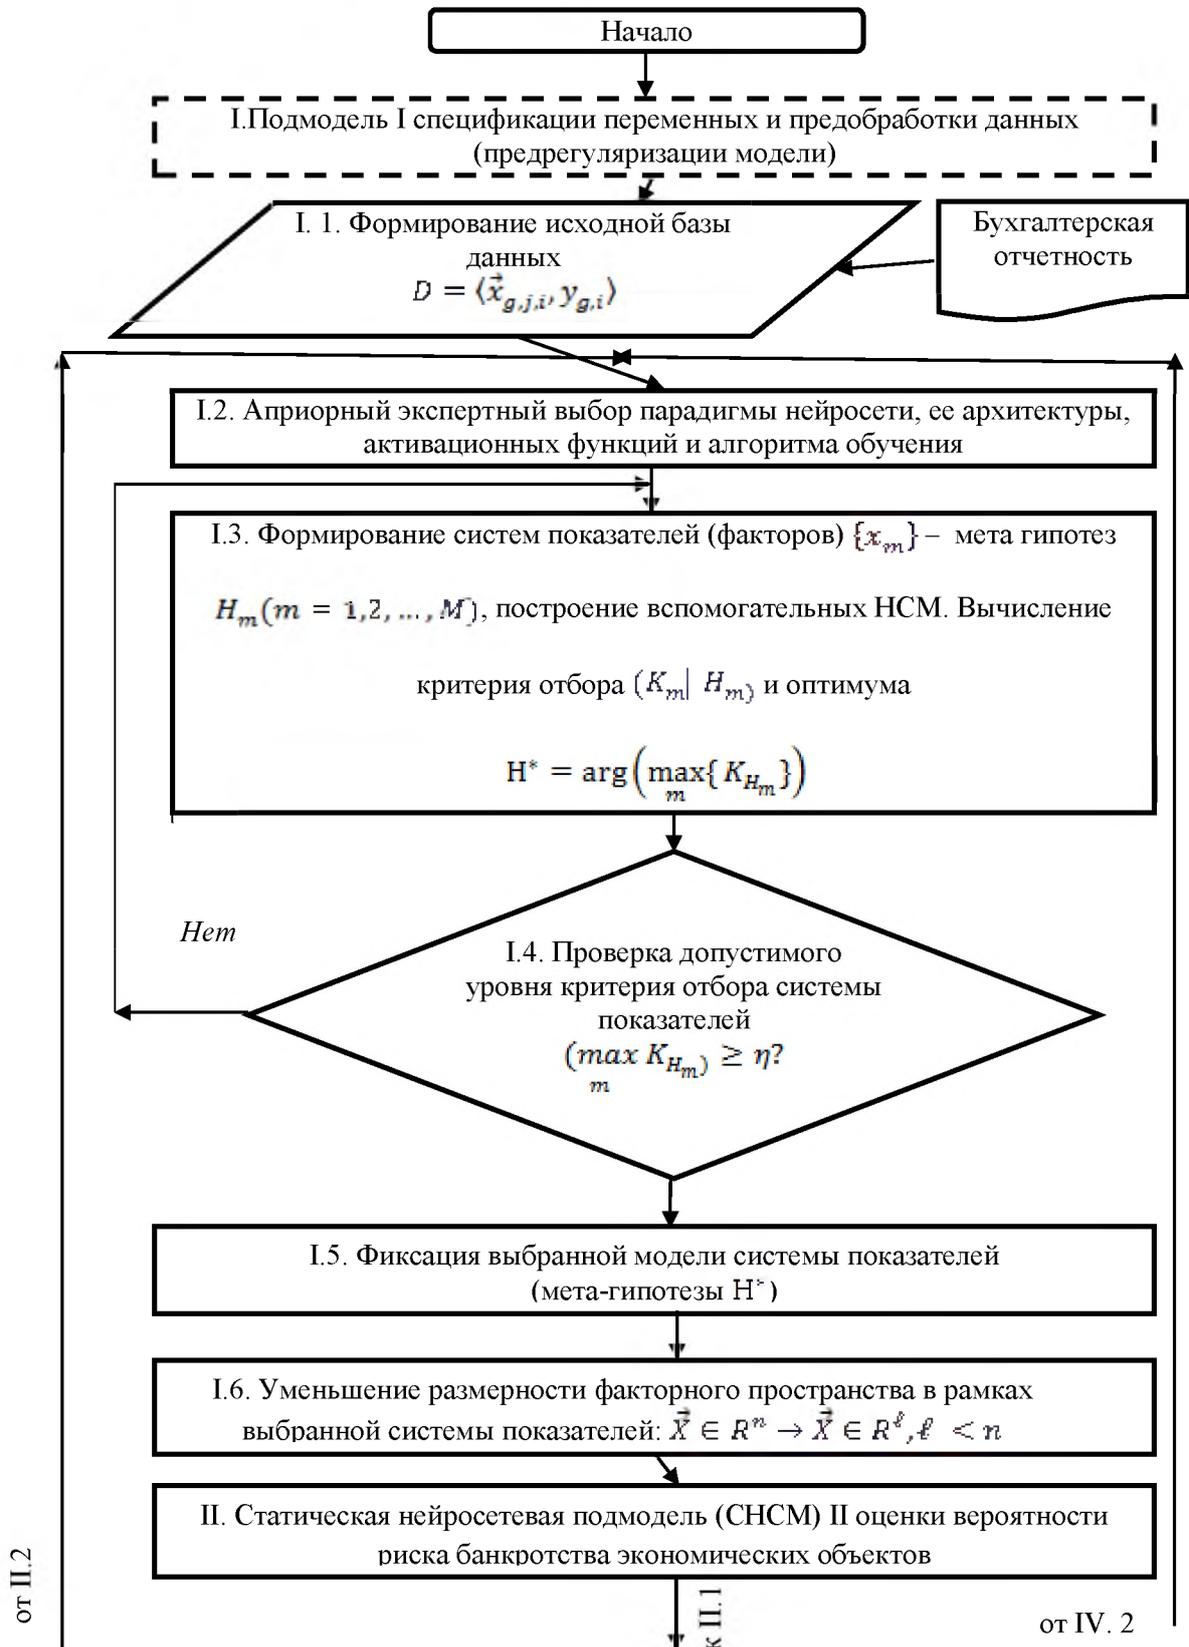
**Блок I.3.** На начальном этапе построения нейросетевой модели неизвестно, какой набор факторов наилучшим образом подходит для восстановления скрытых в данных многомерных зависимостей (как правило, нелинейных). Поэтому на основе исходной базы данных  $D = (\vec{x}_{ij}, y_i), i = \overline{1, N}, j = \overline{1, n}$  формируется несколько альтернативных систем показателей,  $H_m, m = \overline{1, M}$ , отличающихся между собой набором факторов  $\{X\}_m$ . Критерии отбора факторов могут отличаться в зависимости от особенностей решаемой задачи. Для определения оптимальной системы показателей  $H^*$  создается вспомогательная нейросеть, соответствующая ранее выбранной парадигме, которая последовательно обучается на каждом

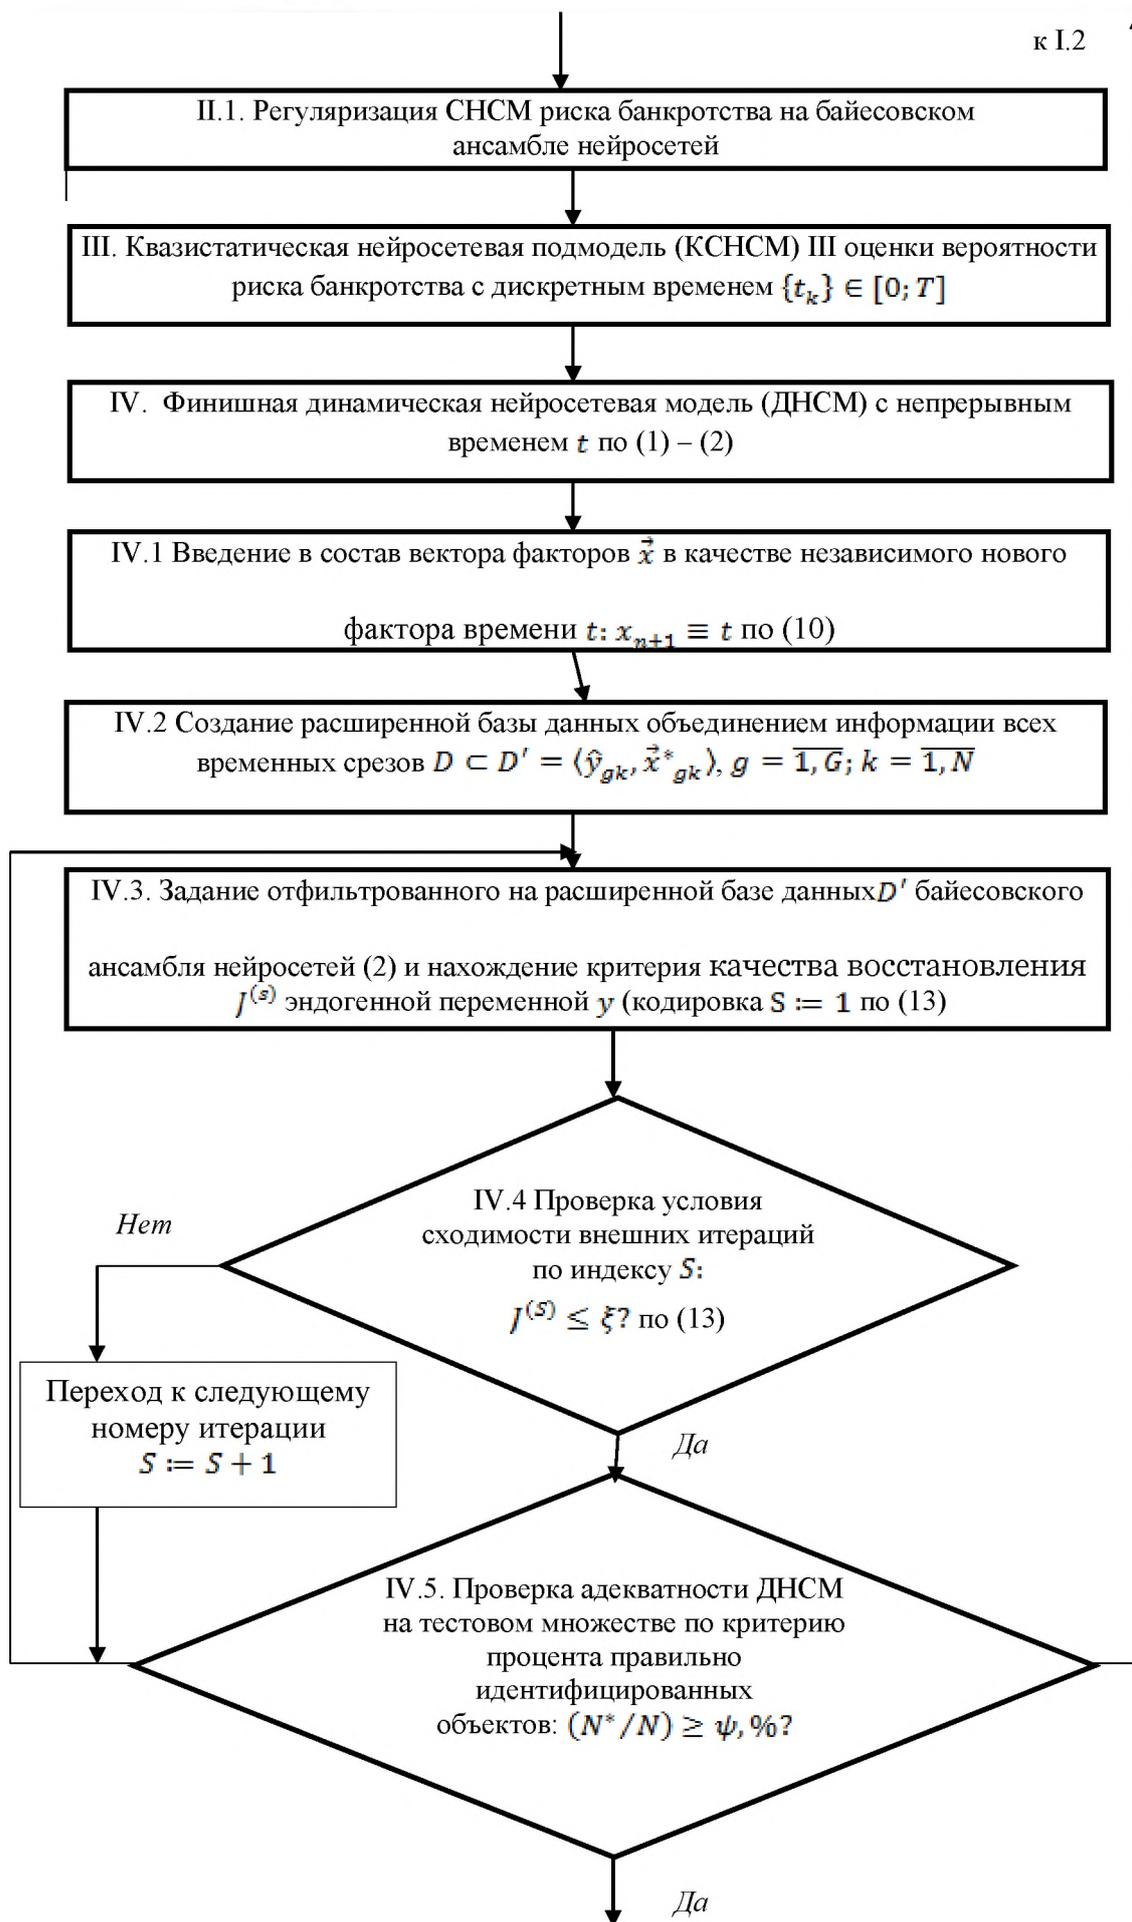


наборе данных из системы  $H_m$ . После тестирования нейросети вычисляется критерий отбора системы факторов, характеризующий качество обучения.

Для задач диагностики банкротств в качестве критерия отбора предлагается использовать следующий показатель:

$$K_{H_m} = N_{H_m}^* r_1 - N_{H_m}^{(1)} r_2 - N_{H_m}^{(2)} r_3, m = \overline{1, M}, \quad (3)$$





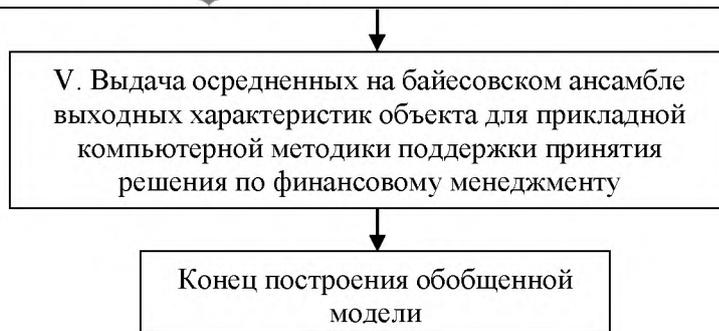


Рис. 1 – Логическая схема алгоритма построения нейросетевой логистической динамической модели оценки риска банкротства

Fig. 1 – the Logical scheme of the algorithm for constructing of neural network dynamic logistic model to assess the risk of bankruptcy

где  $N_{H_m}^*$  - количество верно идентифицированных предприятий для системы показателей  $H_m$ ;  $N_{H_m}^{(1)}$  - количество ошибок первого рода;  $N_{H_m}^{(2)}$  - количество ошибок второго рода;  $r_1, r_2, r_3$  - удельный вес каждого показателя.

Веса  $r_1, r_2, r_3$  назначаются согласно правилу Фишберна:

$$r_i = \frac{2(n-i+1)}{(n+1)n}; \quad (4)$$

где  $n$  - количество ранжируемых показателей;  $i$  - текущий номер показателя в ранжированном по предпочтениям ряду.

Окончательный выбор оптимальной системы показателей  $H^*$  осуществляется по правилу:

$$H^* = \arg(\max_m K_{H_m} | (H_m)), m = \overline{1, M}. \quad (5)$$

**Блок I.4.** Критерий качества обучения для выбранной оптимальной системы показателей должен быть не менее некоторого заранее заданного уровня  $\eta$ . Проверяется условие информативности выбранной системы показателей:

$$H^* : \max_m K_{H_m} | (H_m) \geq \eta? \quad (6)$$

Если это условие выполняется, то выбранная система показателей признается достаточно удачной для дальнейшего построения нейросетевой модели. В противном случае необходимо вернуться к блоку I.3, сформировать новые системы показателей  $H_m, m = \overline{1, M}$ , и повторить процедуру набора  $H^*$ .

**Блок I.5.** Фиксация выбранной оптимальной системы показателей  $H^*$ .

**Блок I.6.** Для выбранной оптимальной системы показателей  $H^*$  проводится процедура уменьшения размерности факторного пространства:

$$\vec{X} \in R^n \rightarrow \vec{X}' \in R^\ell, \ell < n. \quad (7)$$

Уменьшение длины описания данных (количества факторов) позволяет получить следующие положительные эффекты для построения нейросетевой модели:

- уменьшение требуемого объема обучающей выборки для заданного допустимого уровня ошибки обобщения нейросети  $E$ ;
- повышение устойчивости сети к малому возмущению данных;
- сокращения времени обучения и тестирования нейросетей.

Отбор факторов в рамках выбранной системы показателей  $H^*$  может осуществляться путем последовательного включения или исключения факторов. Кратко

опишем первый способ. Случайным образом формируется некоторый первоначальный набор факторов, на основе которого обучается вспомогательная нейросеть (аналогично пункту I.3). Вычисляется критерий качества обучения по (3). Затем к первоначальному набору факторов поочередно добавляются факторы из числа оставшихся. На каждой итерации фиксируется критерий (3) и находится лучшая система факторов  $H^*$  по (6) из набора  $m = \overline{1, M}$ .

**Блок II.1.** Построение статической нейросетевой модели оценки (диагностики) риска банкротства корпорации сводится к восстановлению зависимости показателя экспоненты  $y(x)$  в (1) при условии  $t = t_R = const$  в последнем временном срезе. Исходной базой для этой задачи служат кортежи  $(y_{R,g}; \vec{x}_{R,g})$ , где  $g$  – номер корпорации в объединенной обучающей и тестирующей выборках нейросети. Причем в эти кортежи включаются как граничные значения вероятности  $P_{R,g} = 0$  (корпорация – «небанкрот»,  $y_{R,g} \approx -7$ ) либо  $P_{R,g} = 1$  (корпорация – «банкрот»,  $y_{R,g} \approx +7$ ), так и промежуточные значения  $0 < P_{R,g} < 1$ , восстановленные по вспомогательным известным статическим моделям банкротства (не обязательно логистическим) [Макеева Е.Ю. Горбатков С.А., 2014]. Была использована статическая модель В.Ю. Жданова, И.Ю. Жданова, и реализующую ее программу Q Fin Analysis. Тем самым приближенно компенсируются (либо ослабляется) упомянутая выше «статическая неполнота данных».

**Замечание 1.** Задание архитектуры нейросетей в байесовском ансамбле, количества нейронов в промежуточных слоях, вида активационных функций, варьируемых в разных сетях ансамбля (блок I.2 на Рис. 1) есть не что иное, как использование априорной эвристической информации, аккумулирующей опыт разработчика модели. При этом сужается класс искомых решений обратной задачи аппроксимации зависимости  $\hat{y}_R(x_R)$ , а значит, происходит частично ее регуляризация.

Таким образом, априорное формирование мета-гипотезы  $H$  байесовского ансамбля нейросетей  $\{h_q(D, W|H)\}$  в блоке I.2 и оставляет первый механизм регуляризации при построении подмодели II.

После обучения всех нейросетей  $\{h_q\}$ ,  $q = \overline{1, Q}$ , байесовского ансамбля и их тестирования производится их апостериорная фильтрация по качеству объяснения данных. Для данного алгоритма используется для отбора нейросетей при фильтрации критерии вида (3) и условие:

$$q^* : K_{H,q^*} \geq \eta; q^* \in \overline{1, Q^*}; Q^* \leq Q, \tag{8}$$

где  $\eta$  – экспертно выбираемое на основе предварительных экспериментов число (в оценках авторов  $\eta$  порядка 8...30, см. ниже);  $q^*$  – номер сети в ансамбле прошедшей, процедуру фильтрации (8);  $Q^*$  – суженное число нейросетей в ансамбле.

**Замечание 2.** Процедура фильтрации (8), приводящая к сужению класса искомых решений обратной задачи аппроксимации зависимости  $\hat{y}_R(x_R)$ , есть второй механизм регуляризации в предлагаемом байесовском подходе.

Искомая функция  $\hat{y}_R(\vec{x}_R)$  в подмодели II находится путем весового осреднения на отфильтрованном байесовском ансамбле нейросетей:

$$\hat{y}_{R, \text{ЭСП}}(\vec{x}_R) = \frac{1}{Q^*} \sum_{q^*=1}^{Q^*} \hat{y}_{R,q^*} \cdot \omega_{q^*}; \omega_{q^*} = \frac{K_{H,q^*}}{\sum_{q^*=1}^{Q^*} K_{H,q^*}} > 0,$$

$$\omega_{q^*} < 1, \sum_{q^*=1}^{Q^*} \omega_{q^*} = 1, \quad (9)$$

где  $\omega_{q^*}$  - весовой коэффициент, учитывающий качество объяснения данных  $D$  сетей в отфильтрованном ансамбле.

**Замечание 3.** Операция осреднения результата оценки (9) на отфильтрованном ансамбле сужает класс искомых решений обратной задачи, и, следовательно, представляет собой третий механизм регуляризации в рамках предлагаемого байесовского подхода.

**Замечание 4.** Полученную статическую подмодель II (СНСМ) можно рассматривать как стартовую (базисную) модель, которая предопределяет качество аппроксимации данных для квазистатической подмодели III и динамической модели IV с непрерывным временным аргументом.

**Блок III.** Построение квазистатической нейросетевой подмодели III в блоке III основано на следующем допущении: в силу инерционности экономических процессов будем считать, что найденная в блоке II.1 статическая нелинейная зависимость  $\hat{y}_R(\vec{x}_R)$  «распространяется» и на соседний временной срез ( $t_k = t_{R-1}$ ), естественно, с некоторой погрешностью, для уменьшения которой вводится итерационный процесс с индексом  $k = t_{R-1}, t_{R-2}, \dots, t_1$ , т.е. от предпоследнего к первому временному срезу. Назовем этот процесс «внутренним итерационным циклом».

**Замечание 5.** В КСНСМ уже можно приближенно оценивать стадии развивающегося процесса банкротства в вероятностях во временных срезах. Однако, динамическая информация в моменты времени между срезами и для прогноза вперед отсутствует.

**Блок IV. 4.** Проверяется условие сходимости внешних итераций (по индексу  $s$ ) процесса восстановления эндогенной переменной  $y$  в каждом  $k$  - ом фиксированном временном срезу по (10):

$$J^{(s)} = \max_{\Xi} \left[ \max_k \left| \frac{\hat{y}_{gk}^{(s)} - \hat{y}_{gk}^{(s-1)}}{\hat{y}_{gk}^{(s)}} \right| \right] \leq \xi; \quad g = \overline{1, G}; k = \overline{1, R-1}; S = 3, 4 \dots \quad (10)$$

где  $\xi$  - заданное малое число (в вычислительных экспериментах принималось  $\xi = 0,05$ ).

**Блок IV. 5.** Проверяется качество финишной нейросетевой модели банкротства по критерию процента правильно идентифицированных объектов по (11):

$$(N^*/N) \geq \psi, \%, \quad (11)$$

где  $\psi$  - приемлемый процент верной идентификации (в вычислительных экспериментах по таблице 1, принималось  $\psi = 85\%$ ).

**Блок V.** Определяются характеристики, осредненные на байесовском ансамбле нейросетевых динамических моделей по (9) для последнего шага внешних итераций  $S^*$ , необходимые для поддержки принятия решений по финансовому менеджменту. Например, находится прогноз риска банкротства корпорации для горизонта прогноза  $t = t_{np}$  и оценивается стадия развивающегося процесса кризиса корпорации для времени  $t_{np}$ .

**Замечание 6.** В результате анализа логической схемы предлагаемого алгоритма можно отметить, что по сравнению с известным «прототипом» - алгоритмом построения статической модели банкротства из [Борисов В.В., Круглов В.В., Федюлов А.С., 2007] по



методу «вложенных математических моделей (МВММ)» - в предлагаемом алгоритме оригинальными являются блоки II, III, IV, V.

Новыми отличительными признаками операций в этих блоках являются:

- В блоке II компенсации «статической неполноты данных» в последнем временном срезе путем введения в кортежи данных этого среза информации о промежуточных значениях вероятности риска банкротства  $P_R$  между граничными точками в интервале  $[0; 1]$ , которые вычисляются на основе известных статических моделей банкротства [Макеева Е.Ю. Горбатков С.А., 2014] например В.Ю. Жданова и И.Ю. Жданова, D. Ohlson, Альтмана-Сабато и др. Данная операция повышает информативность стартовой (исходной) базы данных последнего временного среза, где юридически определены метки объектов («банкрот», «небанкрот»). Следовательно, эта операция предопределяет повышение прогностической силы финишной динамической модели, получаемой в блоке IV.

- В блоке III, где получается квазистатическая нейросетевая модель банкротства (КСНСМ), операция компенсации «динамической неполноты данных» путем использования косвенной информации об изменении вероятности  $P(t_k)$  во временных срезах  $\{t_k\}, k = \overline{1, R}$  через временные функции  $\vec{x}(t_k)$ . Другими словами эндогенные переменные во временных срезах  $\{y_k\}, k = \overline{1, (R-1)}$  восстанавливается в процессе «внутренних» итераций по индексу  $k = (R-1), (R-2), \dots, 1$ , где  $k$  – номер временного среза. Положительный эффект этой операции – получение комплектной (полной) базы данных, пригодной для построения финишной нейросетевой динамической модели в блоке IV. Кроме того, КСНСМ позволяет оценивать дискретно, т.е. во временных срезах, вероятности риска банкротства  $P(t_k)$ , а значит определять в срезах стадии развивающегося в предприятии кризиса.

- В блоке IV, где получается финишная нейросетевая динамическая модель банкротства с непрерывным временем  $t$ , операция внешних итераций по индексу  $S$  обучения, тестирования, регуляризации и верификации ДНСМ. Положительный эффект этой операции – введение в модель непрерывного времени, что позволяет оценивать вероятность риска банкротства  $P(t)$  в любой точке между временными срезами, а также экстраполировать эту вероятность вперед на заданный горизонт прогноза  $t = t_{н.п.}$ . В прикладном аспекте это улучшает качество принимаемых управленческих решений по финансовому менеджменту.

#### ***Количественные оценки апробации предложенного алгоритма***

Использовались реальные данные для строительных организаций из международной базы данных «Verua Van Dijk» [Макеева Е., Netetina E. A., 2013]. В исходную базу данных вошли 136 российских предприятий строительной отрасли с наблюдениями в течение 5 лет (для пяти временных срезов с 2009 по 2013 год с равномерным интервалом).

В качестве компонент вектора  $\vec{x}$  использовались:

- Из группы I («рентабельность»);
- Из группы II («ликвидность и платежеспособность»);
- Из группы III («деловая активность»);
- Из группы IV («финансовая устойчивость»).

Все факторы вычислялись на основе стандартной бухгалтерской отчетности и нормировались, т.е. приводились к безразмерной форме.

Результаты расчетов по предлагаемому алгоритму приведены на рисунке 2 и в таблице 1.

Таблица 1

Table 1

Результаты тестирования байесовского ансамбля нейросетей, обучавшихся на данных за все 5 лет (итерация  $s = 2$ )

Results of testing Bayesian ensemble of neural networks trained on data for all 5 years (iteration  $s=2$ )

№ сети	Доля верно распознанных предприятий	Всего ошибок	Количество ошибок 2-го рода	Количество ошибок 1-го рода	$\bar{K}_{H_m}$
1	2	3	4	5	6
НСМ1	85,71%	10	1	9	26,16
НСМ2	85,71%	10	1	9	28,16
НСМ3	85,71%	10	1	9	28,16
НСМ4	85,71%	10	1	9	28,16
НСМ5	85,71%	10	1	9	28,16
НСМ7	85,71%	10	1	9	28,16
НСМ10	87,14%	9	1	8	28,83
Среднее на отфильтрованном ансамбле	85,91%	10	1	9	28

**Результат:** практически все сети (кроме №10) показали один и тот же результат. При этом ошибки идентификации наблюдаются в одних и тех же точках тестового множества. Этот результат можно объяснить тем, что при переходе к следующей итерации нейросетевое отображение «сжимает» невязку для  $\hat{y}$ , т.е. отображение (1) является сжимающим с коэффициентом «сжатия» примерно 14.

На рис. 2 показаны динамические кривые  $P(t)$  для семи строительных предприятий из исходной выборки, которые рассчитаны по финишной динамической нейросетевой модели (ДНСМ) банкротства из блока IV.

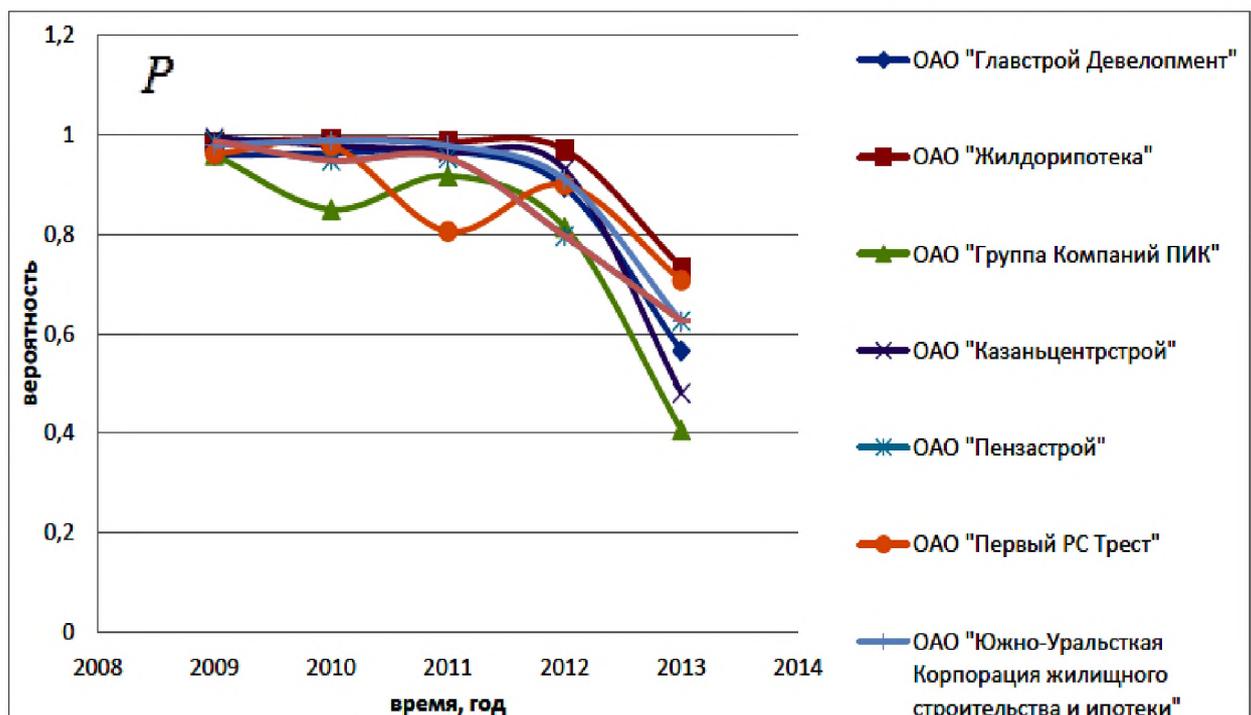


Рис.2. Динамика риска банкротства 7 строительных предприятий  
Fig.2. The dynamics of the risk of bankruptcy of construction companies 7



Видно, что динамические кривые  $P(t)$  информативны для целей анализа стадий развивающегося процесса кризиса предприятий и разработки управленческих решений по финансовому менеджменту в кредитных и иных финансовых технологиях.

### Заключение

Апробацию нейросетевой логистической динамической модели (НЛДМ) на реальных данных и байесовскую регуляризацию модели можно считать успешной.

По результатам можно сделать следующие выводы:

1) Наиболее положительную динамику выхода из банкротства имеет ОАО «Группа компаний ПИК». Так в 2009 г. вероятность риска банкротства этой группы компаний, рассчитанная по динамической модели НЛДМ составляла  $P = 0,9$ , что ассоциируется с завершающей стадией банкротства («хронический кризис»).

Однако принятые руководством этой группы компаний антикризисные меры оказались достаточно успешными, и к концу 2013 г. вероятность риска банкротства снизилась до величины  $P = 0,4$ , что ассоциируется со стадией «временной неплатежеспособности» в условиях которой компании могут сохранять свою жизнеспособность.

2) Разработанная нейросетевая динамическая модель банкротств обладает достаточной чувствительностью в том аспекте, что изменение факторов, введенных в модель, во времени  $t$  ( $x_j = \varphi_j(t), j = \overline{1,7}$ ) отображаются в динамические функции вероятности риска банкротства  $P(t)$ . Для различных предприятий из рисунка 3 кривые  $P(t)$  существенно различаются. В 2009 г. все 7 корпораций находились примерно в одинаковых условиях – они были близки к банкротству ( $P = 0,9 \dots 1,0$ ). Однако затем антикризисные меры действовали по-разному на развитие кризиса. Предприятие ОАО «ГК ПИК» и ОАО «Пензастрой» практически выбирались из кризиса (к 2013 вероятность риска банкротства снизилась до уровня  $0,4 \dots 0,43$ ), а у остальных корпораций эта вероятность была существенно выше ( $P = 0,6 \dots 0,79$ ), т.е. в этих предприятиях принятые антикризисные меры оказались недостаточными.

Таким образом, для построения качественной нейросетевой модели необходима предварительная подготовка (предобработка) данных, направленная на повышение их однородности, информативности и повышения качества обучения нейросетей в задачах, для которых характерны зашумление или сознательное искажение первичных данных.

### Список литературы

#### References

1. Борисов В.В., Круглов В.В., Федулов А.С. 2007. Нечеткие модели и сети: Монография. – М.: Горячая линия – Телеком, 2007. – 284 с.

Borisov V. V., Kruglov V. V., Fedulov A. S., 2007. Fuzzy models and networks: Monograph. – М.: Hot line – Telecom, 2007. – 284 p.

2. Горбатков С.А., Белолипцев И.И. 2013. Алгоритм построения гибридной нейросетевой модели восстановления скрытых в данных закономерностей в технических и экономических системах // Свидет. о госуд. регистрации электронного ресурса №19722. И.И. Белолипцев. – М.: Зарегистр. в ИНИПИ РАО ОФЕРН и О 2.12.2013. – 17 с.

Gorbatkow S. A., Beloliptsev I. 2013. Algorithm of constructing hybrid neural network model restoring hidden data patterns in technical and economic systems // Witnesses.. on GOVt. registration of an electronic resource No. 19722. I. I. Beloliptsev. – М: Reg. in INIPI RAO OVERN and On 2.12.2013. – 17 S.

3. Макеева Е.Ю. Горбатков С.А. 2014. О моделях диагностики банкротств организаций. // Менеджмент и бизнес-администрирование, 2014, №1. – С. 151-171.



Makeeva E. Y. Gorbatkow S. A. 2014. About the models of diagnostics of bankruptcy of organizations. // Management and business administration, 2014, No. 1. – S. 151-171.

4. Горбатков С.А., Полупанов Д.В., Макеева Е.Ю., Бирюков А.Н. 2012. Методологические основы разработки нейросетевых моделей экономических объектов в условиях неопределенности: Монография. – М.: Издательский дом «Экономическая газета», 2012. – 494 с.

Gorbatkow S. A., D. V. Polupanov, Makeeva E. Yu., Biryukov A. N. 2012. Metodologicheskie basis for the development of neural network models of economic objects in conditions of uncertainty: Monograph. – M.: Publishing house "Economic newspaper", 2012. – 494 s

5. Q Fin Analysis [Электронный ресурс] // Школа финансового анализа [Официальный сайт]. URL:<http://www.beintrend.ru/qfinanalysisfree>.

Q Fin Analysis [Electronic resource] // financial analysis School [Official website]. URL:<http://www.beintrend.ru/qfinanalysisfree>.

6. Макеева Е., Нететина Е. 2013. A binary model versus discriminant analysis relating to corporate bankruptcies: The Case of Russian Construction Industry // Journal of Accounting, Finance and Economics. - 2013. – Vol.3, No.1. – P.65-76.

Makeyev E., E. Netetina 2013. A binary model versus discriminant analysis relating to corporate bankruptcies: The Case of Russian Construction Industry // Journal of Accounting, Finance and Economics. - 2013. – Vol.3, No. 1. – P. 65-76.

7. Ясницкий Л.Н. 2016. Интеллектуальные системы. - М.: Лаборатория знаний, 2016. – 221 с.

L Yasnitsky.N. 2016. An intelligent system. - M.: Laboratoriya znaniy, 2016. – 221 p.

8. Miroljubova Tatiana, Alexander Biryukov. 2015. Spatial differentiation and market potential of regions of Russia. Asian Social Science. Toronto.: Canadian center of science and education , 2015.- Vol. 11, vol. 9, p. 96-117.

Miroljubova Tatiana, Alexander Biryukov. 2015. Spatial differentiation and market potential of regions of Russia. Asian Social Science. Toronto.: Canadian center of science and education , 2015.- Vol. 11, vol. 9, p. 96-117.

9. T. Holvoet and p. 2007. Valckenaers use of the environment for coordinating agent intentions // environments for multiagent systems III, Lecture on artificial intelligence, Springer Berlin et al. V. 4389 2007., PP. 51-66.

T. Holvoet and p. 2007. Valckenaers use of the environment for coordinating agent intentions // environments for multiagent systems III, Lecture on artificial intelligence, Springer Berlin et al. V. 4389 2007., PP. 51-66.

10. Xianjun research nor data mining based on neural networks 2008 // world Academy of science, engineering and technology. - 2008. - № 39. – P. 381-384.

Xianjun research nor data mining based on neural networks 2008 // world Academy of science, engineering and technology. - 2008. - № 39. – P. 381-384.