

Neurochips and Neuromorphic Computers: a Modelling Challenges

The complex of models needed for the development of current and future neurochips and neuromorphic computers based on them is presented. The complex of models includes models related to the development of neural network algorithms for solving problems, process models, associated with the construction of the basic elements of the circuitry, and circuit design model concepts realizing neurochips and functional elements.

Due to complexity of current and future neurochips and neuromorphic computers, it is necessary, before their creation, to develop their complex models for testing their basic features and functions. The combination in modern and future neurochips and neuromorphic computers such different technologies as memristors, analog CMOS, digital CMOS, optical, various techniques of development of neuroboards, neroblocks, neuroracks and superneurocomputers, makes it necessary to develop and use such complex models, CAD systems and elements libraries.

This article describes these models and give an explanation of the objective necessity of the implementation such software models on personal computers and GPU-supercomputers.

Keywords: neural networks, weights adjustment, neurochips, circuits design models

References

1. Galushkin A. I. *Sintez mnogosloynnykh sistem raspoznavaniya obrazov*. Moscow: Energiya, 1974.
2. Galushkin A. I. *Mnogosloynnyye sistemy raspoznavaniya obrazov*. Moscow: Izd. MIEM, 1968.
3. Galushkin A. I. *Neural networks theory*. Springer, 2007.
4. Galushkin A. I. *Neyronnyye seti: osnovy teorii*. Moscow: Goryachaya liniya — Telekom, 2010.
5. Rozenblatt F. *Printsiipy neyrodinamiki*. Moscow: Mir, 1963.
6. Dzhordan M. *Iskusstvennyy intellekt, bol'shiye dannyye i dezinformatsiya tekhnologiy*. ICloud.ru
7. *Analiticheskiye samonastroyayushchiyesya sistemy*. Pod red. V. V. Solodovnikova. Moscow: Mashinostroyeniye, 1965.
8. *Neyromatematika*. Ser. "Neyrokomp'yutery i ikh primeneniye". Kn. 6. Moscow: IPRZHR, 2002.
9. Galushkin A. I. *Neyrokomp'yutery*. Ser. "Neyrokomp'yutery i ikh primeneniye". Kn. 3. Moscow: IPRZHR, 2000.
10. Galushkin A. I. Na puti k neyrokomp'yuteram s ispol'zovaniyem memristorov, *Informatsionnyye tekhnologii*, 2014, no. 4, Prilozheniye, 32 p.
11. Galushkin A. I. Transp'yuternyye sistemy — nachalo stanovleniya v Rossii EVMs massovym paralelizmom, *Neyrokomp'yutery*, 2005, no. 3.
12. Qing Sun and all. Implementation Study of an Analog Spiking Neural Network for Assisting Cardiac Delay Prediction in Cardiac Resynchronization Therapy Device, *IEEE Trans. on Neural Networks*. June 2011, vol. 22, no. 6.
13. *Novyy chip uskorit obrabotku video v 1000 raz*. Sistemy videonablyudeniya. Prodolzheniye evolyutsii. Moscow, 4 dekabrya 2013 g. URL: <http://www.cnews.ru>, 16.08.2013.

УДК 338.27

С. А. Горбатков, доктор техн. наук, профессор, e-mail: sgorbatkov@mail.ru,
Финансовый университет при Правительстве РФ, Уфимский филиал, г. Уфа,
Л. И. Касимова, аспирант, клиентский менеджер, e-mail: liankakasimva@yandex.ru,
ОАО "Сбербанк России", Стерлитамакское отд., г. Стерлитамак

Нейросетевой итерационный метод построения динамических моделей вероятности риска банкротства при неполных данных

Предложен нейросетевой итерационный метод оценки вероятности развивающегося во времени риска банкротства экономических объектов применительно к сложным условиям моделирования (неполноты данных, их сильной зашумленности с неизвестным законом распределения шумов). Сделаны оценки сходимости метода для модели, полученной на реальных данных, на основе байесовского подхода к регуляризации модели.

Ключевые слова: диагностирование и прогнозирование банкротств, нейросеть, динамическая модель, логистическая трансформация вероятности

Введение

Математические модели оценки вероятности риска банкротств в настоящее время актуальны в связи со многими приложениями в реальном и финансовом секторах экономики. К ним относятся задачи оценки банкротств корпораций; оценки финансово-экономического положения партнеров в сделках; оценки инвестиционной привлекательности предприятий; обеспечения экономической безопасности предприятий путем постоянного мониторинга их финансового состояния; оценки банком кредитоспособности заемщиков; при выработке управленческих решений по налоговому регулированию (управлению) на местном уровне и во многих других экономических приложениях.

Методы моделирования оценки риска банкротств развивались, начиная с пионерских работ Альтмана (1968 г.) [1] и его последователей, где использовались различные версии линейных методов множественного дискриминантного анализа (MDA). Эти методы оказались практически неприменимыми для российских предприятий вследствие различия в законодательстве (инвестиции на Западе более защищены законодательством, чем в России), различия в стандартах бухгалтерской отчетности, отсутствия глубокой адаптации моделей банкротств для различных стран и отраслей экономики.

В связи с указанными причинами в России были предприняты многочисленные попытки совершенствования MDA — линейных моделей, а также появившихся в 1980 г. логистических моделей банкротств [2]. Бурное развитие в России в последнее 20-летие интеллектуальных информационных технологий, в частности нейросетевых [3], открыло принципиально новые возможности в следующих аспектах:

- учет сложной многофакторной нелинейной связи моделируемого показателя Y с вектором экономических показателей (факторов) анализируемого объекта и окружающей среды:

$$Y = \varphi(\mathbf{x}), \quad \mathbf{x} = (x_1, x_2, \dots, x_j, \dots, x_n), \quad (1)$$

где $\varphi(\cdot)$ — нелинейная функция;

- создание моделей банкротств в условиях сильного зашумления данных, отягченного их дефицитом.

Однако 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 позволяет в каждый момент времени определить стадию банкротства и применить упреждающие управляющие воздействия.

На пути создания динамических моделей риска банкротств предприятий возникают труднопреодолимые препятствия в виде неполноты данных. Суть проблемы заключается в следующем. Пусть имеются данные наблюдения вектора \mathbf{x} в несколь-

ких временных срезах $\{t_k\}$, $k = 1, 2, \dots, N$, т. е. известны значения всех факторов во временных срезах $\{x_{jk}\}$, $j = \overline{1, n}$, $k = \overline{1, N}$. Пусть обучающая выборка D содержит наблюдения для нескольких предприятий $\langle y_{gk}, \mathbf{x}_{gk} \rangle$, $g = \overline{1, G}$, где \langle, \rangle — знак кортежа, g — номер предприятия. При этом в последнем временном срезе ($k = N$), как правило, известны векторы значения факторов $\{\mathbf{x}_{gN}\}$, а также значения эндогенной (выходной) переменной $\{y_{gN}\}$, (метки "банкрот-небанкрот"). Это позволяет оценить вероятность риска банкротства в последнем временном срезе по формуле логистической трансформации риска банкротства:

$$P_{gN} = 1 / \lfloor 1 + \exp(-\hat{y}_g(\mathbf{x}_{gN})) \rfloor, \quad (2)$$

где \hat{y} — расчетное значение случайной величины Y в выражении (1).

При этом показатель экспоненты $\hat{y}(\mathbf{x}_{gN})$ в нашем исследовании является нелинейной функцией от вектора факторов \mathbf{x}_{gN} и аппроксимируется нейросетевой моделью [4].

Однако в других временных срезах $\{t_k\}$, $k \neq N$ известны только векторы факторов $\{\mathbf{x}_{gk}\}$, а значения эндогенной переменной $\{y_{gk}\}$ и, соответственно, вероятности $\{P_{gt_k}\}$ неизвестны, поскольку часть предприятий имеет промежуточную (неизвестную) стадию банкротства, которую по статистической модели вида (2), связывающей \mathbf{x} и P , определить не представляется возможным. Причиной этого является деформация связи (2) с течением времени во временных срезах $\{t_k\}$.

В итоге столбцы (либо строки) данных во временных срезах оказываются неполными и обучение нейросетевой динамической модели оценки риска банкротства невозможно.

В данной работе предлагается гибридный нейросетевой итерационный метод, суть которого основана на следующей идее. Будем считать, что нелинейная функциональная связь между \hat{y} и вектором \mathbf{x} в последнем временном срезе $t = N$ приближенно сохраняется ("наследуется") и в других временных срезах $\{t_k\}$, $k \neq N$. При таком допущении эндогенная переменная y_{gk} , $k = 1, 2, \dots, N - 1$ может быть восстановлена поочередно в каждом временном срезе подстановкой вектора \mathbf{x}_{gk} в обученную статическую нейросетевую модель вида (2). После этого данные становятся полными (комплектными), несущими в себе динамическую информацию через функции $\mathbf{x}_g(t_k)$ и $y_g(t_k)$, где временный аргумент t_k , $k = 1, 2, \dots, N - 1$ является дискретным.

Естественно, допущение о сохранении нелинейной зависимости $\hat{y}(\mathbf{x}_{gN})$ вида (1) во всех временных срезах вызывает определенную погрешность в оценке динамики риска банкротства, поэтому для уменьшения этой погрешности вводится специальный итерационный процесс исправления функции $\hat{y}(\mathbf{x}_g(t))$, в итоге которого мы получим

динамическую модель оценки риска банкротства с непрерывным временем $t \in [0; T]$, что и является целью исследования в работе.

1. Постановка задачи

Пусть известны неполные данные $D' \subset D$, где термин "неполноты" понимается в смысле отсутствия наблюдаемых значений эндогенной переменной $\{y_{kg}\}$ в части временных срезов для некоторых предприятий. Здесь D — гипотетически полные данные.

Требуется построить логистическую динамическую нейросетевую модель оценки вероятности риска банкротства вида

$$P(t) = 1/[1 + \exp(-\hat{y}(\mathbf{x}(t), t))], \quad (3)$$

где показатель экспоненты $\hat{y}(\mathbf{x}(t), t)$ восстанавливается по неполным данным D' с помощью нейросетевого отображения вида

$$\hat{y}(\mathbf{x}, t) = F(\mathbf{x}, \mathbf{W}, t_k). \quad (4)$$

Здесь оператор нейросетевого отображения

$$F: \mathbf{x} \in R^{(n+1)} \rightarrow \hat{y} \in R^{(1)}, \quad (5)$$

где $R^{(n+1)}$, $R^{(1)}$ — пространства действительных чисел размерности $(n+1)$ и 1 соответственно; \mathbf{W} — матрица параметров (синаптических весов) нейро-

сети; t — непрерывно изменяющееся время; t_k — дискретное время.

Поскольку требуемая нейросетевая модель (3) имеет четко выраженную прикладную направленность, то постановку задачи приблизим к реальным сложным условиям моделирования.

1. Помимо оговоренной неполноты данных и возникающей при этом неопределенности в оценке динамической ситуации риска банкротства, будем считать, что данные $D' \subset D$ сильно зашумлены (вплоть до сознательного искажения части данных, что может иметь место в бухгалтерской отчетности).

2. Априорный вид закона распределения шумов считается неизвестным.

3. Число наблюдений в выделенном кластере предприятий данного сектора экономики должно быть не менее двух-трех сотен.

В литературе такие сложные условия моделирования относят к классу задач с триадой "НЕ-факторов" (неполнота, неопределенность, неточность данных).

2. Описание алгоритма предлагаемого гибридного метода

Алгоритм метода (рис. 1) содержит два итерационных цикла:

- цикл внутренних итераций с индексом k , $k = 1, 2, \dots, N-1$, целью которых является восстано-

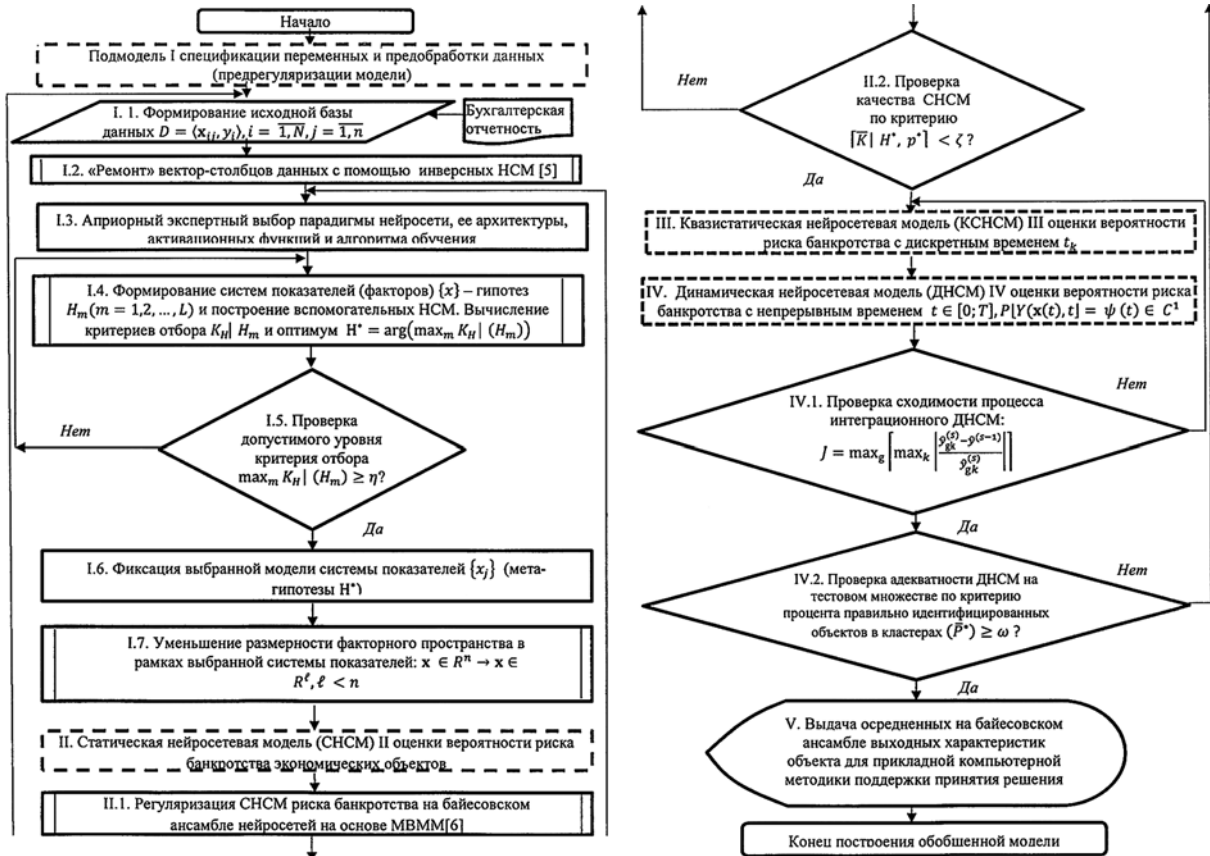


Рис. 1. Логическая схема алгоритма динамического метода оценки риска банкротства предприятий

ление эндогенной переменной $\{y_{gt_k}\}$ во временных срезах $\{t_k\}$;

- цикл внешних итераций с индексом $s = 1, 2, \dots$, целью которых является введение в нейросетевую модель вида (3) информации о времени и, соответственно, получение нейросетевой динамической модели с непрерывным временем.

Построение промежуточной квазистатической нейросетевой модели оценки риска банкротства (КНСМ). Опишем алгоритм предлагаемого итерационного метода по шагам.

Шаг 1 ($k = 1; s = 1$). Используя данные последнего временного среза ($t = N$), где известны вектор факторов x_{gN} и метки "банкрот" ($P_{gN} = 1$), "небанкрот" ($P_{gN} = 0$) для всех объектов $g \in \overline{1, G}$ и соответственно значения аргумента экспоненты \hat{y}_{gN} , строим статическую нейросетевую модель (НСМ) (2), например, типа многослойного перцептрона (MLP) с алгоритмом обучения типа "обратного распространения ошибки" (BP) [4] (далее кратко MLP-BP).

На первом шаге внешних итераций ($s = 1$) важно восстановить наиболее точно функциональную связь $Y(x)$, скрытую в данных, в сложных условиях триады "НЕ-факторов", оговоренных во введении к статье. От качества НСМ на первом шаге будет на последующих шагах зависеть качество восстановления динамических закономерностей $P(\hat{y}, t_k)$ во временных срезах $t_k, k = 1, 2, \dots, N - 1$. Поэтому применим для построения КНСМ модифицированный метод вложенных математических моделей (МВММ), подробно описанный в работах [5–7], который обеспечивает регуляризацию НСМ на основе байесовского подхода.

Поясним кратко суть процедуры регуляризации, основанной на парадигме сужения класса искомого решения обратной задачи восстановления зависимостей, скрытых в данных. В широко известной теории А. Н. Тихонова [8] решения обратных некорректных задач указанное "сужение" выполняется путем введения в алгоритм специального регуляризирующего (стабилизирующего) функционала А. Н. Тихонова, для построения которого требуется использование некоторой априорной информации об искомом решении обратной задачи. Чаще всего это информация о свойствах гладкости искомого решения. В данной статье используется та же парадигма "сужения", но другой подход (концепция) к реализации этой парадигмы, основанной на теории Байеса [5, 6]. Идея состоит в том, что оператор нейросетевого отображения (5) реализуется не на одной нейросети, а на байесовском ансамбле нейросетей, различающихся архитектурой, параметрами промежуточного слоя и видом активационных функций. После обучения ансамбля проводится фильтрация априорных гипотез — ней-

росетевых моделей по критерию качества объяснения данных, например:

$$P_q = (N_q^*/N) \geq \omega, \omega \in [0; 1]. \quad (6)$$

Здесь N_q^* — число точек тестового множества, где ошибка обобщения сети не превосходит заданного уровня ξ :

$$N_q^* = \{i_q^*\}: \delta_{q,i} = \left| \frac{y_i - \hat{y}_{qi}}{y_i} \right| \leq \xi; \\ q = \overline{1, Q}; i = \overline{1, N}. \quad (7)$$

В выражениях (6), (7) введены следующие обозначения: N — число точек тестового множества, которое должно быть одинаковым для всех нейросетей, входящих в байесовский ансамбль; q — номер нейросети в ансамбле; Q — число сетей в ансамбле; P_q — вероятный критерий приемлемого уровня качества объяснения данных, задаваемый параметрами ω и ξ , которые взаимосвязаны через прогностические свойства обученных нейросетей, т. е. $\omega = \rho(\xi)$, $\rho(\cdot)$ — некоторая непрерывная функция; i — номер наблюдения в данных; звездочка сверху означает, что эта величина прошла операцию фильтрации в алгоритме (6), (7).

Процедуры предобработки данных. Процедуры I.1–I.7 (см. рис. 1), входящие в МВММ, по сути, являются процедурами предобработки (предрегуляризации) исходных "сырых" данных, сформированных в блоке I.1 по стандартным данным бухгалтерской отчетности. Эти процедуры, кроме I.7, совпадают с аналогичными процедурами схемы КВММ из работы [6, рис. 3.5]. Общей концепцией предобработки (предрегуляризации) данных в блоках I.1–I.7 является последовательное (сверху вниз) сужение пространства переменных $[X \times Y]$ и, соответственно, повышение качества (однородности и информативности) данных.

Сделаем некоторые комментарии к процедурам I.4 и I.7, которые детально описаны в работах [5, 6]. Формирование систем показателей факторов в процедуре I.4 — это по существу формализованный оптимальный выбор по минимуму критерия K_{H_m} взвешенной суммы ошибок I и II рода идентификации объектов "банкрот—небанкрот". $\{H_m\}$ — это m -я априорная гипотеза (на уровне метагипотез) о подходящей традиционно сложившейся системе показателей (факторов) НСМ банкротств согласно квазيبайесовскому методу регуляризации нейросетевых моделей [6]. Критерий K_m отбора (фильтрации) указанных метагипотез имеет следующий вид:

$$K_{H_m} = N_{H_m}^* r_1 - N_{H_m}^1 r_2 - N_{H_m}^2 r_3, \quad (8)$$

где $N_{H_m}^*$ — число верно идентифицированных предпочтений для данной зафиксированной байесовской метагипотезы H_m ; $N_{H_m}^1, N_{H_m}^2$ — число ошибок пер-

вого и второго рода соответственно при идентификации; r_1, r_2, r_3 — удельные веса показателей в критерии (8), характеризующие их предпочтения, т. е. коэффициенты Фишберна [9]

$$r_i = \frac{2(n-i+1)}{(n+1)n}, \quad (9)$$

где n — число ранжируемых показателей, входящих в критерий (8). Формулу (9) можно использовать в случае [10], если множество показателей $N_{H_m}^*$; $N_{H_m}^1$, $N_{H_m}^2$ упорядочено в порядке убывания их предпочтения по значимости: $N_{H_m}^* > N_{H_m}^1 > N_{H_m}^2$.

В блоке I.7 применяется нейросетевой аналог известного метода "включения" факторов в регрессионную модель [11]. Для выбранной в блоке I.4 системы факторов H^* (мы использовали 16 показателей А. О. Недосекина [9, 10], разбитых на четыре группы: "рентабельность", "ликвидность", "деловая активность", "финансовая устойчивость"). Вначале выбрано по одному фактору из каждой группы и построены вспомогательные НСМ вида (2), (5). Затем на каждом шаге итераций добавлялось по одному новому фактору, выбранному случайно. После полного перебора факторов по индексу $p = \overline{1, 16}$ фиксируется тот оптимальный набор p^* , который соответствует при тестировании модели условию

$$p^* = \arg\left(\max_p K_{H_m p} | H^*\right). \quad (10)$$

Нам удалось сократить размерность факторного пространства с 16 до 6 без заметного снижения критерия (10), т. е. процента правильной идентификации объектов по банкротству.

В блоке III.1 осуществляется регуляризация статической нейросетевой модели (НСМ) оценки риска банкротства на байесовском ансамбле нейросетей на основе МВММ, подробно описанного в работах [5, 6]. Качество регуляризированной модели определяется критерием (10) в блоке III.2:

$$[\bar{K} | H^*, p^*] \geq \zeta,$$

где \bar{K} — усредненное на байесовском отфильтрованном ансамбле значение критерия (8).

В итоге шага 1 в блоке III.2 для фиксированного времени $t_k = T$ в последнем временном срезе мы получаем **статическую** логистическую нейросетевую модель (СЛНСМ) оценки риска банкротства вида (2), (11):

$$\hat{y}(\mathbf{x}) = F(\mathbf{x}, \mathbf{W}), \quad (11)$$

где $F(\cdot)$ — оператор нейросетевого отображения [12].

Квазистатический нейросетевой метод (КСНСМ) оценки риска банкротства с дискретным временем. Термин "квазистатический" здесь понимается в том смысле, что время в нейросетевой модели банкротства "почти учитывается" в

дискретной форме $\{t_k\}$, $k = \overline{1, N}$, но не более того. То есть квазистатическая модель НСМ не позволяет ни прогнозировать вероятность риска банкротства в промежутках времени между временными срезами, ни экстраполировать ее в будущее.

Шаг 2 ($k = 1, 2, \dots, N-1$; $s = 1$). Далее в блоке IV будем восстанавливать эндогенную переменную $\{y_{gk}\}$ в каждом временном срезе t_k во внутреннем итерационном цикле ($k = 1, 2, \dots, N-1$), используя статическую нейросетевую модель (2), (11), полученную на шаге $s = 1$ для каждого g -го предприятия, т. е. подставляя в правую часть (11) факторы $\mathbf{x}_{gk}(t_k)$ для каждого k -го временного среза.

Итогом этой процедуры является множество значений вероятностей риска банкротства во временных срезах:

$$P_g[\hat{y}(\mathbf{x}(t_k))] = 1/[1 + \exp(-\hat{y}(\mathbf{x}(t_k)))];$$

$$k = 1, 2, \dots, N-1; g = \overline{1, G}; \quad (12)$$

$$\{P_g(t_k)\}_{k=1}^{k=N} = P_{gt_1}, P_{gt_2}, \dots, P_{gt_N}. \quad (13)$$

Замечание 1. Модель (4), (5) (12), (13) — это уже квазистатическая нейросетевая модель оценки риска банкротства с логистической трансформацией вероятности (ЛКСНСМ) и дискретным временем $\{t_k\}$. Здесь уже можно приближенно оценивать стадии развивающегося процесса банкротства по вероятностям во временных срезах, $g = \overline{1, G}$.

На языке функционального анализа модель (11), (12) представляет собой композицию двух нелинейных операторов:

$$\mathbf{x} \in R^n \xrightarrow{\beta} P(t_k) \in M^N; \beta = A \circ F; k = \overline{1, N-1}, \quad (14)$$

где F — оператор нейросетевого отображения вида (11); A — оператор логистической трансформации вероятности вида (12); M^N — конечномерное пространство дискретных функций размерности N .

Динамический нейросетевой метод (ДНСМ) оценки вероятности риска банкротства с непрерывным временем.

Шаг 3 ($k = 1, 2, \dots, N-1$; $s = 2$). На шаге 3 в блоке V алгоритма мы переходим к внешним итерациям введения в динамическую модель непрерывного времени $t \in [0; T]$. Для этого в каждой НСМ в состав вектора факторов \mathbf{x} введем в качестве независимого нового фактора — время t :

$$\mathbf{x} = (x_1, x_2, \dots, x_j, \dots, x_n, x_{n+1} \equiv t). \quad (15)$$

Используя восстановленные данные, т. е. кортежи

$$\langle \hat{y}_{gk}, \mathbf{x}_{gk}, t_k \rangle, k = 1, 2, \dots, N-1, N, \quad (16)$$

обучаем заново и тестируем нейросеть:

$$\hat{y}(\mathbf{x}(t), t) = (F(\mathbf{x}(t), t, \mathbf{W})), \quad (17)$$

где в нейросетевой модели время t входит явно и является непрерывным. Значит модель (3), (17) можно в полной мере считать динамической, по-

Структура байесовского ансамбля нейросетей для статической модели

№ сети	Число скрытых слоев	Оптимальное число нейронов в скрытых слоях	Вид активационной функции в скрытых слоях
HCM1	1	7	Гиперболический тангенс
HCM2	1	6	Сигмоид
HCM3	2	14, 9	Гиперболический тангенс в обоих слоях
HCM4	2	14, 11	Гиперболический тангенс в первом слое, сигмоид — во втором слое
HCM5	2	8, 13	Сигмоид в первом слое, гиперболический тангенс во втором
HCM6	2	13, 12	Сигмоид в обоих слоях
HCM7	3	14, 13, 14	Гиперболический тангенс в первом и третьем слоях, сигмоид во втором слое
HCM8	3	8, 14, 12	Гиперболический тангенс во всех слоях
HCM9	3	12, 14, 10	Гиперболический тангенс во всех слоях
HCM10	3	14, 13, 15	Гиперболический тангенс во всех слоях

сколькx при обучении НСМ учитывается, что зависимость (1) "плывет" во времени. Причем можно получить информацию о вероятности риска банкротства, как во временных срезах, так и в любой точке между ними и, главное, экстраполировать ее на заданный горизонт прогноза. Следовательно, появляется возможность уточнения восстанавливаемых значений эндогенных переменных в кортежах:

$$y_{gk}^{(2)} = F(\mathbf{x}(t), t, \mathbf{W}^{(1)}), k = 1, 2, \dots, N - 1, \quad (18)$$

где синаптические веса $\mathbf{W}^{(1)}$ берутся из предыдущего шага внешних итераций ($s = 1$).

Шаг 4 ($k = 1, 2, \dots, N - 1; s = 3$). Заново обучаем ДНСМ с учетом новых восстановленных данных (18), т. е. реализуем шаги 2, 3 и т. д.

Критерий сходимости итерационного процесса по индексу s восстановления эндогенных переменных \hat{y}_{gk} и уточнения ДНСМ выбираем в виде

$$J = \max_g \left[\max_k \left| \frac{\hat{y}_{gk}^{(s)} - \hat{y}_{gk}^{(s-1)}}{\hat{y}_{gk}^{(s)}} \right| \right] \leq \alpha; \quad g = \overline{1, G}; k = \overline{1, N - 1}; s = 3, 4, \dots, \quad (19)$$

Затем критерий (6) усредняется на отфильтрованном ансамбле ДНСМ, вычисляется \bar{P}^* и проверяется условие адекватности модели в блоке V.2 на рис. 1.

Замечание 2. Вычислительный процесс построения ДНСМ является довольно трудоемким, поскольку восстанавливать приходится эндогенные переменные $\{y_{gk}^{(s)}\}$ на шагах 3, 4, ... для всех предприятий, входящих в данные, и во всех временных срезах. Это естественная плата за переход от квазистатической нейросетевой модели к динамической для данного сектора экономики и данного региона (страны). Зато последующее использование на практике ДНСМ довольно просто — оно сводится к постановке на вход обученной и верифицированной нейросети, единой для всего сектора модели, вектора $\mathbf{x}(t)$, факторов для анализируемого g -го объекта в интересующие моменты времени t .

Замечание 3. Основная ценность модели банкротства, получаемой с помощью ДНСМ, — это возможность получения качественного прогноза банкротства с информацией о стадиях его развития.

4. Количественные оценки построения динамической модели банкротств

Использовались реальные данные для строительных организаций из работы [9].

Этап 1 (Итерация 0). Исследовалась статическая нейросетевая модель (11) для фиксированного временного среза $t_k = t_5$. Был обучен и протестирован ансамбль из 10 сетей на выборке из 136 наблюдений. Результаты тестирования и структура сетей представлены в табл. 1 и 2.

Таблица 2

Результаты тестирования нейросетевых статических моделей, обучавшихся на данных за последний год ($t = 5$)

№ сети	Доля верно распознанных предприятий, %	Всего ошибок идентификации (банкрот—небанкрот)	Число ошибок 2-го рода	Число ошибок 1-го рода	Критерий K_{Hk}
HCM1	65,85	14	5	9	10,33
HCM2	80,49	8	5	3	14,33
HCM3	80,49	8	3	5	14,66
HCM4	78,05	9	5	4	13,66
HCM5	78,05	9	5	4	13,66
HCM6	85,37	6	3	3	16,00
HCM7	75,61	10	6	4	12,83
HCM8	82,93	7	3	4	15,33
HCM9	80,49	8	3	5	14,66
HCM10	78,05	9	3	6	14,00
Среднее на отфильтрованном ансамбле	85,37	6	3	3	16,00

После фильтрации обученным сетям, т. е. моделям (11), были предъявлены данные за предыдущие 4 года. Получены осредненные оценки величины Y для всех временных срезов $t = 1, 2, 3, 4$ согласно (12). Была сформирована общая выборка, состоящая из 680 наблюдений ($136 \cdot 5 = 680$).

Этап 2 (Внешняя итерация $s = 1$). В общую выборку был добавлен фактор времени (относительное время). Данные были разбиты на обучающее и тестовое множества следующим образом: 610 на-

Результаты тестирования байесовского ансамбля динамических нейросетевых моделей для первого шага внешних итераций ($s = 1$)

№ сети	Доля верно распознанных предприятий, %	Всего ошибок идентификации	Число ошибок 2-го рода	Число ошибок 1-го рода	Критерий K_{H_k}	Средняя на отфильтрованном ансамбле ошибка обобщения $\bar{\delta}$ по (7), %
HCM1	84,29	11	5	6	26,83	163
HCM2	85,71	10	1	9	28,16	173
HCM3	84,29	1	6	5	26,66	170
HCM4	88,57	8	4	4	29	172
HCM5	85,71	10	1	9	28,16	177
HCM6	71,43	20	0	20	21,66	171
HCM7	87,14	9	4	5	28,33	179
HCM8	80,0	14	3	11	25,16	191
HCM9	81,43	13	6	7	25,33	174
HCM10	85,71	10	3	7	27,83	178
Среднее на отфильтрованном ансамбле	87,14	9	3	6	28,5	

блюдений в обучающем множестве и 70 в тестовом. На этих данных был переобучен ансамбль нейросетей (оптимальное число нейронов в скрытых слоях подбирали заново). Результаты тестирования полученной модели (17) показаны в табл. 3.

Критерий фильтрации $K_{H_k} > 26$.

Оставшимся после фильтрации семи сетям (№ 1, 2, 3, 4, 5, 7, 10) были предъявлены данные и получены значения \hat{y} .

Дополнительно для каждой нейросети была рассчитана средняя относительная погрешность аппроксимации обучения по формуле

$$\bar{\delta} = \sum_{i=1}^{N_{learn}} \left| \frac{y_i - \hat{y}_i}{y_i} \cdot 100 \% \right| / N_{learn} \quad (20)$$

где N_{learn} — число наблюдений в обучающем множестве.

Этап 3 (Итерация $s = 2$). В данных значениях Y (показатель экспоненты) были заменены на значения \hat{y} , полученные на предыдущей итерации. Цикл обучения повторялся заново. Результаты показаны в табл. 4.

Результат. Практически процесс внешних итераций сошелся за два шага, все сети (кроме HCM 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 (4) является сжимающим [8]. Дополнительное "сжатие" реализует также логистическая функция (3).

Относительная погрешность также уменьшилась примерно в 2,5 раза.

Полученная динамическая модель с непрерывным временем позволяет достаточно точно отслеживать характерную динамику вероятности банкротства и своевременно принимать соответствующие управляющие воздействия. Для иллюстрации на рис. 2 приведены графики динамики вероятно-

Таблица 4

Результаты тестирования динамического байесовского ансамбля нейросетей, для второго шага внешних итераций ($s = 2$)


№ сети	Доля верно распознанных предприятий, %	Всего ошибок	Число ошибок 2-го рода	Число ошибок 1-го рода	K_{H_k}	$\bar{\delta}$, %
HCM1	85,71	10	1	9	26,16	63,37
HCM2	85,71	10	1	9	28,16	65,98
HCM3	85,71	10	1	9	28,16	78,92
HCM4	85,71	10	1	9	28,16	69,61
HCM5	85,71	10	1	9	28,16	66,38
HCM7	85,71	10	1	9	28,16	70,84
HCM10	87,14	9	1	8	28,83	70,03
Среднее на отфильтрованном ансамбле	85,91	10	1	9	28	

сти риска банкротств трех предприятий из выборки 136 предприятий строительных организаций [9].


Рис. 2, *a–в* соответствуют объектам из трех различных кластеров, где кластерообразующие признаки x входят в качестве аргумента в показатель экспоненты $\hat{y}(x, t)$ в логистическую функцию (3). Видно, что различие в признаках x трансформируется в динамических моделях в различие динамики риска банкротства. На рис. 2, *a* видно, что предприятие, близкое к банкротству в период с 2005 по 2008 г., благодаря принятым антикризисным мерам в 2009 г. улучшило свое финансово-экономическое состояние, и вероятность риска банкротства снизилась до 0,42.

Из рис. 2, *б* следует, что принятые антикризисные меры оказались недостаточно эффективными: вероятность риска банкротства оказалась к 2010 г. на высоком уровне ($P = 0,8$).


На рис. 2, *в* видно, что принимаемые антикризисные меры в период с 2008 г. по 2009 г. оказались



а)



б)



в)

Рис. 2. Динамика вероятности риска банкротств

недостаточными, и к 2010 г. предприятие обанкротилось.

Таким образом, вычислительные эксперименты подтвердили эффективность основной идеи разработки гибридного нейросетевого метода построения динамической модели банкротств с непрерывным временем, т. е. идеи восстановления динамической зависимости вероятности риска банкротств предприятий по неполным данным.

Заключение

Разработан динамический нейросетевой метод (ДНСМ) оценки банкротств, который может быть использован в широком спектре динамических прикладных задач оценки вероятности риска наступления нежелательных событий в экономических объектах применительно к условиям моделирования, приближенным к реальным (наличие триады "НЕ-факторов" — неполнота, неопределенность, неточность данных).

Достоинством предложенного метода, по мнению авторов, является принципиальная возможность оценивания на его основе интегрального показателя финансово-экономического состояния экономического объекта — вероятности риска банкротства — для любого момента времени (как между временными "срезами" в данных, так и для заданного горизонта прогноза).

Следовательно, появляется возможность текущего мониторинга стадий развивающегося кризиса объекта и принятия соответствующих упреждающих управленческих воздействий. Примером может служить реструктуризация кредиторской задолженности корпорации-заемщика.

Предложенный метод достаточно подробно проанализирован на реальных данных с точки зрения устойчивости (регуляризации) и адекватности получаемой нейросетевой модели.

По сути, имеются три ограничения для области применения ДНСМ.

1. В последнем временном срезе $t_N = T$ должны быть известны метки "банкрот—небанкрот" для эндогенной переменной ($P = 1$ либо $P = 0$).

2. Выборка должна содержать по крайней мере 200—300 наблюдений.

3. Среди наблюдений должны быть как предприятия "банкроты", так и предприятия "небанкроты" (примерно одинаковое число в последнем временном срезе $t_N = T$).

Традиционно используемые ограничения на вид закона распределения шумов в данных в нашей работе отсутствуют.

В качестве перспектив развития предложенного ДНСМ хотелось бы отметить разработку алгоритмов введения качественных факторов в вектор экзогенных переменных x в модели (17).

Список литературы

- Altman E. I. Financial ratios, discriminant analysis and the prediction of corporate bankruptcy // Journal of Finance. 1968. Vol. 23, N. 9. P. 589—609.
- Ohlson J. A. Financial Ratios and the Probabilistic Prediction of Bankruptcy // Journal of Accounting Research. 1980. N. 18 (1). P. 109—113.
- Галушкин А. И. Нейрокомпьютеры и их применение на рубеже тысячелетий в Китае. В 2-х томах. Том 1. М.: Горячая линия — Телеком, 2004. 367 с., Том 2. М.: Горячая линия — Телеком, 2004. 464 с.
- Галушкин А. И. Теория нейронных сетей. Кн. 1: учеб. пособие для вузов. М.: ИПРЖ, 2000. 416 с.
- Горбатков С. А., Фархиева С. А., Белолипец И. И. Обобщенная нейросетевая модель риска банкротства предприятия // XVI Всероссийская научно-техническая конференция "Информатика — 2014" 20: Сб. науч. трудов в 3-х частях. Ч. 3. М.: Изд-во НИЯУ МИФИ, 2013. С. 210—220.
- Горбатков С. А., Полупанов Д. В., Макеева Е. Ю., Бирюков А. Н. Методологические основы разработки нейросетевых моделей экономических объектов в условиях неопределенности / Под ред. С. А. Горбаткова. М.: ИД "Экономическая газета", 2012. 494 с.
- Горбатков С. А., Белолипец И. И., Фархиева С. А. Приближенный метод байесовской регуляризации и двухступенчатая оценка адекватности гибридной нейросетевой модели на

логового контроля // Научная сессия НИЯУ МИФИ-2011: XIII Всероссийская научно-техническая конференция "Нейроинформатика-2011", г. Москва, 24–28 января 2011 г.: Сб. научных трудов. М.: Изд-во МИФИ, 2011. С. 144–154.

8. **Тихонов А. Н., Арсенин В. Я.** Методы решения некорректных задач. М.: Наука. Физматлит, 1984. 288 с.

9. **Горбатков С. А., Белолыцев И. И., Makeeva E. Ю.** Выбор системы экономических показателей для диагностики и прогнозирования банкротств на основе байесовского подхода и интеллектуальных информационных технологий // Вестник Фи-

нансового университета при Правительстве РФ. 2013. № 4 (76). С. 50–62.

10. **Недосекин А. О.** Комплексная оценка риска банкротства корпорации на основе нечетких описаний. URL: <http://sedok.narod.ru/sc-group.html>.

11. **Горбатков С. А., Полуванов Д. В., Фархиева С. А., Коротнева М. В.** Эконометрика: учеб. пособие / Под. ред. С. А. Горбаткова. Уфа: Изд-во РИЦ БашГУ, 2012. 204 с.

12. **Хайкин С.** Нейронные сети: полный курс: учебник, 2-е изд.; пер. с англ. М.: Вильямс, 2006. 1104 с.

S. A. Gorbatkov, Professor of Mathematics and Computer Science

of the Ufa branch of the Financial University under the Government of the Russian Federation,

Doctor of Technical Sciences, e-mail: sgorbatkov@mail.ru,

L. I. Kasimova, Client Manager of "Sberbank of Russia. Sterlitamak branch", e-mail: liankakasimva@yandex.ru

Neural Network Iterative Method for Constructing Dynamic Models of the Probability of Bankruptcy Risk at Incomplete Data

The goal of this article is to develop the original iterative method of constructing dynamic model estimates the probability of the risk of bankruptcy for a wide range of facilities in the financial and real sectors of the economy. The models of this class are had the great theoretical interest due to their poor knowledge and interest for applications. These include the problem of estimating the developing stages in time the corporations bankruptcy; evaluation of the financial and economic situation of the partners in the transaction; evaluation of investment attractiveness of corporations; ensuring the economic security corporations through constant monitoring of their financial condition; decision support for the restructuring of credit debt of legal entities; making decisions on taxation, and in many other applications.

A key objective of the article is to restore the hidden dynamic patterns of development of the process of bankruptcy of an economic object in data with using an ensemble of neural networks. The data are incomplete: in general, the label "bankrupt — not bankrupt" contained not in all time cuts, but only in the final cut. The data sets are incomplete and very noisy with unknown noise distribution law. The main result of this paper is an original dynamic iterative neural network method (DINNM) of constructing predictive models of this class. To ensure the sustainability DINNM in such difficult modeling conditions develops a Bayesian approach to regularization neural network model. On the basis of real data for construction companies was conducted a series of computational experiments to substantiate the adequacy obtained dynamic model. The iterative process of restoring dynamic dependencies in DINNM converges in a few iterations with the discrepancy of a few percent.

Keywords: diagnostics and prediction of bankruptcy, neural network, dynamic logistic model, Bayesian regularization

References

1. **Altman E. I.** Financial ratios, discriminant analysis and the prediction of corporate bankruptcy, *Journal of Finance*, 1968, vol. 23, no. 9, pp. 589–609.

2. **Ohlson J. A.** Financial Ratios and the Probabilistic Prediction of Bankruptcy, *Journal of Accounting Research*, 1980, no. 18 (1), pp. 109–113.

3. **Galushkin A. I.** *Neurocomputeri i ich primeneniye na rubege tisyacheletij v Kitae*. V 2-h tomah. Vol. 1. Moscow, Gorjachaja linija-Telekom, 2004, 367 p., Vol. 2. Moscow, Gorjachaja linija-Telekom, 2004, 464 p.

4. **Galushkin A. I.** *Teoria neyronnyh setej*, Kn. 1, uchebn. posobie, Moscow, IPRY, 2000, 416 p.

5. **Gorbatkov S. A., Farhieva S. A., Belolipcev I. I.** Obobshhennaja nejrosetevaja model' riska bankrotstva predpriyatija // XVI Vserossijskaja nauchno-tehnicheskaja konferencija "Nejroinformatika-2014" 20: Sbornik nauchnyh trudov v 3-h chastjah. Ch. 3. — М.: NIJaU MIFI. 2013, s. 210–220.

6. **Gorbatkov S. A., Polupanov D. C., Makeeva E. Yu., A. Birjukov A. N.** *Metodologicheskiye osnovy razrabotki nejrosetevykh modelej jekonomiceskikh ob'ektov v uslovijah neopredelennosti*, pod red. S. A. Gor-

batkova, Moscow, Izdatel'skij dom "Jekonomicheskaja gazeta", 2012. 494 p.

7. **Gorbatkov S. A., Belolipcev I. I., Farhieva S. A.** Priblizhennyj metod bajesovskoy reguljarizacii i ddvuhstupenchataja ocenka adekvatnosti gibridnoj neyrosetevoj modeli nalogovogo kontrolja // Nauchnaja sessija NIJaU MIFI-2011: XIII Vserossijskaja nauchno-tehnicheskaja konferencija "Nejroinformatika-2011": Sb. nauchnyh trudov, Moscow, MIFI, 2011, pp. 144–154.

8. **Tihonov A. N., Arsenin V. Ja.** *Metody reshenija nekorrektnykh zadach*. Moscow, Nauka, Fizmatlit, 1986, 288 p.

9. **Gorbatkov S. A., Belolipcev I. I., Makeeva E. Ju.** Vybor sistemy jekonomiceskikh pokazatelej dlja diagnostiki i prognosirovanija bankrotstv na osnove bajesovskogo podhoda i intellektual'nyh informacionnyh tehnologij, *Vestnik Finansovogo Universiteta pri Pravitel'stve RF*, 2013, № 4 (76), pp. 50–62.

10. **Nedosekin A. O.** *Kompleksnaja ocenka riska bankrotstva korporacij na osnove nechetkih opesaniy*, URL: <http://sedok.narod.ru/sc-group.html>.

11. **Gorbatkov S. A., Polupanov D. V., Farhieva S. A., Korotneva M. V.** *Jekonometrika*: Ucheb. posobie, Ed. S. A. Gorbatkov, Ufa, Izd-vo RIC BashGU, 2012, 204 p.

12. **Haykin S.** *Nejronnye seti*: polnyj kurs: Uchebnik, 2-e izd., Per. s angl., Moscow, Vil'jams, 2006, 1104 p.