

Вестник Евразийской науки / The Eurasian Scientific Journal <https://esj.today>

2020, №3, Том 12 / 2020, No 3, Vol 12 <https://esj.today/issue-3-2020.html>

URL статьи: <https://esj.today/PDF/42ECVN320.pdf>

Ссылка для цитирования этой статьи:

Горбатков С.А., Фархиева С.А. Гибридный метод структурного синтеза и регуляризации нейросетевой динамической модели банкротств корпораций // Вестник Евразийской науки, 2020 №3, <https://esj.today/PDF/42ECVN320.pdf> (доступ свободный). Загл. с экрана. Яз. рус., англ.

For citation:

Gorbatkov S.A., Farkhieva S.A. (2020). Hybrid method of structural synthesis and regularization of a neural network dynamic model of corporate bankruptcies. *The Eurasian Scientific Journal*, [online] 3(12). Available at: <https://esj.today/PDF/42ECVN320.pdf> (in Russian)

УДК 378.675

ГРНТИ 28.23.24

Горбатков Станислав Анатольевич

ФГОБУ ВО «Финансовый университет при Правительстве Российской Федерации»
Филиал в г. Уфа, Уфа, Россия

Профессор кафедры «Математика и информатика»

Доктор технических наук, профессор

E-mail: sgorbatkov@mail.ru

РИНЦ: https://elibrary.ru/author_profile.asp?id=158740

SCOPUS: <https://www.scopus.com/authid/detail.url?authorId=8646868800>

Фархиева Светлана Анатольевна

ФГОБУ ВО «Финансовый университет при Правительстве Российской Федерации»

Филиал в г. Уфа, Уфа, Россия

Заведующий кафедрой «Математика и информатика»

Кандидат технических наук

E-mail: ok-xi@yandex.ru

РИНЦ: https://elibrary.ru/author_profile.asp?id=567037

Гибридный метод структурного синтеза и регуляризации нейросетевой динамической модели банкротств корпораций

Аннотация. Объектом исследования являются задачи финансового менеджмента, в частности задачи прогноза стадий развивающегося банкротства корпораций-заемщиков и принятия решений по реструктуризации кредитной задолженности. Решение подобных задач важно также для оценки платежеспособности контрагентов в сделках, решения вопросов о незаконности банкротств, экономической безопасности и в других сферах экономики.

Предмет исследования – разработка в условиях высокой неопределенности и зашумленности данных динамической модели банкротств с непрерывным временем, позволяющей диагностировать стадии банкротства моделируемого объекта в любой момент времени (между «временными срезами» в данных), а также прогнозировать вероятность банкротства по времени вперед для заданного горизонта. Под неопределенностью понимается специфическая характеристика моделируемого класса динамических задач банкротств – неполнота и неопределенность в данных: в обучающей выборке во «временных срезах» ретроспективных данных, по которым строится модель, обычно указываются только граничные значения вероятности банкротства ($P = 0$ либо $P = 1$), т. е. отсутствует информация о промежуточных значениях P в интервале $[0; 1]$. Неопределенность обусловлена юридическими

причинами: пока корпорация не признана банкротом арбитражным судом, либо налоговыми органами, либо по собственному заявлению для нее $P = 0$, хотя объективные данные бухгалтерской отчетности могут показывать близость к банкротству.

Целью исследования является разработка научно обоснованного подхода к синтезу структуры динамической нейросети, способной эффективно работать в сложных условиях моделирования.

Ключевые слова: нейросеть; алгоритм оптимального отбора факторов; концептуальный базис; компрессия факторов в кластерах; функция Харрингтона; динамическая модель банкротств; регуляризация модели; интегрированная со структурным синтезом; тестирование; адекватность модели

Введение

В российской и зарубежной практике для оценки риска возникновения банкротства рассчитываются показатели платежеспособности и финансовой устойчивости. В соответствии с методическими указаниями по проведению анализа финансового состояния организаций данные показатели относятся к показателям первого класса и имеют соответствующие нормативные значения. Несмотря на то, что анализ показателей платежеспособности и финансовой устойчивости проводится в сравнении полученных данных в динамике и в сравнении с нормативами, дать объективную оценку не всегда представляется возможным. Так как периодичность формирования такой отчетности составляет 12 месяцев, то на получение достоверных данных в строительной отрасли влияет множество изменяющихся в течение года факторов, в том числе и неопределенностей различного рода, неучтенных в отчетах.

Применительно к деятельности современных финансово-экономических объектов, в которых имеет место отмеченная выше неопределенность в характеристиках этих объектов и условиях их функционирования, построение динамической модели банкротств не может быть выполнено известными методами диагностики банкротств, основанными на использовании: Z-счета Альтмана и различных модификациях этого метода за рубежом и в России, подробный обзор которых приведен в монографиях авторов статьи [1–3]. Парировать проявления неопределенностей в процессе функционирования моделируемых объектов в рамках используемой ретроспективной обучающей выборки можно только в адаптивной (интеллектуальной) модели, имеющей средства оперативной подстройки параметров модели к изменяющейся текущей ситуации. Здесь хорошо подходят интеллектуальные нейросетевые методы [1–4].

Однако эффективное применение нейросетевых методов для построения динамических моделей банкротств непосредственно к исходным «сырым» данным вряд ли возможно. Необходима разработать формализованную процедуру структурирования обучающей выборки и оптимального отбора факторов, а также их последующей компрессии.

Другими словами, под информативностью обучающего набора данных будем понимать требование адекватного отражения в упорядоченных наборах (кортежах)

$$(y_{g,t}; \vec{x}_{g,t}), g \in \overline{1, G}; t \in [t_0, T]; \vec{x} = (x_1, \dots, x_j, \dots, x_n) \in X \quad (1)$$

закономерностей «вход-выход» моделируемых объектов, которые нужно восстановить с помощью НСМ. Здесь $y_{g,t}$ – значение выхода НСМ для g -го объекта в момент времени t ; $\vec{x}_{g,t}$ – значения вектора факторов на входе модели; t_0 – значальный момент времени; T – ретроспективный период наблюдения при формировании данных; X – пространство количественных и качественных факторов. Помимо указанного требования «адекватного

отражения» необходимо выполнение требования достаточности объема данных, содержащихся в наборе, для обучения и тестирования НСМ, которая с требуемым уровнем точности могла бы воспроизводить поведение динамической системы (ДС) во всей области возможных значений для моделируемой обобщенной характеристики – вероятности банкротства $P(y(\vec{x}(t))) \in [0; 1]$.

Вопросы отбора факторов при формировании обучающих выборок для динамических НСМ исследованы мало, точнее среди нескольких сотен работ по банкротствам, обзор которых приведен в [1; 2], не выработан теоретически обоснованный общий подход (концепция) к формированию факторного пространства. Исключения составляют работы С.А. Шумского [5], где на основе информационного критерия Кулбака-Лейблера сделан важный обобщенный теоретический вывод: чем короче суммарная длина описания данных и модели (и соответственно число переменных в модели), тем лучше обобщающая способность НСМ, т. е. её прогностические свойства. С точки зрения этой рекомендации рационально в первоначальной экспертно сформированной системе факторов провести оптимальный отбор, а затем выполнить операцию компрессии факторов [6], если их число слишком велико, например, более 50.

Широко известен факт зависимости всех характеристик разрабатываемой нейросетевой модели (НСМ) от ее структуры, особенно от числа скрытых слоев и степени связности структуры. Известны разные приближенные, итерационные подходы к проблеме синтеза рациональной структуры нейросети в основном на базе минимизации среднего экспериментального риска [7]. Однако формализованный математический метод решения этой проблемы до сих пор не разработан.

Важным и малоисследованным вопросом построения динамической НСМ банкротств является также обоснование адекватности модели и регуляризации её обучения в сложных условиях неполноты данных, отмеченной выше, и отсутствии априорных сведений о виде закона распределения шумов измерений в данных. Здесь авторы статьи сознательно отказываются от стеснения разрабатываемой модели допущением о каком-либо виде закона распределения шумов, подобно [5], что приближает нашу модель к практике.

Исследование указанных выше малоизученных вопросов разработки методов построения нейросетевой динамической модели банкротств в сложных условиях неопределенности данных и послужило посылком к написанию данной статьи.

1. Постановка задачи исследования

Рассмотрим подробнее проблему неполноты и неопределенности данных, специфическую для задач банкротств. Данные обычно формируются в виде «временных срезов» (1), в которых $t = t_0, t_1, t_2, \dots, t_N$, где N – количество срезов за ретроспективный период наблюдения каждого g -го объекта финансового менеджмента. При этом, как отмечалось выше, во временных срезах указываются только граничные точки диапазона возможных значений вероятности банкротства корпорации-заемщика: $P = 1$ (корпорация «банкрот») и $P = 0$ (корпорация-«небанкрот»). Отсутствует информация о промежуточных значениях P в интервале $[0; 1]$, которые характеризуют различные стадии развивающегося процесса банкротства корпорации. Неполнота данных во временных срезах взаимосвязана с неопределенностью, вызванной юридическими причинами, отмеченными выше. При этом в модель вносится искусственная «несимметрия»: информация о признании банкротства корпорации является достаточно достоверной, но информация о присвоении метки «небанкрот» ($P = 0$) содержит высокую степень неопределенности, вызываемой деформацией модели юридическими особенностями процедуры банкротства.

Пусть имеются ретроспективные данные вида (1). При этом в последнем временном срезе ($k=N$) обычно известны как векторы значения факторов $\{\vec{x}_{gN}\}$, так и значения выходной переменной $y = \arg(P(\vec{x}_{gN}, t_N))$. Это позволяет обучить НС и оценить вероятность банкротства P в последнем временном срезе ($t = t_N$). Однако для части предшествующих временных срезов (t_1, t_2, \dots, t_{N-1}) значения выходной (эндогенной) переменной $y_{gk} = \arg(P(X_{gk}, t_k))$, $k = \overline{1, N-1}$ могут быть неизвестны, поскольку к моменту $t \leq t_N$ в некоторых из корпораций-заемщиков процесс кризиса развивается и они еще не признаны банкротами.

Отсюда вывод: независимо от применяемого метода построения модели банкротств, негативное проявление отмеченной неполноты, неопределенности и несимметрии информации в данных нужно каким-то способом устранить, либо, по крайней мере, существенно ослабить. Этот вывод и лег в основную идею предлагаемого итерационного НЛДМ.

Теперь изложим информационно-математическую постановку задачи исследования. Будем рассматривать обратную задачу (ОЗ) восстановления зависимости вероятности банкротства P от вектора экзогенных переменных \vec{x} , скрытой в данных. Эту зависимость будем определять в виде логистической функции, предложенной Ольсоном [8]:

$$P(t) = 1/[1 + \exp(-\hat{y}(\vec{x}(t), t))], P \in [0; 1]. \quad (2)$$

Показатель экспоненты $\hat{y}(\vec{x}(t), t)$, играющий роль аргумента в (2), восстанавливается с помощью нейросетевого (НС) отображения из данных:

$$\hat{y}(\vec{x}, t) = F(\vec{x}, W, t); F: \vec{x} \in R^{(n)} \rightarrow \hat{y} \in R^{(1)}, \quad (3)$$

где W – множество синаптических весов и смещений в нейронах; $F(\cdot)$ – оператор НС-отображения; $R^{(n)}$ – n -мерное факторное пространство вещественных чисел; $R^{(1)}$ – одномерное пространство аргументов функции (2).

Отметим важную для построения динамической НС-модели особенность логистической функции: отображение (2) является сжимающим в том смысле, что интервал для аргумента функции (2) $\hat{y}(\vec{x}, t) \in [-6; 6]$ отображается в соответствующий интервал значения функции $P \in [0; 1]$, т. е. коэффициент сжатия составляет примерно 12. Следовательно, если НСМ (2)–(3) уже обучена, протестирована и проэкзаменована, то ошибки в задании вектора факторов \vec{x} будут «уменьшаться» оператором логистического отображения (2) при вычислении вероятности P . Однако для нейросетевой модели (3) задача обучения сети, т. е. нахождения синаптических весов W нейросети, является ОЗ, некорректно поставленной по Адамару [10], поэтому требует специальных мер по регуляризации ее решения, что отмечалось в работах авторов [1; 2]. В данной статье на основе байесовского подхода подробно изложен оригинальный алгоритм регуляризации, интегрированной с синтезом рациональной структуры нейросети (НС) и одновременным выбором функций активации в промежуточных слоях. Этот результат и является центральным в статье (см. ниже).

2. Концептуальный базис и нейросетевой логистический динамический метод построения модели банкротств

В качестве концептуального базиса как методологической основы построения динамической модели банкротств разработано три концепции:

Концепция 1: Носителем косвенной, но достаточно достоверной информации о динамике процесса банкротства в системе финансового менеджмента, т. е. в выделенном кластере корпораций-заемщиков, является множество экзогенных переменных (факторов)

$\{\vec{x}_{g,t}\}$, изменяющихся во времени ($g \in \overline{1, G}, t \in [t_k, t_N]$). Причем информация $\{\vec{x}_{g,t}\}$ заранее известна во всех временных срезах данных, т. е. является полной.

Концепция 2: Используя закон временной инерции объектов финансового менеджмента, можно с помощью специально построенных итерационных процедур извлекать с помощью нейросети знания о динамике процесса из указанной в концепции 1 косвенной информации, содержащейся во временных срезах факторов $\{\vec{x}_g, t_k\}$, $k=1, 2, \dots, N$, и восстанавливать неполную, неопределенную и несимметричную информацию о значениях эндогенной переменной $\{y_g, t_k\}$ во временных срезах.

Концепция 3: На основе общесистемного закона уменьшения энтропии при объединении рационально взаимодействующих подсистем в общую систему предлагается концепция регуляризации нейросетевой динамической модели банкротств, отличающаяся введением в байесовский ансамбль нейросетей с различными структурами и различными активационными функциями, с последующей апостериорной фильтрацией этих структур по прямому критерию числа ошибок идентификации НСМ на тестовом множестве и затем осреднением расчетных характеристик на отфильтрованных сетях. Достижимый эмерджентный эффект – формализованное получение одновременно с регуляризацией модели рациональных структур нейросети вида активационных структур нейросети и вида активационных функций, т. е. синтез структуры НС.

Рассмотрим теперь конкретный алгоритм НЛДМ, реализующий концепции 1, 2, 3 и включающий в себя четыре подзадачи:

- А. Формализации и оптимизации отбора факторов для формирования обучающей выборки.
- Б. Изучения возможности эффективного использования в построении НСМ банкротств агрегирующих обобщенных функций желательности Харрингтона [6].
- В. Восстановления во временных срезах данных неполной, неопределенной и несимметричной информации о значениях эндогенных переменных $\{y_g, t_k\}$ во всех временных срезах $t_k = t_1, t_2, \dots, t_N$.
- Г. Разработки алгоритма регуляризации решения обратной задачи обучения НС, интегрированным с формализованным выбором структуры НС и активационных функций в промежуточных слоях.

Алгоритмы решения подзадач А, Б и В подробно изложены в работах авторов [1–3]. Поэтому на этих подзадачах подробно останавливаться не будем, а основное внимание уделим подзадаче Г, которая ранее нигде не рассматривалась.

3. Алгоритм решения подзадачи Г

Пусть в ретроспективной выборке данных образованы достаточно однородные кластеры, причем в критерий группировки входят только значимые факторы согласно решению подзадачи А из [6].

Алгоритм решения подзадачи В реализуется введением двух итерационных циклов, реализующих концепции 1 и 2: «внешних» итераций по индексу k -номеру временного «среза», которые служат для восстановления неполных данных во временных срезах; «внутренних» итераций по индексу m , которые служат для коррекции ошибок восстановления данных, т. е. более «тонкой» настройки динамической НСМ.

Внешние итерации реализуются по формулам:

$$F^{(k-1)}(\vec{x}_{k-1}, W_k, s) \approx F^{(k)}(\vec{x}_k, W_k, s) \Rightarrow \hat{y}_{k-1,g} \approx F^{(k)}(\vec{x}_{g,k-1}, W_k, s), \quad (4)$$

$$\varepsilon = \max_{g \in 1, G} |y_{g,k-1} - F^{(k)}(\vec{x}_{g,k-1}, W_k, s)|; \varepsilon > 0, \quad (5)$$

где $F(\cdot)$ – нейросетевое отображение вида (3); $k = N-1, N-2, \dots, 1$; ε – ошибка восстановления данных.

Другими словами, в качестве НСМ для среза $(k - 1)$ используется уже обученная и протестированная сеть, полученная в предыдущем срезе $k = N$ и т. д.

Внутренние итерации по индексу m служат для уменьшения ошибки ε в (5) и используют уже полные (восстановленные) данные:

$$\{\hat{y}_{g,k}^{(m)}(\vec{x}_{g,k}) = F^{(m)}(\vec{x}_{g,k}, W^{(m)}, s)\}; m = 1, 2, \dots, k, \dots, N. \quad (6)$$

Замечание. При высоких требованиях к качеству прогноза можно организовать несколько прогонов по индексу m в (6).

Критерием остановки итераций коррекции ε из (9)–(10) служит условие стабилизации восстановленных значений $\{\hat{y}_{g,k}^{(m)}\}$:

$$I^{(m)} = \max_{m \in 1, N} \left\{ \max_{k, m \in 1, G} \left[\frac{\hat{y}_{g,k}^{(m)}(\vec{x}_{g,k}) - \hat{y}_{g,k}^{(m-1)}(\vec{x}_{g,k})}{\hat{y}_{g,k}^{(m)}(\vec{x}_{g,k})} \right] \right\} \leq \xi, m = 1, 2, \dots, N. \quad (7)$$

На практике обычно достаточно 1...2 прогона «вперед-назад» в (7).

Теперь изложим предлагаемый алгоритм регуляризации НСМ, интегрированный со структурным синтезом сети на основе концепции 3, который использует ту же парадигму регуляризации решения ОЗ, что и в теории А.Н. Тихонова [10] – это сужение пространства искомых решений $Z' \subset Z$, где Z' – некоторый «компакт». Однако способ сужения Z до компакта Z' в нашем случае другой, отличный от построения стабилизаторов Тихонова.

- За счет механизма апостериорной фильтрации нейросетей – гипотез $\{h_q\}$ построенных на рационально отобранных структурах сетей, на байесовском ансамбле и последующего усреднения характеристик модели на отфильтрованном ансамбле.
- За счет оптимального отбора факторов и их агрегирования в подзадачах А и Б.

4. Результаты количественных оценок

Вначале укажем общие моменты организации вычислительных экспериментов. В качестве исходных данных D использовали ретроспективные данные корпораций-заемщиков одной из наиболее распространенных отраслей экономики – строительной отрасли, полученные фирмой «Bereua Van Dijk» [10]. База данных содержала 136 наблюдений. Использовалась система из 15 удельных показателей, широко применяемых в задачах оценки банкротств [1]: L_1 – быстрый коэффициент ликвидности; L_2 – коэффициент покрытия запасов; P_1 – текущий коэффициент ликвидности; F_1 – коэффициент финансовой зависимости; F_2 – коэффициент автономии собственных средств; F_3 – обеспеченность запасов собственными оборотными средствами; F_4 – индекс постоянного актива; R_1 – общая рентабельность; R_2 – рентабельность активов; R_3 – рентабельность собственного капитала; R_5 – рентабельность оборотных активов; A_2 – оборачиваемость активов; A_4 – оборачиваемость кредиторской

задолженности; A_5 – оборачиваемость дебиторской задолженности; A_6 – оборачиваемость запасов.

Формулы для расчета этих удельных показателей содержатся в работах [2–4] и оперируют с данными стандартной бухгалтерской отчетности.

Был реализован алгоритм из [6] оптимального отбора факторов с применением регуляризации на байесовском ансамбле вспомогательных нейросетевых моделях (ВНСМ). Характеристики ансамбля: метагипотеза Ω – MLP-BP, реализованная на программном продукте NeuroSolutions 5.0 (демоверсия). Из исходных 15 факторов были отобраны 11 факторов, соответствующих значениям $\bar{\Theta} \leq 0,0444$, т. е. средней ошибке идентификации на ансамбле ВНСМ, равной 4,44 %:

$$\Theta_{qj} = (N^{(I)} / N) + (N^{(II)} / N); \bar{\Theta}_j = [\sum_{q=1}^{Q^*} \Theta_{qj}] / N, j = \overline{1, n}. \quad (8)$$

Здесь Θ – критерий качества идентификации примеров тестового множества с помощью ансамбля (ВНСМ); j – номер фактора; q – номер ВНСМ в ансамбле; $N^{(I)}, N^{(II)}$ – число ошибок I и II рода при идентификации объектов тестовой выборки; N – общее число объектов.

Замечание. При решении задачи формализованного выбора структуры «рабочей» НСМ (после отбора факторов), интегрированного с регуляризацией НСМ на байесовском ансамбле, использовался тот же прямой критерий качества синтеза структуры вида (8) и активационные функции (гиперболический тангенс и сигмоида) в скрытых слоях сети:

$$f(s) = th(bs), b > 0; f(s) = 1/[1 + \exp(-as)], a, b > 0. \quad (9)$$

где S – состояние нейронов. Правило отбора рациональной структуры НС: $St^*: \Theta_q \leq \eta$; где η – заданное малое число, например 0,01; звездочка означает, что данная структура успешно прошла фильтрацию.

В таблице 1 представлены байесовский ансамбль анализируемых НС – структур.

Таблица 1

Байесовский ансамбль НСМ

№ НСМ	Число скрытых слоев	Вид активационной функции в скрытых слоях
1	1	(9)
2	2	(9) в обоих слоях
3	2	(9) в первом слое, (10) – во втором слое
4	1	(10)
5	2	(10) в обоих слоях
6	2	(10) в первом слое, (9) – во втором слое

Получено авторами статьи

Таблица 1 соответствует оптимальному набору 11 факторов в итоге решения задачи А: $L_1, L_2, F_1, F_2, R_1, R_2, R_3, A_2, A_4, A_6$. Была отсеяна структура ансамбля №2 при $\bar{\Theta}_2 = 0,166 > \eta = 0,01$. Принятый уровень $\eta = 0,1$ составляет 90%-ой правильной идентификации тестовой выборки.

5. Оценка сходимости итерационных процессов восстановления эндогенных переменных и корректировки восстановленных значений

Для предложенного НЛДМ построения динамической модели банкротства вопрос сходимости итерационных процессов (4)–(5) является центральным. Данные оценки сходимости этих процессов показаны на рис. 1.

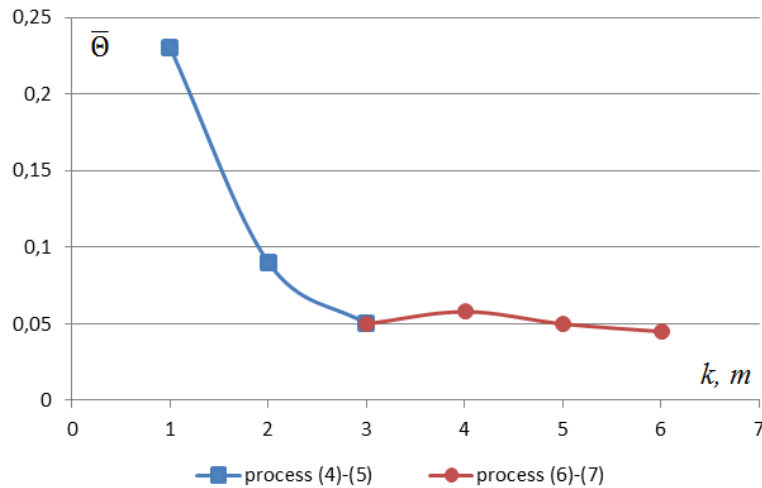


Рисунок 1. Изменение критерия качества $\bar{\Theta}$ идентификации объектов по шагам k процесса (4)–(5) и по шагам m процесса (6)–(7) (рисунок получен авторами статьи)

Из рис. 1 видно, что рекуррентный итерационный процесс (4)–(5) восстановления эндогенных переменных $\{\hat{y}_{g,k}\}$ при движении от временного среза $k = 5$ к срезу $k = 3$ приводит к улучшению критерия качества (8) с $\bar{\Theta} = 0,2417$ до 0,05, т. е. в 4,83 раза. Следовательно, качество восстановления эндогенных переменных $\{\hat{y}_{g,k}\}$ по финишному критерию $\bar{\Theta}$ из (8) является весьма высоким.

Последующие итерации $m = 4, 5$ и 6 на рис. 1 соответствуют процессу коррекции ε по (6)–(7). Здесь сходимость носит колебательный характер с невязкой между шагами итераций, не превышающей 0,0276. Причиной колеблемости $\Delta\bar{\Theta}$ невязки с малыми отклонениями порядка 2,76 % авторы статьи считают «неулучшаемую» зашумленность обучающей выборки данных.

Таким образом, вычислительные эксперименты по сходимости процесса восстановления эндогенных переменных (4)–(5) и дальнейшей их коррекции (6)–(7) подтвердили работоспособность предложенных концепций 1, 2 и 3 построения НЛДМ банкротств.

Оценки изменения вероятности банкротства P во времени t , рассчитанные по НЛДМ для 7 строительных компаний по данным из [1], показаны на рис. 2.

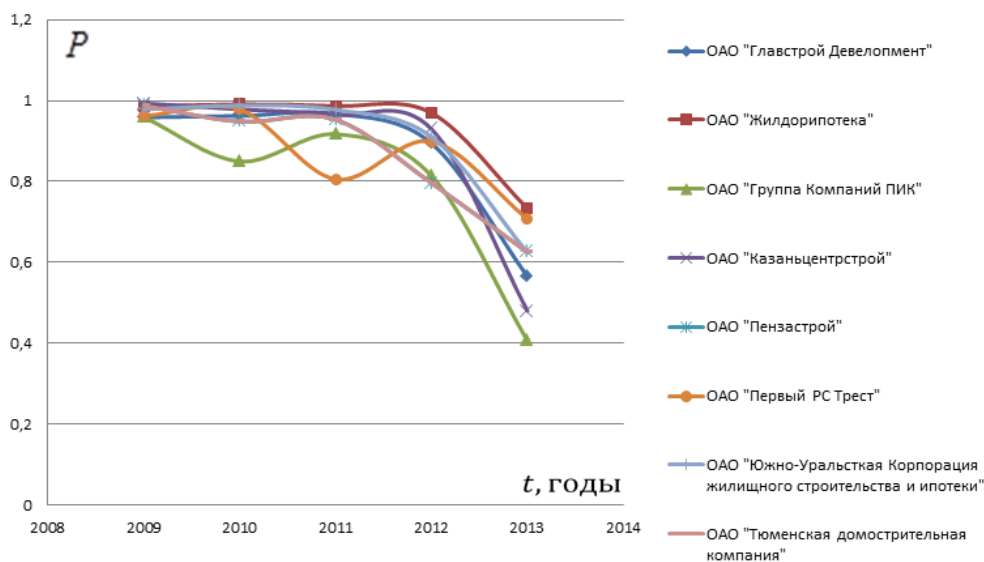


Рисунок 2. Динамика вероятности банкротства корпораций (рисунок получен авторами статьи)

Здесь 2013 год является прогнозным. Видно, что динамическая модель банкротств, построенная по НЛДМ, дает ценную прогнозную информацию для принятия управленческих решений по финансовому менеджменту. Так в ОАО «Группа компаний ПИК» и ОАО «Казаньцентрострой» имеют положительную динамику (сценарий развития банкротства). Благодаря антикризисным мерам: прогнозные значения вероятности банкротства P от значения 0,98 снизились до (0,40, ..., 0,45). В отношении других корпораций прогноз дает неблагоприятные значения ($P > 0,56$, ..., 0,76), что свидетельствует о неэффективности антикризисных мер, принятых в этих корпорациях с 2009 г. по 2012 г. (недостаточная выручка и прибыль).

Выводы

1. Применительно к сложным условиям моделирования, характерным для задач банкротств, в которых помимо обычной зашумленности данных имеет место специфические свойства неопределенности (несимметрии) и неполноты данных, построение динамической модели банкротств с помощью традиционных методов эконометрики проблематично. Здесь перспективно применение интеллектуальных нейросетевых методов моделирования.

2. Разработан концептуальный базис и реализующий его оригинальный итерационный нейросетевой логистический динамический метод (НЛДМ) построения моделей банкротств, основная идея которого состоит в использовании косвенной информации обо всех нюансах проявления динамики развивающегося процесса банкротства, содержащейся в значениях векторов факторов $\vec{x}_{g,k}$ «временных срезов» данных. При этом НЛДМ в процессе построения модели восстанавливает неполные данные в срезах и исправляет их несимметрию.

3. Новая версия НЛДМ, рассматриваемая в данной статье, содержит помимо процедуры восстановления неполных данных, алгоритм интеграции процедуры регуляризации НСМ на байесовском ансамбле с формализованной процедурой синтеза рациональной структуры нейросети.

4. Направлением дальнейших исследований авторы видят в повышении качества среднесрочного и краткосрочного прогноза банкротства на основе предложенного НЛДМ, в частности, в задачах установления незаконности банкротств.

ЛИТЕРАТУРА

1. Горбатков С.А., Фархиева С.А., Белолипец И.И. Нейросетевые и нечеткие методы моделирования диагностики и прогнозирования банкротств корпораций: Монография / Под ред. проф. С.А. Горбаткова. – М.: Прометей, 2018. – 371 с.
2. Белолипец И.И., Горбатков С.А., Романов А.Н., Фархиева С.А. Моделирование управленческих решений в сфере экономики в условиях неопределенности: Монография / Под ред. А.Н. Романова. – М.: ИНФРА – М, 2015. – 299 с.
3. Горбатков С.А., Фархиева С.А. Динамические нейросетевые модели банкротств корпораций при неполных данных: Монография / Под ред. С.А. Горбаткова. – М.: Прометей, 2020. – 210 с.
4. Хайкин С. Нейронные сети: полный курс: учебник / 2 – изд.; перевод с англ. – М.: Вильямс, 2006. – 1104 с.
5. Шумский С.А. Байесова регуляризация обучения // Лекции школы – семинара «Современные проблемы нейроинформатики» (23–25 января 2002 г., Москва). – М.: МИФИ, 2002. – с. 61–94.
6. Горбатков С.А., Полупанов Д.В. Оптимальный отбор и агрегирование экзогенных переменных в нейросетевых моделях банкротств на основе функций Харрингтона // Информационные технологии. Том 24. №2, 218. – с. 121–130.
7. Милов В.Р. Структурно-параметрический синтез нейросетевых систем обработки информации // Автореф. дисс. ... докт. техн. наук. – Нижний Новгород, 2003. – 35 с.
8. Ohlson J.A. Financial Ratios and the Probabilistic Prediction of Bankruptcy // Journal of Accounting Research. – 1980. – № 18(1). – P. 109–113.
9. Тихонов А.Н., Арсенин В.Я. Методы решения некорректных задач: Монография. – М.: Наука. Физмат, 1979. – 286 с.
10. Makeeva E.U., Neretina E.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. № 1. P. 65–76.

Gorbatkov Stanislav Anatol'evich

Financial university under the Government of the Russian Federation
Ufa branch, Ufa, Russia
E-mail: sgorbatkov@mail.ru

Farkhieva Svetlana Anatol'evna

Financial university under the Government of the Russian Federation
Ufa branch, Ufa, Russia
E-mail: ok-xi@yandex.ru

Hybrid method of structural synthesis and regularization of a neural network dynamic model of corporate bankruptcies

Abstract. The object of the research is the tasks of financial management, in particular, the tasks of forecasting the stages of developing bankruptcy of corporate borrowers and making decisions on the restructuring of credit debt. Solving such problems is also important for assessing the solvency of counterparties in transactions, resolving issues about the illegality of bankruptcies, economic security, and other areas of the economy.

The subject of the research is the development of a dynamic bankruptcy model with continuous time under conditions of high uncertainty and noise of data, which allows diagnosing the bankruptcy stages of the simulated object at any time (between "time slices" in the data), as well as predicting the probability of bankruptcy in time ahead for a given horizon. Uncertainty refers to a specific characteristic of the simulated class of dynamic bankruptcy problems – incompleteness and uncertainty in the data: in the training sample, only the boundary values of the probability of bankruptcy ($P = 0$ or $P = 1$) are usually specified in the "time slices" of the retrospective data that the model is based on, i.e. there is no information about the intermediate values of P in the interval $[0;1]$. The uncertainty is due to legal reasons: until the Corporation is declared bankrupt by an arbitration court, or tax authorities, or on its own application for it, $P = 0$, although objective accounting data may show that it is close to bankruptcy.

The aim of the research is to develop a scientifically based approach to synthesizing the structure of a dynamic neural network that can work effectively in complex modeling conditions.

Keywords: neural network; optimal factor selection algorithm; conceptual basis; factor compression in clusters; Harrington function; dynamic bankruptcy model; model regularization integrated with structural synthesis; testing; model adequacy