

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ ПРОГНОЗИРОВАНИЯ ПЛАТЕЖЕСПОСОБНОСТИ РОССИЙСКИХ ПРЕДПРИЯТИЙ ОБРАБАТЫВАЮЩИХ ОТРАСЛЕЙ

Т.К. Богданова,

кандидат экономических наук, доцент кафедры бизнес-аналитики Национального исследовательского университета «Высшая школа экономики»

Т.Я. Шевгунов,

кандидат технических наук, доцент кафедры теоретической радиотехники Московского авиационного института (национального исследовательского университета), выпускник Высшей школы бизнес-информатики (ВШБИ) НИУ ВШЭ

О.М. Уварова,

старший преподаватель кафедры бизнес-аналитики Национального исследовательского университета «Высшая школа экономики»

E-mail: tanbog@hse.ru, shevgunov@gmail.com, ouvarova@hse.ru

Адрес: г. Москва, ул. Кирпичная, д. 33/5

В статье рассмотрен метод построения модели для прогнозирования платежеспособности предприятий с использованием нейронных сетей. Проведен анализ платежеспособности российских предприятий обрабатывающих отраслей на основе финансовых показателей их публичной отчетности. Также приводится объяснение повышения точности прогноза нейросетевой модели по сравнению с известными моделями, построенными на основе логистической регрессии.

Ключевые слова: платежеспособность, нейронные сети, модели предсказания банкротства, логистическая регрессия.

1. Введение

Выбор надежных деловых партнеров является одним из главных факторов результативной хозяйственной деятельности для частных и государственных компаний, функционирующих

в условиях рыночной экономики. Выбор партнеров при организации цепочек поставок сырья и реализации готовой продукции, анализ объектов инвестиций или выбор соисполнителей для действующих контрактов — это типичные задачи, в которых лицам, принимающим решения, требует-

ся оценить финансовое состояние большого числа потенциальных контрагентов. Не менее важным является мониторинг финансового состояния текущих контрагентов компании, позволяющий принимать обоснованное решение о возбуждении процедуры банкротства с целью защиты собственных финансовых интересов. В дополнение к этому своевременное прогнозирование собственного неблагоприятного финансового состояния позволяет руководству компании выявлять причины и незамедлительно принимать необходимые меры по его оздоровлению.

Способность организации своевременно и в полном объеме исполнять свои краткосрочные обязательства, используя при этом оборотные активы, чаще всего определяют как краткосрочную платежеспособность, ассоциирующуюся с ликвидностью баланса предприятия, т.е. с возможностью превращать свои активы в денежные средства для погашения текущих обязательств. Для оценки краткосрочной платежеспособности традиционно применяется широко известная методика, утвержденная нормативными документами [1]. Данная методика базируется на сравнении коэффициента текущей ликвидности с пороговым значением, равным двум, и анализе его изменения по отношению к предыдущему отчетному периоду. Однако в настоящее время данная методика подвергается обоснованной критике по следующим причинам. Во-первых, она не учитывает отраслевую специфику предприятия и этап его жизненного цикла; во-вторых, методика дает ретроспективный характер оценки, что обуславливает ее низкую прогностическую способность; в-третьих, она дает локальную и одностороннюю оценку, которая является отражением преимущественно только текущей операционной деятельности фирмы.

В действительности, для широкого круга субъектов, заинтересованных в деятельности фирмы, более важной оказывается долгосрочная платежеспособность — способность организации рассчитываться по своим обязательствам в долгосрочной перспективе. Именно долгосрочная платежеспособность является индикатором устойчивого финансового состояния организации, достигаемого, в общем случае, правильным стратегическим управлением компанией в сложившихся условиях рынка продукции, на котором действует компания, и рынка капитала, к которому она имеет доступ. Оценить это состояние можно на основе анализа системы показателей, отражающих разные аспекты деятель-

ности фирмы. Выбор таких показателей и способа извлечения из них необходимой информации является открытой задачей, привлекающей активное внимание исследователей с середины 60-х годов XX века, работы которых базировались на регрессионных моделях, реализующих классические методы классификации [2; 3]. Главным недостатком таких методов является снижение их прогностической способности при нелинейном характере связей между показателями.

В настоящей работе представлена методика оценки долгосрочной платежеспособности предприятия на основе обработки системы финансовых показателей с использованием нейронных сетей. Следует отметить, что оценка финансового состояния с использованием нейронных сетей уже проводилась в работах отечественных и зарубежных исследователей [4; 5]. Однако устойчиво закрепилось использование в прикладных задачах нейронных сетей, как моделей «черного ящика» или, иначе, суррогатных моделей, реализуемых посредством predetermined алгоритмов выбранного программного обеспечения. Это может быть удобно для типичного бизнес-пользователя, но скрывает от исследователей и аналитиков важные детали изучаемой им предметной области. Настоящая работа призвана восполнить данный пробел и представить предметно обоснованную базу для создания эффективных моделей предсказания. Хотя задача выбора оптимальной системы финансовых показателей для оценки платежеспособности фирмы в настоящей работе не решалась, предлагаемый нейросетевой подход может быть применен совместно с любой совокупностью финансовых показателей, обеспечивающей достаточную полноту охвата различных аспектов деятельности анализируемой фирмы.

В настоящей работе приводится краткое описание нейросетевого метода оценки платежеспособности, для которого составлены основные рекомендации по выбору структуры нейронной сети и указаны ее возможные вариации. В результате применения данного подхода были синтезированы модели предсказания неплатежеспособности российских предприятий обрабатывающего сектора, анализ которых представлен в экспериментальной части. В заключение было проведено сравнение нейросетевого метода оценки платежеспособности с классическими методами классификации, и выявлены причины, позволяющие получать дополнительный выигрыш при построении прогнозных моделей с использованием нейросетей.

2. Постановка задачи

Общая постановка задачи оценки платежеспособности может быть сформулирована следующим образом. Необходимо найти способ достоверно предсказать наступление неблагоприятных финансовых событий для предприятия по анализу его публичной финансовой отчетности. В качестве неблагоприятного события рассматривается наступление неплатежеспособности – неспособности субъекта предпринимательской деятельности исполнить в установленный срок денежные обязательства перед своими кредиторами. Неплатежеспособность не обязательно влечет за собой последующее банкротство предприятия, но всегда сигнализирует его контрагентам о неблагоприятном финансовом состоянии.

Задача оценки платежеспособности предприятий традиционно рассматривается как задача классификации. В качестве объектов классификации выступают предприятия, а их классы определяются по отношению к свойству платежеспособности. В простом случае решается задача бинарной классификации, когда любая запись в реестре о неблагоприятном статусе рассматривается как наступление неплатежеспособности предприятия, а отсутствие таковой считается достаточным для отнесения к классу платежеспособных фирм. Признаки, на основе которых производится классификация, представляют собой показатели, вычисляемые на основе данных официальной финансовой отчетности. Традиционно в качестве признаков выступают коэффициенты финансового анализа, отражающие различные аспекты деятельности предприятия.

Для оценки финансового состояния как решения задачи классификации, можно выделить две группы методов, которые условно можно обозначить как традиционные и интеллектуальные. Традиционные методы используют сравнительно простой математический аппарат, а модели, полученные с их помощью, предполагают простую качественную интерпретацию. К таким методам относятся [6–9]:

- ◆ модели линейных пороговых классификаторов: модели Альтмана, Спрингейта, Фулмера, Лиса, Таффлера-Тишоу, ИГЭА и др.;
- ◆ скоринговые модели, типичным примером которой является модель Сбербанка РФ;

◆ регрессионные модели, наиболее известными из которых являются модели логистической регрессии: модели Ольсона, Чессера, Богдановой-Алексеевой и др., и пробит-регрессии, среди которых наиболее известна модель Змиевского [10].

Ко второй группе методов, можно отнести методы классификации, построенные на основе технологий прикладного искусственного интеллекта, такие как: деревья решений, нейронные сети, самоорганизующиеся карты, системы *ANFIS*¹ и др.

Большую популярность в настоящее время получили деревья решений, поскольку реализуемая ими процедура классификации похожа на серию принятия решений, каждое из которых часто может быть предметно интерпретировано в контексте выбранной системы признаков. Методы нейронных сетей обычно не предоставляют подобной возможности, однако, их потенциальная прогностическая способность оказывается выше за счет более качественного разделения классов, обусловленного использованием гладких функций трансформации, обеспечивающих сохранение информации до этапа окончательного принятия решений. Самоорганизующиеся карты позволяют отказаться от априорного выделения классов предприятий и выполнить эту операцию в процессе обучения, однако для их использования требуется подготовка качественной обучающей выборки.

Цель данной работы – построение нейронной сети, обеспечивающей более высокую точность прогнозирования платежеспособности предприятия по сравнению с прогнозными моделями, построенными традиционными методами, последующее выявление причин выигрыша в точности прогноза, полученного с использованием нейросетевой модели, и выработка рекомендаций по выбору наилучшей структуры сети и ее параметров.

3. Синтез нейросетевой модели

На *рис. 1* представлена структурная схема системы оценки платежеспособности на основе метода классификации, построенная с использованием искусственной сети прямого распространения сигнала (*feed-forward network*) класса «многослойный персептрон» [11; 12]. Синтезируемая сеть состоит из нейронов, объединенных в два слоя, называемых традиционно скрытым и выходным.

¹ (artificial neuro-fuzzy inference system) – технология организации систем прикладного искусственного интеллекта, объединяющая нейронные сети и операции нечеткого вывода

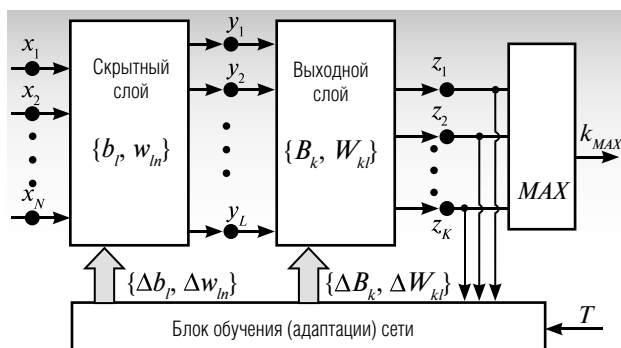


Рис. 1. Структура нейронной сети классификации предприятий

На вход нейронной сети поступает вектор

$$\mathbf{x} = (x_1, x_2, \dots, x_N)^T,$$

представляющий собой набор из N финансовых показателей x_n исследуемой фирмы. Скрытый слой формирует вектор признаков

$$\mathbf{y} = (y_1, y_2, \dots, y_L)^T,$$

размер которого L больше количества входных показателей $L > N$. Выходной слой осуществляет преобразование вектора \mathbf{y} из пространства признаков в вектор

$$\mathbf{z} = (z_1, z_2, \dots, z_K)^T,$$

представляющий собой оценку функции принадлежности объекта к одному из K классов. Для принятия решения нейронная сеть дополняется устройством принятия решений – «жестким» классификатором, выбирающим по правилу максимума номер компоненты выходного вектора, ассоциированный с одним из predetermined классов. Задачей блока обучения является адаптация нейронной сети, производимая за счет изменения параметров нейронов, составляющих скрытый и выходной слой сети.

Скрытый слой состоит из L нейронов, каждый из которых реализован в виде простого адаптивного элемента [13] – сумматора со смещением, имеющего нелинейную функцию активации. Структурная схема рассматриваемого нейрона представлена на рис. 2.




Рис. 2. Структурная схема нейрона скрытого слоя

Выходной сигнал такого нейрона формируется по следующему правилу:

$$y_l = f(b_l + \mathbf{w}_l^T \mathbf{x}), \quad (1)$$

где l – номер нейрона скрытого слоя ($l = 1, \dots, L$), b_l и \mathbf{w}_l – соответственно смещение и вектор весов для l -го нейрона скрытого слоя, а $f(v)$ – нелинейная функция активации, которая обычно задается в виде сигмоидальной, или логистической, функции:

$$f(v) = \sigma(v) = \frac{1}{1 + e^{-v}}, \quad (2)$$

или в виде гиперболического тангенса:

$$f(v) = th(v) = \frac{e^v - e^{-v}}{e^v + e^{-v}} = 2\sigma(2v) - 1. \quad (3)$$

Фактически гиперболический тангенс можно считать масштабированной и вертикально смещенной версией сигмоидальной функции, обладающей нечетной симметрией. Хотя выбор именно такого типа функций сложился исторически, они остаются чрезвычайно популярными у исследователей по причине удобства вычисления их производных при обучении сети.

Универсальная структура выходного слоя сети классификации, предназначенной для отнесения предприятий к двум и более классам, предполагает закрепление в выходном слое за каждым из выделенных классов одного из выходов. Будем считать, что фирмы можно отнести к одному из K классов, каждому из которых можно сопоставить свой номер k . Тогда компонент z_k выходного вектора \mathbf{z} представляет собой оценку функции принадлежности к k -му классу для предприятия, заданного совокупностью показателей. Величина z_k принимает значения из диапазона от нуля до единицы: $0 \leq z_k \leq 1$, при этом значения близкие к единице трактуются как высокая степень принадлежности к соответствующему классу, а близкие к нулю указывают на то, что фирма к указанному классу не принадлежит.

Окончательное решение, выполняемое «жестким» классификатором, состоит в отнесении предприятия к тому классу D , для которого соответствующий компонент z_D принимает наибольшее значение среди всех компонент $\{z_k\}$ выходного вектора:

$$D = \arg\{\max_k(z_1, \dots, z_k, \dots, z_K)\} \quad (4)$$

Рассмотрим два наиболее популярных способа организации выходного слоя классифицирующей сети. В первом случае каждый компонент выход-

ного вектора может быть связан с единственным нейроном с сигмоидальной функцией активации. Такой нейрон осуществляет нелинейное преобразование вектора признаков \mathbf{y} в скаляр:

$$z_k = \sigma(V_k) = \sigma(B_k + \mathbf{W}_k^T \mathbf{y}). \quad (5)$$

Другим способом организации выходного слоя является использование адаптивных сумматоров, совместно разделяющих общую функцию активации типа «softmax». При этом каждый из выходов z_k формируется с использованием результатов всех сумматоров:

$$z_k = \frac{\exp(B_k + \mathbf{W}_k^T \mathbf{y})}{\sum_1^K \exp(B_j + \mathbf{W}_j^T \mathbf{y})}, \quad (6)$$

Нейронная сеть может находиться в одном из двух режимов: режиме эксплуатации и режиме обучения. При работе в первом режиме сеть рассматривается как закрытая система («черный ящик»), на вход которой подается вектор показателей, а с выхода снимается номер класса. Однако для эффективной работы сеть должна быть определенным образом настроена. Это значит, что параметры сети, а именно: смещения и весовые векторы нейронов скрытого и выходного слоев — должны принять такие значения, которые обеспечат наибольшее количество правильных решений, вырабатываемых сетью. Аналитическая оценка указанных параметров с использованием компактных формул оказывается невозможной по ряду причин. Поэтому для их нахождения сеть переводится в режим обучения, в котором сеть адаптируется — ее параметры (смещения и весовые коэффициенты скрытого и выходного слоев) изменяются по результатам анализа предъявляемых сети примеров.

Традиционно обучение нейронной сети в задачах классификации производится по схеме обучения с учителем (*supervised learning*). Это значит, что в процессе обучения используются примеры, каждый из которых состоит из вектора показателей и номера класса T , к которому данное предприятие относится согласно мнению эксперта, обучающего сеть. Номер класса преобразуется в целевой вектор \mathbf{t} (*target*) функции принадлежности, состоящий из единицы в позиции, соответствующей номеру класса T , и нулевых элементов во всех остальных позициях. Таким образом, каждый пример, служащий для обучения сети, является парой векторов $\{\mathbf{x}, \mathbf{t}\}$.

Вся доступная выборка примеров делится на две или три неравные группы. При делении на две

группы выделяются обучающая и проверочная выборки, содержащие примерно 70 и 30 процентов примеров из общей выборки. Обучающая выборка служит для изменения параметров сети, а проверочная — для проверки качества работы сети на примерах, с которыми сеть не знакомилась в процессе обучения. Третья группа, называемая контрольной, служит для борьбы с, так называемым, переобучением сети, и обычно используется в том случае, когда общий объем выборки велик, а размерность пространства признаков много больше размера вектора входных показателей \mathbf{x} : $L \gg N$. Для этой группы обычно выделяют 15–20% от объема всей выборки за счет сокращения долей обучающей и проверочной группы.

Для сети вводится целевая функция, представляющая собой сумму квадратов ошибок e_k , вычисляемых как разность оценок функции принадлежности и целевых значений этой функции:

$$E = \frac{1}{2} \sum_{k=1}^K e_k^2 = \frac{1}{2} \sum_{k=1}^K (z_k - t_k)^2 \rightarrow \min. \quad (7)$$

Такие свойства представленной функции, как выпуклость и дифференцируемость в строгом смысле, позволяют создать итеративный алгоритм, при котором параметры сети будут подстраиваться — итеративно изменяться в течение последовательности эпох.

В задачах статической классификации, к которым в полной мере относится рассматриваемая задача классификации предприятий по их платежеспособности, обычно используется пакетный режим обучения (*batch mode*), при котором подстройка параметров осуществляется после представления сети всей совокупности примеров обучающей выборки. Пакетный режим обучения в отличие от последовательного (*interactive mode*) режима, в котором подстройка осуществляется после представления каждого примера, позволяет получить более устойчивые в статистическом смысле решения задачи минимизации целевой функции в пространстве параметров.

В общем случае подстройка некоторого параметра, который мы условно обозначим через θ , осуществляется по следующей формуле:

$$\theta_{m+1} = \theta_m + \alpha \cdot \Delta \theta_m, \quad (8)$$

где α — скорость обучения сети, θ_m — это величина желательного изменения параметра, способ вычисления которой зависит от метода обучения, а индекс m указывает на номер эпохи. С увеличением номера эпохи данный алгоритм описывает итеративный

процесс изменения величины θ до достижения ей некоторого оптимального значения θ^* . Типичный процесс адаптации сети сопровождается плавным уменьшением величины ошибки E до достижения ей некоторой минимальной величины E_{min} как на обучающей, так и на контрольной выборке, если последняя используется². Необходимым признаком успешного процесса адаптации, является монотонное уменьшение абсолютной величины $\Delta\theta_m$ для всех настраиваемых параметров сети, начиная с некоторого номера эпохи:

$$|\Delta\theta_{m+1}| < |\Delta\theta_m|, \lim_{m \rightarrow \infty} \Delta\theta_m = 0.$$

Выбор скорости обучения α является отдельной задачей, и некоторые рекомендации по выбору α для больших выборок данных приводятся в работе [12]. Общим признаком того, что величина α выбрана слишком маленькой, является долгий процесс адаптации и незначительное изменение величины ошибки E , а избыточная скорость обучения приводит к тому, что поведение величины $\Delta\theta$ принимает выраженный колебательный характер. В случае слишком большой скорости обучения, процесс адаптации может оказаться расходящимся, и оптимальные значения параметров никогда не будут достигнуты. Признаком этого является специфическое поведение графика функционала ошибки: начиная с некоторого номера, он монотонно увеличивается или принимает колебательный характер.

Способ вычисления величины подстройки определяется выбранным методом адаптации сети. Так, например, в методе градиентного спуска – базовом методе обучения первого порядка и самом простом с точки зрения реализации – величина $\Delta\theta$ вычисляется по следующей формуле:

$$\Delta\theta = - \sum_{i=1}^I \sum_{k=1}^K \left[e_{k,i} \frac{\partial z_{k,i}}{\partial \theta} \right], \text{ где} \quad (9)$$

I – общее количество примеров обучающей выборки
 $e_{k,i}$ – ошибка принадлежности примера i к классу k , определенная как разность $e_{k,i} = z_{k,i} - t_{k,i}$, а

$$\frac{\partial z_{k,i}}{\partial \theta} -$$

частная производная функции принадлежности по параметру, вычисленная при подаче на вход сети вектора признаков, описывающая i -ый пример.

Вычисление этой производной для параметров нейронов выходного слоя может быть выполнено непосредственно. Для нейронов же скрытого слоя оно осуществляется с помощью правила выведения производной сложной функции, которое в теории нейронных сетей также известно как процедура обратного распространения ошибки (*error back-propagation*) [12; 13], для которой в работе [14] было получено структурное представление в виде специального сигнального графа.

Выбор более сложных методов обучения: методов второго порядка, методов смешанного порядка, а также применение специальных техник, таких как введение момента и адаптивной скорости обучения, направлены на увеличение скорости сходимости сети к обученному состоянию. Это позволяет сократить необходимое число эпох обучения, но неизбежной платой за это является увеличение алгоритмической и вычислительной сложности.

4. Тестирование нейросетевой модели

Для представления была использована выборка российских предприятий обрабатывающих отраслей – пищевой, легкой и деревообрабатывающей промышленности – с номинальной балансовой стоимостью от 100 млн. до 1 млрд. руб. Были выбраны 264 платежеспособных предприятия и 206 предприятий, ставших банкротами в следующем отчетном периоде. Финансовые показатели были получены для отчетных периодов 2004–2009 годов с использованием информационно-аналитической системы FIRA PRO.

Был рассмотрен ряд моделей, отличающихся совокупностями используемых показателей, и установлено, что для данной выборки может быть успешно использована трехпараметрическая модель, в которую включены следующие показатели: рентабельность продаж, коэффициент финансовой зависимости и текущая ликвидность. Такая система описывает различные аспекты деятельности организации, а входящие в нее показатели являются некоррелированными между собой величинами. В дополнении к этому, при предварительном анализе, выполненном путем построения модели логистической регрессии, именно эти показатели обладали наибольшей значимостью.

² Упомянутое выше явление «переобучения» сети проявляется в том, что с каждой следующей эпохой ошибка для примеров обучающей выборки продолжает уменьшаться, но для примеров тестовой выборки начинает увеличиваться! Традиционно исследователи нейронных сетей трактуют это явление, как попытку сети запомнить все обучающие примеры вместо выделения обобщающей их информации.

На рис. 3 представлена зависимость точности прогноза от размера скрытого слоя, фактически, порядка нейросетевой модели, для двух типов сетей, различающихся организацией выходного слоя: нейронный слой или «softmax».

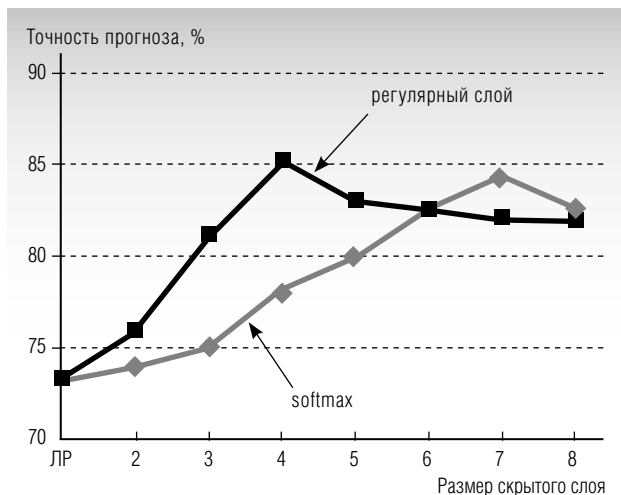


Рис. 3. Точность прогноза от размера скрытого слоя

Нейронные сети первого порядка структурно совпадают для обоих способов организации выходного и реализуют модель логистической регрессии; на графике они обозначены через LP. Такая сеть обеспечивает наименьшую точность прогноза, которая немонотонно возрастает с увеличением размера скрытого слоя, достигая максимума при некотором его значении. Дальнейшее увеличение порядка сети приводит к небольшому уменьшению точности прогноза. Такое поведение данных кривых объясняется тем, что избыточный порядок нейронов в скрытом слое ухудшает свойство нейронной сети проводить обобщение данных, предложенных ей при обучении. Различие в поведении характеристик для сетей разных типов объясняется тем, что нейроны в сети «softmax» обладают большей топологической связанностью, и степень их влияния друг на друга при обучении оказывается высокой. Как следствие, в данной задаче требуется больший порядок такого типа сети для достижения той же способности разделять классы платежеспособности. Однако это же свойство сетей «softmax» будет обеспечивать некоторый небольшой выигрыш, по сравнению с сетями, содержащими нейроны в выходном слое, при высоких порядках. Выбор оптимального порядка сети является отдельной задачей, однако, принятие более высокого порядка, чем оптимальный, не приведет к существенному ухудшению предсказательной способности модели.

В табл. 1 приводится результат для сети с промежуточным нейронным слоем, состоящим из четырех нейронов, обеспечивающих наибольшую точность прогноза, равную 85,1%, на данной выборке предприятий.

Таблица 1.

Результат прогнозирования модели

Наблюдаемое банкротство	Предсказанное банкротство		Процент корректных предсказаний
	нет	да	
нет	228	36	86,4
да	34	172	83,1
Общий процент			85,1

Для выявления степени влияния отдельных показателей на выходные решения, вырабатываемые нейронной сетью, используется величина, называемая важностью входного показателя. Она позволяет оценить в некотором смысле предсказательную способность каждого из показателей, что дает возможность ранжировать их по вкладу в точность решений, принимаемых с использованием модели на основе такой нейронной сети. Затем проводится их нормализация так, чтобы максимальной важности соответствовала единица. В табл. 2 представлены нормализованные важности финансовых показателей, использованных в рассматриваемой нейросетевой модели.

Таблица 2.

Нормализованная важность показателей

	Показатель	Содержание	Нормализованная важность
1	Коэффициент финансовой зависимости	Отношение суммы долгосрочных и краткосрочных обязательств к совокупным активам	1,00
2	Рентабельность продаж	Отношение прибыли от реализации к выручке	0,92
3	Текущая ликвидность	Отношение оборотных активов к краткосрочным обязательствам	0,45

Из данной таблицы следует, что здесь максимальную важность в принятии решений имеют два показателя – коэффициент финансовой зависимости и рентабельность продаж. Меры важности для этих показателей близки и более чем в два раза превосходят важность текущей ликвидности. Таким образом, роль последней как модельного фактора для предсказания наступления неплатежеспособности предприятий данной отраслевой группы в следующий отчетный период будет несколько снижена.

5. Анализ нейросетевой модели платежеспособности

Иллюстрацией для выяснения причин выигрыша нейронных сетей по сравнению с линейным классификатором может служить пример классификации предприятий с использованием двух финансовых показателей – признаков, которые мы обозначим через x_1 и x_2 . Отображение разными символами предприятий разных классов на координатной плоскости (x_1, x_2) дает хорошую геометрическую интерпретацию решаемой задачи.

На рис. 4 представлен случай, когда предприятия двух классов платежеспособности формируют распределения, носители которых отделены друг от друга на расстояние, превышающее в несколько раз средний разброс объектов вокруг центроидов их классов. Это позволяет с легкостью провести границу классов в двумерном пространстве признаков; более того, подходящая граница разделения будет неединственной. Из рис. 4 видно, что любая из представленных прямых линий может обеспечить безошибочное разделение объектов двух классов. Уравнение каждой линии является линейной комбинацией исходных финансовых признаков x_1 и x_2 и фактически определяет коэффициенты модели предсказания, формируемой уравнением вида:

$$Z = k \cdot x = k_0 + k_1 x_1 + k_2 x_2, \quad (10)$$

при этом выбор коэффициентов (k_0, k_1, k_2) оказывается в некоторой мере произвольным. Достаточно, чтобы для всех объектов, принадлежащих одному из классов, выполнялось условие $Z > 0$, и противоположное условие $Z < 0$ – для объектов второго класса. Это является одной из причин существования большого числа превосходно работающих моделей, включающих сходные наборы показателей, но различающихся коэффициентами, с которыми эти показатели входят в уравнение (10).

Более строгим условием, определяющим границу применимости моделей (10), является статистическая линейная разделимость классов. На рис. 5 представлен пример, когда невозможно провести линейную границу, которая обеспечила бы безошибочное разделение объектов двух классов. Однако можно найти наилучшее по некоторому критерию положение разделяющей линии, обеспечивающее вполне приемлемый результат для практических задач. При этом имеют место ошибки классификации, когда предприятия одного класса относятся к другому классу. Однако такие ошибки малы и могут быть оценены на этапе построения разделяющей




Рис. 4. Полностью разделимые классы




Рис. 5. Линейно разделимые классы

границы. При этом такие ошибки интерпретируются как случайные флуктуации значений признаков, порождаемые сторонними факторами, не учитываемыми в конкретном исследовании.

При более сложном характере взаимного влияния показателей может оказаться невозможным провести линейную границу без существенной потери качества предсказания. Типичный пример приведен на рис. 6, где дополнительно представлена кривая сложной формы, которая могла бы являться хорошей границей разделения классов. Однако для построения такой кривой нет теоретически возможного решения, обоснованного предметным содержанием используемых в модели финансовых показателей и их совместным влиянием на долгосрочную платежеспособность.

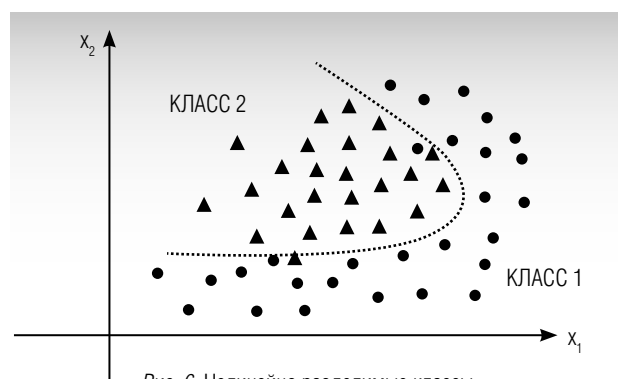


Рис. 6. Нелинейно разделимые классы

Нейронная сеть является удобным инструментом, позволяющим выявить характер влияния связанной системы показателей и построить приемлемую границу сложной формы на большой выборке классифицируемых объектов. Это достигается за счет нелинейного преобразования исходного пространства показателей, в котором классы не являются принципиально линейно разделимыми в пространстве признаков более высокой размерности, в котором эти классы оказываются разделимыми линейно с высокой достоверностью.

Необходимо отметить, что анализ платежеспособности предприятий по данным публичной финансовой отчетности, все еще остается открытой задачей. Использование интеллектуальных методов предсказания, таких как нейронные сети, способно обеспечить заметный выигрыш по сравнению с моделями линейных классификаторов. Однако общее ограничение предсказательной способности таких моделей является следствием их статичности — используемые данные относятся к единственному временному периоду. Увеличить надежность прогноза можно с ис-

пользованием динамических моделей, учитывающих изменение интегрального показателя финансового состояния в течение нескольких последовательных периодов, например, как рассмотрено в работе [15].

Выбор конкретной совокупности учитываемых показателей всегда является компромиссом между более полным охватом деятельности организации и увеличенной сложностью модели. При построении нейросетевой модели необходимо принимать во внимание ее адаптивный характер. Это значит, что выборка, сформированная для обучения сети, должна состоять из предприятий той же группы, для которых в дальнейшем предполагается ее использование. Таким обобщающим фактором может служить, например, отраслевая принадлежность и размер совокупных активов фирмы. Подобные адаптивные методики анализа платежеспособности предприятий могут являться важным инструментом, способствующим принятию эффективных решений как в задачах управления отдельной фирмой, так и в задачах отраслевого мониторинга и государственного регулирования. ■

Литература

1. Федеральный закон №127-ФЗ О несостоятельности (банкротстве) от 26.10.2002.
2. Beaver V. Financial ratios as predictors of failure // Journal of Accounting Research. — 1966. — Vol.4. — P. 91-101.
3. Altman E.I. Financial ratios, discriminant analysis and the prediction of corporate bankruptcy // The Journal of Finance. — 1968. — Vol. 23, No. 4. — P. 589-609.
4. Neves J.C., Vieira A. Improving bankruptcy prediction with hidden layer learning vector quantization // European Accounting Review. — 2006. — Vol. 15, No. 2. — P. 253-271.
5. Рахимкулова Г.З. Аналитические и нейрокомпьютерные модели оценки кредитоспособности предприятия // Аудит и финансовый анализ. — 2007. — №3. — С. 196-198.
6. Алексеева Ю.А. Оценка финансового состояния и прогнозирование банкротства предприятия // Автореферат диссертации на соискание ученой степени кандидата экономических наук. — М., 2011.
7. Анализ финансового состояния предприятия / Веб-сайт <http://afdanalyse.ru/>
8. Богданова Т.К., Баклакова А.В., Инструментальные средства прогнозирования вероятности банкротства авиапредприятий // Бизнес-информатика. — 2008. — №1. — С. 45-61.
9. Арутюнян А.Б. Опыт применения моделей Фулмера и Спрингейта в оценке венгерских предприятий сельского хозяйства и пищевой промышленности // Аудит и финансовый анализ. — 2002. — №2. — С. 200-204.
10. Zmijewski M.E., Methodological issues related to the estimation of financial distress prediction models // Journal of Accounting Research. — 1984. — Vol. 22. — P. 59-82.
11. Тадеусевич Р. и др. Элементарное введение в технологию нейронных сетей с примерами программ / Пер. с польск. — М.: Горячая линия — Телеком, 2011.
12. Хайкин С. Нейронные сети: полный курс. 2-е изд., испр. / Пер. с англ. — М.: Вильямс, 2006.
13. Ефимов Е.Н., Шевгунов Т.Я. Построение нейронных сетей прямого распространения с использованием адаптивных элементов // Журнал радиоэлектроники (электронный журнал), ISSN 1684-1719. — М.: ИРЭ РАН, 2012. — №8.
14. Narendra K.S., Parthasarathy K. Identification and control of dynamical systems using neural networks // IEEE Transactions on Neural Networks. — 1990. — Vol. 1, No. 1. — P. 4-27.
15. Богданова Т.К., Алексеева Ю.А. Прогнозирование вероятности банкротства предприятий с учетом изменения финансовых показателей в динамике // Бизнес-информатика. — 2011. — №1(15). — С. 50-60.