

НЕЙРОСЕТЕВАЯ СИСТЕМА ОЦЕНКИ ВЕРОЯТНОСТИ БАНКРОТСТВА БАНКОВ

Л.Н. ЯСНИЦКИЙ

доктор технических наук, профессор кафедры информационных технологий в бизнесе, факультет бизнес-информатики, Национальный исследовательский университет «Высшая школа экономики» (Пермский филиал); Председатель Пермского отделения Научного Совета РАН по методологии искусственного интеллекта
Адрес: 614046, г. Пермь, ул. Студенческая, д. 38
E-mail: yasn@psu.ru

Д.В. ИВАНОВ

аспирант кафедры информационных систем и математических методов в экономике, экономический факультет, Пермский государственный национальный исследовательский университет
Адрес: 614990, г. Пермь, ул. Букирева, д. 15
E-mail: idv_1988@mail.ru

Е.В. ЛИПАТОВА

студент факультета экономики, Национальный исследовательский университет «Высшая школа экономики» (Пермский филиал)
Адрес: 614046, г. Пермь, ул. Студенческая, д. 38
E-mail: lipatova_katya@mail.ru

Предметом исследования является банковская система России. Цель работы – создание математической модели, предназначенной для оценки вероятности банкротств банков по причине отзыва лицензии. Инструмент создания модели – аппарат нейронных сетей, обучаемых на материалах финансовой отчетности Центрального банка Российской Федерации. Погрешность тестирования (обобщения) обученной и оптимизированной нейронной сети составила 6,3%. Исследования моделируемой области, – банковской сферы РФ, – выполнены путем проведения виртуальных компьютерных экспериментов, в ходе которых вычисления с помощью нейронной сети производились при изменении одного из пятнадцати входных параметров, характеризующих банки, в то время как остальные параметры сохранялись неизменными. В частности, исследовалось влияние на вероятность банкротства банка коэффициента долгосрочной ликвидности, вида организационно-правовой формы, показателя размера крупных кредитных рисков, места регистрации банка. В результате сделан вывод о том, что повышение коэффициента долгосрочной ликвидности снижает вероятность банкротства банка, однако, начиная с определенного уровня, зависящего от других параметров конкретного банка, повышение данного показателя увеличивает вероятность его банкротства. Существенное влияние на успешность функционирования банка оказывает организационно-правовая форма банка, а также место его регистрации. Однако это влияние неоднозначно и в каждом конкретном случае может проявляться по-разному, в зависимости от множества других параметров банка и его деятельности. Приведен пример применения математической модели для разработки рекомендаций по снижению вероятности банкротства одного из банков.

Ключевые слова: банк, лицензия, банкротство, ликвидность, активы, капитал, прогноз, модель, нейронная сеть.

1. Введение

Актуальность проблемы прогнозирования банкротства предприятий, в частности, банкротства банков привела к тому, что сегодня в мире существует большое количество различных методик. В то же время, по мнению специалистов, не существует единого общепринятого метода. Кроме того, как отмечают многие российские авторы, многочисленные попытки применения иностранных моделей прогнозирования банкротств в отечественных условиях не позволили получить достаточно точные результаты.

Целью настоящей работы является создание математической модели, предназначенной для оценки вероятности банкротства банков по причине отзыва лицензии. Какие закономерности существуют между вероятностью отзыва лицензии и параметрами банка, чем руководствуется Центральный банк Российской Федерации (ЦБ РФ), отзывая лицензии банков – можно узнать, если проанализировать его финансовую отчетность. Перспективным инструментом для выявления скрытых в статистической информации закономерностей и построения на их основе математических моделей являются нейросетевые технологии.

Нейрокомпьютерные и нейросетевые технологии – это одна из наиболее эффективных стратегий искусственного интеллекта. Они наследуют от своего прототипа – мозга, его полезные свойства: способность извлечения знаний из статистических данных, способность обобщения их в виде закономерностей моделируемых предметных областей, свойство интуиции [1], как способность делать правильные прогнозы и принимать верные решения в тех случаях, когда обычная логика оказывается бессильной. Как убедительно показывает наш собственный опыт ([2, 3], www.PermAi.ru), хорошо спроектированные и правильно обученные нейронные сети являются мощным инструментом, позволяющим выявлять закономерности практически любых предметных областей и строить адекватные математические модели в промышленности, в экономике и бизнесе, в политологии, в криминалистике, в медицине, в экологии, в исторических науках, спорте и др.

Возможности применения нейросетевых технологий в прогнозировании банкротства предприятий исследовались в работах ряда зарубежных авторов. Так, в работе [4] рассмотрены различные подходы к построению моделей прогнозирования банкротства предприятий в Тайване. В результате исследования

был сделан вывод о том, что нейронная сеть обладает такой же эффективностью в оценке вероятности финансового краха, как CRIS (composite rule induction system), и большей эффективностью, чем логит-модель. Результаты работы [5] демонстрируют более высокую, чем модель на основе MDA (множественный дискриминантный анализ) эффективность нейронных сетей. Среди их преимуществ указывается способность прогнозировать банкротство на более ранних стадиях. В работе [6], посвященной прогнозированию платежеспособности российских предприятий, подчеркивается преимущество нейросетевого метода в случае нелинейного характера связей между показателями.

2. Математическая постановка задачи

При постановке задачи была введена гипотеза о том, что между финансово-юридическими параметрами банка и вероятностью отзыва его лицензии существуют некие закономерности, которые, впрочем, могут нарушаться, например, в случаях коррупции, рейдерского захвата и пр. Было введено предположение, что таких случаев в России относительно мало, и что они должны отображаться в статистической информации в виде отдельных выбросов. В качестве входных параметров нейросетевой математической модели были выбраны критерии, которые являются наиболее широко распространенными, включенными в официальные нормативы ЦБ РФ для банков и, в то же время, доступными. Всего было использовано 15 входных параметров:

- x_1 – достаточность собственных средств;
- x_2 – коэффициент мгновенной ликвидности;
- x_3 – коэффициент текущей ликвидности;
- x_4 – коэффициент долгосрочной ликвидности;
- x_5 – показатель максимального размера риска на одного заемщика или группу связанных заемщиков;
- x_6 – показатель максимального размера крупных кредитных рисков;
- x_7 – показатель максимального размера кредитов, банковских гарантий и поручительств, предоставленных банком своим участникам (акционерам);
- x_8 – показатель совокупной величины риска по инсайдерам банка;
- x_9 – показатель использования собственных средств (капитала) банка для приобретения акций (долей) других юридических лиц;
- x_{10} – рентабельность активов;
- x_{11} – год внесения в книгу государственной регистрации;
- x_{12} – место регистрации банка;

x_{13} – правовая форма;
 x_{14} – размер уставного капитала;
 x_{15} – размер активов.

Среди входных параметров модели имеются качественные факторы, характеризующие место регистрации банка (x_{12}) и его организационно-правовую форму (x_{13}). Эти показатели были закодированы следующим образом. Если банк зарегистрирован в Москве или Санкт-Петербурге, то параметру x_{12} присваивается значение «1», если же он зарегистрирован в других городах, то «0». Если банк зарегистрирован как ОАО, то параметру x_{13} присваивается значение «1», ООО – «2» и ЗАО – «3».

Выходная переменная y принимает значение, равное единице, если у банка была отозвана лицензия, и значение ноль, если банк продолжает свою деятельность.

В качестве источника информации для обучения нейронных сетей были использованы данные финансовой отчетности с сайта ЦБ РФ. Причинами банкротств банков, данные которых брались с сайта, были: неспособность удовлетворить требования кредиторов по денежным обязательствам и исполнить обязанность по уплате обязательных платежей, потеря ликвидности, неисполнение обязательств перед кредиторами, бездействие по восстановлению финансового положения, отсутствие адекватных резервов на возможные потери по ссудам, предоставление недостоверной финансовой отчетности, проведение операций, связанных с переводами денежных средств в пользу нерезидентов по различным сомнительным сделкам, несоблюдение сроков направления в Росфинмониторинг сообщений об операциях, подлежащих обязательному контролю, а также противодействие проведению инспекционной проверки и совершению надзорных действий.

На основании этой информации было сформировано множество, содержащее 111 примеров, из которых 52 примера являются данными обанкротившихся банков, 59 примеров относятся к работающим банкам. Все множество примеров разбито на обучающее, использованное для обучения сети, и тестирующее, предназначенное для проверки ее прогностических свойств. Естественно, что примеры тестирующего множества при обучении сети не использовались.

Проектирование, оптимизация, обучение, тестирование нейронной сети и эксперименты над нейросетевой математической моделью выполнялись с помощью нейропакета [2]. Оптимальная структура нейронной сети представляла собой персептрон

[3], имеющий пятнадцать входных нейронов, один скрытый слой с пятью нейронами и один выходной нейрон. В качестве активационных функций нейронов скрытого слоя и выходного нейрона использовались сигмоидные функции [3].

После обучения, прогностические свойства сети проверялись на тестирующих примерах. Изначально среднеквадратичная ошибка тестирования нейронной сети составила 13,5 %.

В процессе обучения и тестирования нейросети были обнаружены выбросы, выявленные с помощью методики [7]. Суть этой методики состоит в поочередном исключении примеров из обучающего множества и наблюдении за погрешностью нейросети, обученной на этих урезанных множествах. Если пример обучающего множества является выбросом и выпадает из закономерности, характерной для исследуемой предметной области, то его удаление из обучающего множества приводит к падению погрешности обучения сети и повышению ее обобщающих свойств, тогда как исключение обычных примеров существенного влияния на качество сети, как правило, не оказывает.

В число выбросов, обнаруженных с помощью этой методики, попали данные о пяти банках, среди которых: «Сембанк» и «Анкор-банк». Данные о первом банке были квалифицированы нейронной сетью как выброс, по-видимому, в связи с тем, что у него была отозвана лицензия, несмотря на то, что банк имел хорошие показатели достаточности капитала и коэффициенты ликвидности. Второй банк, наоборот, не подвергся санкциям ЦБ РФ несмотря на то, что имел довольно низкие показатели достаточности капитала и самый маленький размер уставного капитала из всей выборки.

После удаления обнаруженных нейросетью выбросов среднеквадратичная ошибка тестирования (обобщения) снизилась до 2,6%. Причем дополнительное тестирование нейронных сетей по методу multi-fold cross-validation [3] не показали сколько-нибудь заметного увеличения погрешности тестирования.

Обучение, оптимизация и тестирование нейронных сетей проводилось согласно методике, принятой в Пермской научной школе искусственного интеллекта ([2-3], www.PermAi.ru).

3. Исследование предметной области

После проверки разработанной нейросетевой математической модели на адекватность и точность, ее можно использовать для исследования предмет-

Таблица 1.

Параметры исследуемых банков

Банк	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8	X_9	X_{10}	X_{11}	X_{12}	X_{13}	X_{14}	X_{15}	Y
1. Банкрот	10	19	92	30	24	306	0	1	10	0	1992	1	1	150000000	1695047	0,99
2. Не банкрот	10	19	92	30	24	306	0	1	0,1	0,3	1992	1	1	550000000	18991000	0,09

ной области. Эта задача решалась путем проведения виртуальных компьютерных экспериментов, в ходе которых вычисления с помощью нейронной сети производились при изменении одного из входных параметров, в то время как остальные параметры «замораживались», т.е. сохранялись неизменными.

3.1. Влияние коэффициента долгосрочной ликвидности

Рассматривались характеристики двух банков, первый из которых изначально классифицировался как банкрот, а второй банк – как не банкрот. Значения параметров рассматриваемых банков приведены в табл. 1. Как видно из таблицы, банки существенно отличаются показателем использования собственных средств (капитала) для приобретения акций (долей) других юридических лиц (x_9), рентабельностью активов (x_{10}), размером уставного капитала (x_{14}) и размером активов (x_{15}).

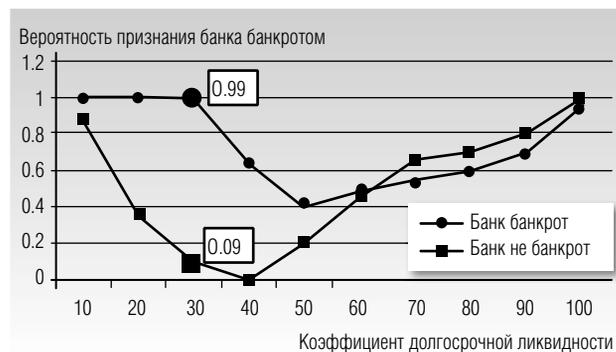


Рис. 1. Влияние коэффициента долгосрочной ликвидности на вероятность признания банка банкротом. Маркером увеличенного размера отмечено реальное состояние исследуемых банков

Анализируя результаты исследований, представленные на рис. 1, можно заключить, что значение коэффициента долгосрочной ликвидности оказывает существенное влияние на вероятность признания банка банкротом, причем кривые имеют U-образную форму. Повышение коэффициента долгосрочной ликвидности до определенного уровня снижает вероятность банкротства. Однако с определенного момента дальнейшее повышение данного показателя увеличивает вероятность банкротства. Оптимальным показателем долгосрочной ликвидности для изначально надежного банка является значение 40, а для банка банкрота – 50.

Нужно отметить, что вывод об U-образной форме зависимости подтверждается и теоретическими исследованиями. Слишком высокая ликвидность снижает прибыльность операций банка, поскольку большая часть денежных средств банка не инвестируется с целью получения доходов. Это влечет недополучение банком потенциальной прибыли и, как следствие, менее устойчивое финансовое состояние.

С другой стороны, слишком низкая ликвидность связана с риском дефолта банка вследствие невозможности удовлетворить в необходимые сроки финансовые требования вкладчиков, кредиторов и других клиентов. Например, невозможность банка возратить депозит и/или межбанковский кредит, а также проводить операции по расчетным счетам клиентов в необходимые сроки является одной из наиболее частых причин отзыва лицензий у банков.

Таблица 2.

Параметры исследуемых банков

Банк	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8	X_9	X_{10}	X_{11}	X_{12}	X_{13}	X_{14}	X_{15}	Y
1. Банкрот	25	50	60	28	14	200	0	1	0	0,2	1994	0	2	200000000	1220000	0,997
2. Не банкрот	14	50	60	60	14	200	0	0	0	0,2	1991	0	2	300000000	21991000	0,0

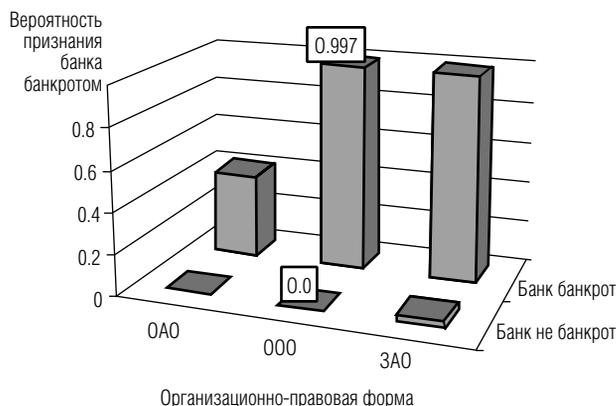


Рис. 2. Влияние организационно-правовой формы на вероятность признания банка банкротом

3.2. Влияние организационно-правовой формы

Рассматривались два банка. Первый банк изначально классифицировался как банкрот, второй банк – как не банкрот. Организационно-правовая форма обоих банков – ООО. Параметры рассматриваемых банков приведены в *табл. 2*.

Как видно из *рис. 2*, где приведены результаты исследований, для изначально нормально функционирующего банка (для него $y=0$) изменение организационно-правовой формы не оказывает существенного влияния на признание его банкротом. Для рассматриваемого банка банкрота (для него $y=0,997$) существует определенная зависимость, а именно: банк, существующий в форме ООО, имел бы меньшую вероятность банкротства, если бы был зарегистрирован в форме ОАО.

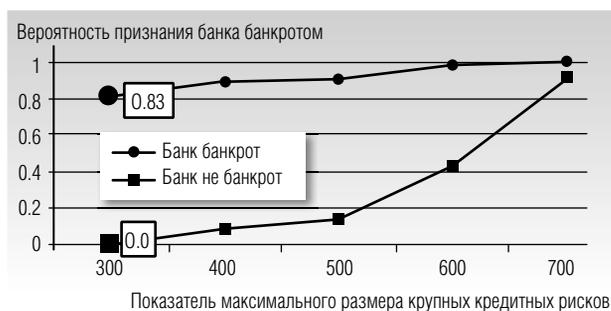


Рис. 3. Влияние показателя максимального размера крупных кредитных рисков на вероятность признания банка банкротом

3.3. Влияние показателя максимального размера крупных кредитных рисков

Рассмотрены два банка с одинаковым показателем максимального размера крупных кредитных рисков, отличающиеся по остальным входным факторам. Параметры банков приведены в *табл. 3*. По результатам исследований нейросетевой математической модели, приведенным на *рис. 3*, можно сделать вывод о прямой зависимости между показателем максимального размера крупных кредитных рисков и вероятностью признания банкротства как для изначально нормально функционирующего банка, так и для банка, признанного банкротом.

3.4. Влияние места регистрации банка

Рассмотрены характеристики трех банков, значения параметров которых представлены в *табл. 4*, а результаты исследований – на *рис. 4*.

Банк №1 изначально классифицировался как нормально функционирующий, и смена места регистрации банка не повлияла на вероятность признания его банкротом.

Банк №2 изначально рассматривался, как зарегистрированный в регионах и был признан банкротом ($y=0,87$). Смена регистрации банка на Москву и Санкт-Петербург изменила категорию данного банка на нормально функционирующий.

Банк №3 обладает теми же характеристиками, что и банк №2, кроме параметра x_4 (коэффициент долгосрочной ликвидности). Этот параметр банка №3 ниже на 43%. На *рис. 4* можно видеть, что данный банк является банкротом в Москве и Санкт-Петербурге, а в регионах он банкротом не является.

Таким образом, в результате выполненных исследований можно сделать заключение о существовании связи между местом регистрации банка и вероятностью признания его банкротом. Однако при этом стоит учитывать влияние других факторов. Если у банка хорошие показатели финансовой устойчивости (Банк №1), то он остается нормально

Таблица 3.

Параметры исследуемых банков

Банк	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}	x_{11}	x_{12}	x_{13}	x_{14}	x_{15}	y
1. Банкрот	10	24	60	20	10	300	19	1	0	0	1991	1	2	200000000	1220000	0,83
2. Не банкрот	12	19	63	30	14	300	14	0	0	0,1	1989	1	1	3400000000	21991000	0,0

Таблица 4.

Входные параметры банков и результаты исследования

Банк	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}	x_{11}	x_{12}	x_{13}	x_{14}	x_{15}	y
Банк №1	16	45	76	90	14	72	0	1	0	0,5	1989	0	1	40000000000	25000000	0,0
	16	45	76	90	14	72	0	1	0	0,5	1989	1	1	40000000000	25000000	0,0
Банк №2	13	55	64	70	9	21	18	0	0	0	1991	0	1	16000000000	10000000	0,87
	13	55	64	70	9	21	18	0	0	0	1991	1	1	16000000000	10000000	0,11
Банк №3	13	55	64	40	9	21	18	0	0	0	1991	0	1	16000000000	15000000	0,34
	13	55	64	40	9	21	18	0	0	0	1991	1	1	16000000000	15000000	0,99

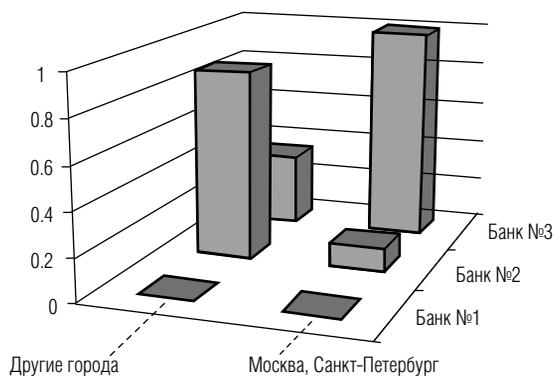


Рис. 4. Влияние места регистрации банка на вероятность признания его банкротом

функционирующим при смене Москвы (Санкт-Петербурга) на другой город. Если региональный банк признан банкротом (Банк №2), то по результатам исследования нейронной сети, он может улучшить свое положение, если позиционируется в Москве или в Санкт-Петербурге. Однако может быть и наоборот. Например, в ситуации, если банк характеризуется низким коэффициентом долгосрочной ликвидности и успешно работает в регионе (Банк №3), то в Москве и в Санкт-Петербурге такой банк может стать банкротом.

3.5. Пример разработки рекомендаций по снижению вероятности банкротства банка «Акционерный коммерческий банк «Кодекс»

Характеристика параметров рассматриваемого банка приведена в табл. 5, из которой видно, что банк является банкротом.

Как следует из рис. 5, уменьшение коэффициента долгосрочной ликвидности (x_4) с 82,5 до 55 приводит к снижению вероятности признания банкротства с 1 до 0,65. Из этого же рисунка видно, что уменьшение показателя совокупной величины риска по инсайдерам (x_9) с 2 до 0 приводит к снижению вероятности

признания банка банкротом с 1 до 0,62. Аналогично, из рис. 5 следует, что уменьшение показателя использования собственных средств (капитала) банка для приобретения акций (долей) других юридических лиц (x_9) с 18 до 9 приводит к снижению вероятности банкротства банка с 1 до 0,66. И наконец, как видно из таблицы 6, одновременное изменение всех трех параметров (x_4 , x_8 , x_9) в указанных выше пределах позволяет снизить вероятность банкротства банка «Кодекс» до нуля.

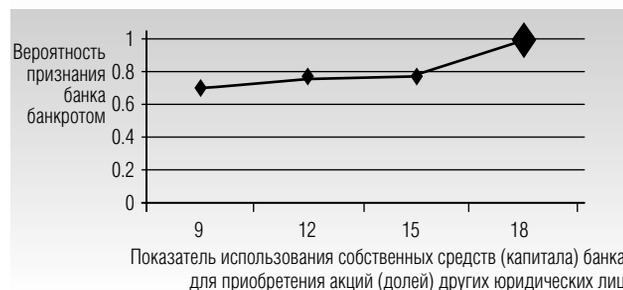
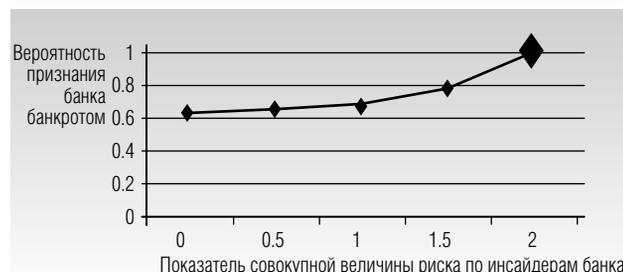
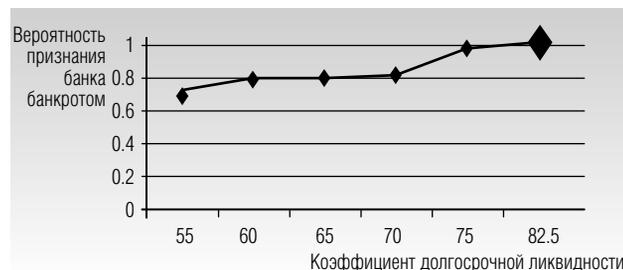


Рис. 5. Влияние параметров банка «Кодекс» на вероятность признания его банкротом. Маркером увеличенного размера отмечены реальные значения параметров банка

Таблица 5.

Параметры банка «Кодекс»

x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}	x_{11}	x_{12}	x_{13}	x_{14}	x_{15}	y
27,8	55,3	67,3	82,5	23	218,6	0	2	18	0	1994	1	1	80000000	733755	1

Таблица 6.

Параметры банка «Кодекс» после корректировки

x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}	x_{11}	x_{12}	x_{13}	x_{14}	x_{15}	y
27,8	55,3	67,3	55	23	218,6	0	0	9	0	1994	1	1	80000000	733755	0

4. Заключение

Применение метода нейросетевого моделирования позволило создать систему, с высокой точностью оценивающую вероятность банкротства банков по пятнадцати входным параметрам. С помощью вычислительных экспериментов над разработанной математической моделью выявлен ряд закономерностей исследуемой предметной области – банковской системы России. В частности, сделан вывод о том, что повышение коэффициента долгосрочной ликвидности до определенного момента снижает вероятность банкротства банка, однако с определенного уровня повышение данного

показателя увеличивает вероятность банкротства банка. Оптимальное значение коэффициента долгосрочной ликвидности для каждого конкретного банка может быть определено путем вычислений с помощью разработанной нейросетевой системы.

Вычислительные эксперименты позволили установить, что организационно-правовая форма банка, а также его место регистрации оказывают существенное влияние на состояние банка, однако это влияние неоднозначно и в каждом конкретном случае может проявляться по-разному, в зависимости от множества других параметров, характеризующих банк. ■

Литература

1. Ясницкий Л.Н., Данилевич Т.В. Современные проблемы науки. М.: БИНОМ. Лаборатория знаний, 2008. 295 с.
2. Ясницкий Л.Н., Богданов К.В., Черепанов Ф.М. Технология нейросетевого моделирования и обзор работ Пермской научной школы искусственного интеллекта // *Фундаментальные исследования*. 2013. № 1–3. С. 736–740.
3. Ясницкий Л.Н. Интеллектуальные информационные технологии и системы. Пермь: Пермский университет, 2007. 271 с.
4. Ko L.-J., Blocher E.J., Lin P.P. Prediction of corporate financial distress: An application of the composite rule induction system // *The International Journal of Digital Accounting Research*. 2009. Vol. 1, No. 1. P. 69–85.
5. Coats P.K., Fant L.F. Recognizing financial distress patterns using a neural network tool // *Financial Management*. 1993. Vol. 22. P. 142–155.
6. Богданова Т.К., Шевгунов Т.Я., Уварова О.М. Применение нейронных сетей для прогнозирования платежеспособности российских предприятий обрабатывающих отраслей // *Бизнес-информатика*. 2013. №2 (24). С. 40–48.
7. Черепанов Ф.М., Ясницкий Л.Н. Нейросетевой фильтр для исключения выбросов в статистической информации // *Вестник Пермского университета. Серия: Математика. Механика. Информатика*. 2008. № 4. С. 151–155.

NEURAL NETWORK DESIGNED TO ESTIMATE PROBABILITY OF BANK BANKRUPTCIES

Leonid YASNITSKY

Professor, Department of Information Technologies in Business, Faculty of Business Informatics, National Research University Higher School of Economics (Perm branch); The Chairman of the Perm office of Scientific Council of the Russian Academy of Sciences on methodology of artificial intelligence
Address: 38, Studencheskaya street, Perm, 614046, Russian Federation
E-mail: yasn@psu.ru

Dmitry IVANOV

Post-graduate student, Department of Information Systems and Mathematical Methods in Economics, Faculty of Economics, Perm State University
Address: 15, Bukireva street, Perm, 614990, Russian Federation
E-mail: idv_1988@mail.ru

Ekaterina LIPATOVA

Student, Faculty of Economics, National Research University Higher School of Economics (Perm branch)
Address: 38, Studencheskaya street, Perm, 614046, Russian Federation
E-mail: Lipatova_katya@mail.ru

The object of research is the banking system of Russia. The study purpose is to build a mathematical model to estimate probability of bank bankruptcies due to license revocation. An instrument to build the model is neural networks to be trained on financial statements of the Central Bank of the Russian Federation. The testing error of the trained and optimized neural network has constituted 6.3%. The studies of the modeled area – the banking system of the Russian Federation – have been carried out through virtual computer experiments. The neural network calculations have been made by changing one of fifteen bank-related input parameters with other parameters remaining constant.

In particular, the impact of long-term liquidity ratio, the type of business legal status, the exposure to large credit risks and bank place of registration on bank bankruptcy probability has been investigated. As a result the conclusion has been formulated that the increase of long-term liquidity ratio reduces the bank bankruptcy probability. However, starting with a certain level, depending on other parameters of a specific bank, the increase of this indicator increases the probability of its bankruptcy. Essential impact on successful bank performance is exerted by bank's business legal status, as well as the place of its registration. However, this impact is ambiguous and may manifest itself differently in each individual case, depending on many other bank parameters and its operations. A case study involving the mathematical model application to formulate recommendations to reduce bankruptcy probability of a bank is given.

Key words: bank, license, bankruptcy, liquidity, assets, capital, forecast, model, neural network.

References

1. Yasnitsky L.N., Danilevich T.V. (2008) *Sovremennye problemy nauki* [Modern problems of science]. Moscow: BINOM. (in Russian)
2. Yasnitsky L.N., Bogdanov K.V., Cherepanov F.M. (2013) Tehnologija nejrosetevogo modelirovanija i obzor rabot Permskoj nauchnoj shkoly iskusstvennogo intellekta [Neural network technology and an overview of the Perm scientific school of artificial intelligence]. *Fundamental research*, no. 1–3, pp. 736–740. (in Russian)
3. Yasnitsky L.N. (2007) *Intellektual'nye informacionnye tehnologii i sistemy* [Intelligent information technologies and systems]. Perm: Perm University. (in Russian)
4. Ko L.-J., Blocher E.J., Lin P.P. (2009) Prediction of corporate financial distress: An application of the composite rule induction system. *The International Journal of Digital Accounting Research*, vol. 1, no. 1, pp. 69–85.
5. Coats P.K., Fant L.F. (1993) Recognizing financial distress patterns using a neural network tool. *Financial Management*, vol. 22, pp. 142–155.
6. Bogdanova T.K., Shevgunov T.Y., Uvarova O.M. (2013) Primenenie nejronnyh setej dlja prognozirovaniya platyezposobnosti rossijskih predpriyatij obrabatyvajushih otraslej [Application of neural networks to predict the solvency of Russian enterprises manufacturing industries]. *Business Informatics*, no. 2 (24), pp. 40–48. (in Russian)
7. Cherepanov F.M., Yasnitsky L.N. (2008) Nejrosetevoj fil'tr dlja iskljuchenija vybrosov v statisticheskoj informacii [Neural network filter for eliminating outliers in the statistical information]. *Bulletin of the University of Perm. Series: Mathematics. Mechanic. Informatics*, no. 4, pp. 151–155. (in Russian)