

ИССЛЕДОВАНИЕ ПРИЧИН ОТЗЫВА ЛИЦЕНЗИЙ У РОССИЙСКИХ КОММЕРЧЕСКИХ БАНКОВ В ПОСТКРИЗИСНЫЙ ПЕРИОД (2010–2011)

© 2015 г. А.М. Емельянов, О.О. Брюхова

(Пермь)

В статье рассматриваются факторы, определяющие вероятность отзыва лицензий российских коммерческих банков в посткризисный период с 1 января 2010 г. по 31 декабря 2011 г. Прогнозирование финансовой устойчивости осуществляется с использованием логистической модели бинарного выбора, построенной на основе ежемесячной бухгалтерской отчетности, взятой за пять месяцев до наблюдения статуса банка. В работе также рассматривается вопрос о влиянии несбалансированности исходных данных на качество модели.

Ключевые слова: банк, оценка вероятности банкротства, логистическая регрессионная модель, финансовые показатели.

Классификация JEL: G210, C530.

ВВЕДЕНИЕ

Изменчивая конъюнктура российской финансовой сферы создает стимулы для осуществления постоянного контроля уровня надежности и финансовой устойчивости банков. Банкротство банка негативно сказывается на его непосредственных вкладчиках и кредиторах, а также снижает доверие к банковской системе в целом, не позволяя ей эффективно функционировать. В зарубежной практике контроль над риском дефолта банков осуществляется на основе внешних и внутренних рейтингов. Отсутствие в России развитой системы внешнего рейтингования обуславливает популярность второго подхода, связанного с разработкой систем раннего предупреждения. Использование систем раннего предупреждения позволяет по показателям, доступным на текущий момент, определить будущее финансовое состояние банка. Такой подход дает возможность менеджменту банка и регулятору своевременно осуществлять меры, направленные на его оздоровление.

Модели, позволяющие прогнозировать банкротство, уже достаточно долго обсуждаются в литературе, посвященной корпоративным финансам. Один из первых способов оценки финансового состояния компании – множественный дискриминантный анализ – был предложен еще Э. Альтманом (Altman, 1968). Среди более современных методов оценки вероятности банкротства можно выделить Logit- и Probit-модели, оболочечный анализ данных (Data Envelopment Analysis) (Charnes et al., 1978), нейронные сети (Bell, 1997), алгоритм распознавания признаков (trait recognition approach) (Kolari, Caputo, Wagner, 1996).

Для оценки вероятности банкротства банков наиболее широко применяется логистическая регрессия. Эффективность данного метода оценки была подтверждена во многих исследованиях: от самых ранних (Martin, 1977) до современных (Карминский и др., 2012).

Впервые возможность применения бинарной логистической регрессии для оценки вероятности дефолта была протестирована Д. Мартином на основе данных по банкам США за период 1975–1977 гг. (Martin, 1977). Эмпирическое исследование показало, что логистическая регрессия обеспечивает не меньшую точность прогноза, чем применявшийся ранее множественный дискриминантный анализ (МДА). Дополнительное преимущество логистической регрессии заключается в том, что ее результатом является не только классификация банка как банкрота или

небанкрота, но и прогнозирование точной вероятности его дефолта. Кроме того, использование логистической регрессии позволяет оценить значимость влияния объясняющих переменных, которые включены в модель. Благодаря данным особенностям построение logit-моделей становилось все более популярным способом оценки вероятности банкротства банков. Так, данный подход применялся для выявления финансовых показателей, объясняющих крупнейшие дефолты американских банков за период 1989–1992 гг. (Kolari et al., 2002). В исследуемую выборку вошли 50 обанкротившихся банков с величиной активов не менее 250 млн долл. и 50 финансово устойчивых банков, которые были подобраны в соответствии с размером и схожестью экономических и конкурентных условий регионов, в которых действуют банки. Наиболее значимыми оказались факторы, отражающие уровни рентабельности, достаточности капитала и кредитного риска. Построенные logit-модели позволили прогнозировать вероятность дефолта за 1 год до его наступления с точностью 100% для исходной выборки и 70% – для тестирующей; а за 2 года – с точностью 96 и 60% соответственно. Значимость показателей прибыльности, достаточности капитала и ликвидности подтвердилась также в исследовании (Kahn, Papanikolaou, 2013), проведенном по данным американских банков, которые обанкротились в период 2007–2010 гг. Эмпирически авторы показали, что крупные банки сталкиваются с большими рисками банкротства, чем мелкие. Данный факт является следствием привлечения ими более современных финансовых продуктов для финансирования своей деятельности, что создает дополнительные риски к традиционным процентным доходам, к которым прибегают мелкие банки.

Зародившаяся в США проблема прогнозирования вероятности банкротства банков стала широко обсуждаться исследователями по всему миру. На основе данных об азиатских банках за период 1996–1998 гг. авторы (Paola et al., 2002) выявили, что показатели бухгалтерской отчетности позволяют получать несколько более точные прогнозы финансового состояния банка, чем информация, получаемая с фондового рынка или из кредитных рейтингов. Авторы пришли к выводу, что в развивающихся финансовых системах имеет смысл использовать комплекс показателей различных видов. Банковскому кризису 1997–1999 гг. в азиатских странах также посвящено исследование Бонджини, Клаессенса, Ферри (Bongini et al., 2001). В их исследовании выборка включала 283 банка из Индонезии, Кореи, Малайзии, Филиппин и Таиланда. Авторы проанализировали зависимость между вероятностью дефолта банка и его отношением к крупным промышленным группам или влиятельным семьям.

Оценке вероятности банкротства коммерческих банков Турции посвящена работа Б. Эрдогана (Erdogan, 2008). В исследовании была использована информация из годовых бухгалтерских отчетов 42 коммерческих банков за период 1999–2001 гг. Автор построил logit-модель, на основе которой можно оценить вероятность дефолта за два года до его наступления. В модель были включены показатели, описывающие долю капитала банка, его прибыльность, соотношения доходов и затрат, а также резервы под возможные потери по кредитам.

Моделированию вероятности дефолта европейских банков также посвящен ряд работ. Так, в исследовании (Berg, Nexeberg, 1994) выявляются основные индикаторы проблемных банков Норвегии, а детерминанты финансового положения небольших банков Великобритании в начале 1990-х годов подробно описаны в работе А. Логана (Logan, 2000).

Анализ теоретических и эмпирических статей показал, что, несмотря на наличие общих подходов к оценке вероятности дефолта банков, существует определенная страновая специфика, которую необходимо учитывать при моделировании. В связи с этим особое внимание стоит уделить исследованиям, посвященным анализу состояния российских коммерческих банков.

Наиболее значительные результаты в моделировании вероятности банкротства российских банков были получены группой исследователей под руководством А.А. Пересецкого и А.М. Карминского. В ряде работ представлены результаты предварительного разделения банков на кластеры (Головань, Карминский и др., 2003), добавления в модель макроэкономических показателей (Головань и др., 2004) и институциональных факторов (Карминский, Костров, 2013). Моделирование осуществлялось с использованием логистической регрессии на основе данных из квартальной бухгалтерской отчетности банков, предоставленной информационным агентством «Мобиле». Авторы анализируют современную российскую банковскую систему с использованием квазипанельных данных за период 1998–2011 г. (Карминский, Костров, 2013).

В работе, описывающей возможность разделения банков на кластеры, предлагается два варианта разделения: на основе экспертного подхода и с использованием формального алгоритма построения функции максимального правдоподобия (Головань и др., 2003). Итогом выявления структурной неоднородности банков стало улучшение диаграммы ошибок. Данный эффект особенно ярко проявился при разделении банков на кластеры по доле вложений в государственные ценные бумаги: вероятность ошибки второго рода снизилась примерно на 20% при неизменном уровне ошибок первого рода. Схожий, но менее значимый результат достигается, если принять в качестве параметра разделения доли собственного капитала в активах банка. Для значительно-го улучшения качества модели достаточно добавить в нее всего один макропоказатель. Наиболее удачным оказалось включение в модель валютного курса, объема чистого экспорта (Головань и др., 2004) или индекса потребительских цен (Карминский, Костров, 2013). Среди институциональных факторов значимым оказался индекс Лернера. Интересным результатом стало обнаружение нелинейной зависимости между долей капитала в чистых активах банка и вероятностью его дефолта (Карминский, Костров, 2013).

Выявлению факторов, влияющих на вероятность дефолта российских банков, также посвящено исследование Лелайна и Веннета (Lanine, Vennet, 2006). В качестве объясняющих переменных они использовали параметры, отражающие прибыльность банка, его размер, а также подверженность рискам дефолта, ликвидности и недостаточности капитала.

Финансовая сфера российской экономики серьезно пострадала в период кризиса 2008–2009 гг. Факторы, влияющие на вероятность банкротства банков в кризисный период, были определены в работе (Дробышевский, Зубарев, 2011). Исследование проводилось на основе квартальных данных о банках, ставших банкротами в течение кризиса 2008–2009 гг. Всего в выборку вошло 1331 событие. Результаты показали, что участие банка в кредитовании физических лиц снижает вероятность банкротства. Интересные результаты были получены авторами относительно влияния на вероятность банкротства доли просроченных кредитов. Как подсказывает логика, рост данного показателя должен приводить к снижению устойчивости банка, однако авторы обнаружили противоположную ситуацию. Полученные ими результаты можно объяснить тем, что реальную величину просроченных кредитов не скрывают только крупные и успешные банки, а мелкие игроки, выживание которых находится под угрозой, вообще предпочитают не отражать ее в своей отчетности.

В данной статье представлены результаты исследования, направленного на моделирование дефолта российских коммерческих банков в послекризисный период. Решение схожей задачи было описано в статье (Емельянов, Брюхова, 2013). Основным недостатком предложенной авторами модели можно считать невысокую точность классификации банков-банкротов. Главной причиной недооценки вероятности дефолта стало построение модели на основе выборки с низкой долей банков, лишившихся лицензии. Поэтому в данной работе помимо факторов, оказывающих значимое влияние на финансовую устойчивость кредитных организаций, рассматривается решение проблемы несбалансированности данных и выбора оптимальной структуры подвыборки. Балансировка выборки проводилась путем бут-страппирования (boot-strapping). Такой подход позволил значительно улучшить диаграмму ошибок, избежать эффекта переобучения модели, а также оценить устойчивость полученных коэффициентов. Как следствие, были получены более точные значения коэффициентов, что крайне важно для корректной оценки вероятности банкротства и дальнейших возможностей применения модели.

Отличительной особенностью данного исследования является использование шага длиной в один месяц при изменении горизонта прогнозирования. Такой подход позволяет более оперативно отслеживать изменения в финансовом состоянии банков, чем при использовании квартальных данных, на которых базируется большинство предшествующих исследований.

ДАННЫЕ ДЛЯ ЭМПИРИЧЕСКОГО ИССЛЕДОВАНИЯ

Выборка, используемая в исследовании, включала банки двух категорий: банкроты и небанкроты. Банк относился к категории банкротов только в случае отзыва у него лицензии в соответствии с Федеральным законом от 25 февраля 1999 г. № 40-ФЗ (ред. от 2 июля 2013 г.) «О несостоятельности (банкротстве) кредитных организаций».

Обучающая выборка охватывала период с 1 января 2010 г. по 31 декабря 2011 г., а тестирующая – с 1 января 2012 г. по 30 июня 2012 г.

Всего за анализируемый период лицензия была отозвана у 58 российских банков. Однако часть обанкротившихся банков была обвинена в предоставлении в надзорные органы недостоверной отчетности. Направляемые в ЦБ отчеты не отражали в действительности ухудшающееся финансовое состояние банков. Исследование А.А. Пересецкого (Пересецкий, 2013) показало, что набор факторов, позволяющих оценивать вероятность банкротства, существенно разнится в зависимости от того, была ли лицензия отозвана из-за ухудшения финансового состояния банка или в связи с подозрением в «отмывании денег». Отзывы лицензий по причине неблагоприятного финансового состояния приводят к гораздо большим издержкам со стороны Агентства страхования вкладов (АСВ) и в большей степени поддаются прогнозированию при отделении их от случаев уличения банка в махинациях.

Организации, обвиненные в финансовых махинациях, были исключены из выборки. У 15 из 58 банков лицензия была отозвана в связи с установлением фактов существенной недостоверности отчетности, скрывающей в том числе наличие оснований для осуществления мер, направленных на предупреждение несостоятельности (АМТ Банк, Банк Империя, Международный промышленный Банк). Другой причиной отзыва лицензии, не связанной с финансовой устойчивостью банка, является нарушение требований Федерального закона «О противодействии легализации (отмыванию) доходов, полученных преступным путем, и финансированию терроризма» (от 7 августа 2001 г. № 115-ФЗ, в ред. от 31.12.2014) (Хоум-Банк, СахаДаймондБанк).

Таким образом, основой для формирования обучающей выборки стали 30 банков-банкротов, а тестирующей – 10. Обе выборки были дополнены соответственно 180 и 60 банками, продолжавшими функционировать в анализируемый период. Банки-небанкроты подбирались в соответствии с величиной активов, чтобы отчасти элиминировать эффект от разницы в размере банков.

Наиболее частыми причинами отзыва лицензий, связанными с ухудшением финансовой устойчивости кредитных организаций, стали потеря ликвидности и снижение величины собственных средств.

При недостатке ликвидных средств банки лишаются возможности своевременно исполнять обязательства перед кредиторами. В течение анализируемого периода политика ЦБ в основном была направлена на абсорбирование ликвидности банковской системы. Банки возвращали старые кредиты, полученные в пиковые моменты кризиса, а выдавали новые кредиты в гораздо меньших объемах. Те банки, которые не смогли нормализовать уровень ликвидности активов во время проведения ЦБ политики, направленной на ее поддержание, столкнулись со значительными проблемами после окончания проведения этой политики. В связи с этим в число объясняющих переменных при последующем построении модели были включены доли в общей величине активов вложений в государственные ценные бумаги и ликвидные активы, которые должны быть получены в срок до 30 календарных дней.

Помимо потери ликвидности, частой причиной отзыва банковских лицензий стало снижение величины собственных средств. Капитал имеет решающее значение для безопасности и надежности банка, так как он представляет способность финансовых учреждений противостоять непредвиденным потерям без ущемления интересов вкладчиков и других кредиторов. Необходимая для обеспечения активов величина капитала зависит от их размера и рискованности, поэтому наиболее точным показателем достаточности собственного капитала является его отношение к сумме активов, взвешенных в соответствии с присущим им уровнем риска. В результате эмпирического исследования (Estrella et al., 2000) авторы выявили, что при коротких периодах прогнозирования (не более двух лет) взвешенная сумма активов может быть заменена их простой суммой без потери в объясняющей способности показателя, а это значительно упрощает расчеты.

Основные причины отзыва лицензий за анализируемый период, а также результаты предшествующих исследований учитывались при формировании набора показателей, которые могут быть полезны при оценке финансового состояния кредитных организаций. Каждому банку соответствовало 12 финансовых показателей, которые рассчитывались на основе ежемесячных бухгалтерских отчетов, опубликованных на сайте Центрального банка РФ, за период с 1 до 8 месяцев до наступления банкротства. Способствовать росту вероятности банкротства может доля кредитного портфеля

в валюте баланса (Zhao et al., 2009), а также доля просроченной задолженности и резервов в общем размере выданных займов (Карминский и др., 2012). В то время как к снижению риска дефолта могут приводить высокие доли в общей величине активов собственного капитала (Головань и др., 2004; Zhao et al., 2009), ликвидных активов (Lanine, Vennet, 2006; Kahn, Papanikolaou, 2013), вкладов нерезидентов, вкладов физических лиц, кредитов нефинансовым организациям, а также рентабельность активов (Головань и др., 2004; Kahn, Papanikolaou, 2013) и размеры банков. Также к числу факторов, которые могут оказывать значимое влияние на вероятность банкротства, была отнесена доля вложений в государственные ценные бумаги в общей величине активов (Головань и др., 2003; Пересецкий, 2007) и доля долгосрочных кредитов в кредитном портфеле.

МОДЕЛИРОВАНИЕ ОЦЕНКИ ВЕРОЯТНОСТИ БАНКРОТСТВА

Оценка вероятности дефолта банков осуществлялась с использованием бинарной логистической регрессии. Вероятность банкротства может быть выражена из следующей спецификации:

$$Z_i = \ln(P_i/(1 - P_i)) = \beta_0 + \beta_1 X_1 + \dots + \beta_k X_k,$$

тогда $P_i = e^{Z_i}/(1 + e^{Z_i})$, где P_i – вероятность того, что в следующем периоде банк i станет банкротом; X_j – независимая переменная с номером j ; β_j – коэффициент перед объясняющей переменной с номером j . Зависимая переменная принимает значение, равное единице для банков-банкротов и нулю – для банков-небанкротов.

Качество построенной модели определялось значимостью оценок параметров регрессионного уравнения, а также ее классификационной точностью. Общим показателем точности модели служила доля банков, верно разнесенных по своим априорным категориям. Однако пропуск-регулятором финансово неустойчивого банка (ошибка рода II) приводит к более существенным издержкам со стороны вкладчиков и кредиторов банка, чем проявление ложной тревоги по отношению к надежному банку (ошибка рода I). Большая значимость ошибок рода II учитывается во взвешенном показателе эффективности (Kolari et al., 1996):

$$WE = (FCC/PF) (FCC/AF)CC,$$

где FCC – число верно классифицированных банкротов; PF – число банков, классифицированных как банкроты; AF – число фактических банков-банкротов; CC – доля (%) верно классифицированных банков.

Для оценки точности классификации модели необходимо установить пороговый уровень вероятности, при превышении расчетной вероятности которого банк будет относиться к категории банкротов. В данном исследовании сравнивались два способа расчета порогового уровня вероятности: исходя из максимизации общей точности модели и взвешенного показателя эффективности. Тестирование вероятности производилось с шагом в 1%.

Число банков-банкротов в анализируемой выборке значительно ниже, чем банков-небанкротов (15%), что соответствует складывающейся в реальности ситуации, однако не допускает адекватного применения логистической регрессии. Следствием несбалансированности данных может стать низкая точность классификации банков-банкротов согласно модели, так как модель будет занижать вероятность дефолта.

Выделяют несколько способов, позволяющих сбалансировать выборку (He et al., 2009): повышение числа банков-небанкротов; снижение числа банков-банкротов; составление случайной выборки с соразмерным числом банков обеих категорий.

При небольшом объеме имеющихся данных оптимальным является метод, основанный на составлении большого числа случайных сбалансированных подвыборок. При помощи эконометрического пакета *R* случайным образом было сформировано 150 подвыборок, по каждой из которых строилась *logit*-модель. Затем находились медианные значения всех характеристик модели, которые более устойчивы к «выбросам», чем средние. Тестирование на большом числе подвыборок позволяет избежать тенденции к переобучаемости, т.е. зависимости модели от исходной выборки.

В каждую подвыборку входили все 30 банков-банкротов. Подвыборки дополнялись определенным числом произвольно выбранных банков-небанкротов. Было рассмотрено четыре вариан-

Таблица 1. Классификационная таблица на основе общей значимости

Модель	Факт							
	Доля банков-банкротов, %							
	15 (базовый вариант)		25		33		50	
	Небанкрот	Банкрот	Небанкрот	Банкрот	Небанкрот	Банкрот	Небанкрот	Банкрот
Небанкрот, ед.	175	18	84	13	55	9	26	8
Банкрот, ед.	5	12	6	17	5	21	4	22
Верно, %	97,2	40	93,3	56,7	91,7	70	86,7	73,3
Всего верно, %	89		87,1		84,4		80	
<i>WE</i>	28,23		41,88		47,7		49,6	
Пороговая вероятность	0,37		0,46		0,48		0,49	
<i>LR</i> -тест	$0,07 \times 10^{-4}$		1×10^{-4}		5×10^{-4}		40×10^{-4}	

та формирования подвыборок в зависимости от того, каким числом банков-небанкротов дополнялись банки, потерпевшие дефолт. Доля банков-банкротов составляла 50, 33, 25 и 15% (базовый вариант с использованием всех имеющихся банков-небанкротов). Схожий метод балансировки выборки применялся в таких работах, как (Карминский и др., 2012; Lousada et al., 2012).

Оптимальная структура подвыборки выбиралась с учетом значимости коэффициентов перед объясняющими факторами и классификационной точности модели. Данный анализ проводился на основе модели, построенной за 1 месяц до банкротства.

Создание сбалансированной выборки приводит к сокращению числа наблюдений в каждой подвыборке за счет исключения из нее большего числа банков-небанкротов, что при построении нелинейной модели негативно сказывается на точности оценки коэффициентов. По мере удаления от базового варианта оценки коэффициентов становятся менее точными, доверительные интервалы увеличиваются. Тенденция снижения общей значимости модели, определяемой с помощью *LR*-теста, отражена в табл. 1.

Модель, построенная на основе несбалансированной выборки, занижает вероятность банкротства банков, поэтому оптимальный критический уровень вероятности находится в прямой зависимости от доли банков-банкротов в подвыборке. С ростом числа наблюдений пороговая вероятность банкротств снижается, что частично компенсирует несбалансированность выборки и способствует снижению числа ошибок рода II. Пороговый уровень, рассчитанный с учетом общей точности модели, всегда превышает границу, основанную на взвешенном показателе эффективности, так как использование второго подхода направлено на поддержание чувствительности модели на максимально возможном уровне. При прогнозировании вероятности банкротства на 1 месяц модель проявляет более высокую прогнозную точность с использованием пороговой вероятности, соответствующей коэффициенту общей эффективности вне зависимости от структуры подвыборки. Таким образом, при коротких горизонтах прогнозирования учет значимости ошибок рода II достаточно проводить за счет балансировки выборки, без дополнительного изменения порогового уровня вероятности. Результаты построения модели представлены в табл. 1.

Возникает необходимость поиска компромисса между общим качеством модели и потребностью избежать ошибок рода II. С ростом числа наблюдений общая точность модели повышается незначительно, в то время как взвешенный показатель эффективности резко снижается. С учетом данного факта, а также изменяющейся значимости коэффициентов в качестве наиболее оптимального варианта для дальнейшего исследования была принята подвыборка, состоящая из 30 банкротов и 60 небанкротов (33%).

Интересно отметить, что вне зависимости от структуры подвыборки, по которой строилась модель, набор значимых объясняющих факторов остается неизменным. С учетом проверки данных на нормальность распределения, дескриптивную способность (с использованием теста

Таблица 2. Оценки коэффициентов моделей на основе сбалансированной выборки

Объясняющие факторы модели	Горизонт прогнозирования, мес.							
	1	2	3	4	5	6	7	8
Доля собственного капитала	–0,9* (0,095)	–0,82** (0,098)	–0,58* (0,1)	–0,74* (0,129)	–0,64* (0,118)	–0,54 (0,152)	–0,56 (0,153)	–0,5* (0,114)
Доля инвестиций в ГКО	3,41** (0,048)	2,41** (0,05)	4,14** (0,048)	3,91* (0,055)	3,18** (0,047)	2,52* (0,053)	1,87* (0,056)	4,04* (0,051)
Доля ликвидных активов	–1,2*** (0,004)	–1,15*** (0,003)	–1,1*** (0,003)	–1*** (0,005)	–1,1*** (0,005)	–0,95*** (0,005)	–0,8*** (0,004)	–0,85*** (0,004)
Размер банка	–0,09* (0,134)	–0,08* (0,141)	–0,02* (0,139)	–0,06* (0,143)	–0,05* (0,149)	–0,04 (0,154)	–0,03 (0,167)	–0,02 (0,183)
Доля кредитов нефинансовым организациям	–0,1* (0,12)	–0,82* (0,098)	–0,9* (0,098)	–0,73* (0,133)	–0,57* (0,12)	–0,55* (0,135)	–0,35* (0,139)	–0,4* (0,134)
Константа	2,35* (0,055)	2,07** (0,047)	1,26** (0,041)	1,74** (0,05)	1,63** (0,049)	1,44** (0,049)	1,17* (0,051)	1,02** (0,046)
LR-тест	$4,39 \times 10^{-4}$	$5,52 \times 10^{-4}$	$5,66 \times 10^{-4}$	$7,99 \times 10^{-4}$	$6,15 \times 10^{-4}$	$7,14 \times 10^{-4}$	$7,37 \times 10^{-4}$	$7,55 \times 10^{-4}$
Критерий Акаике	107,6	107,96	108,22	109,01	108,51	108,72	108,83	109,11

Примечание. Здесь и далее «*» означает значимость на уровне 15%; «**» – на уровне 5%, «***» – на уровне 1%. В скобках указано медианное *p*-значение.

ANOVA), а также мультиколлинеарность для построения модели было выбрано пять показателей: доли в валюте баланса собственного капитала, ликвидных активов, кредитов нефинансовым организациям, вложений в государственные ценные бумаги и величина валюты баланса (табл. 2).

Следующим вопросом стал поиск оптимального горизонта прогнозирования. По мере удаления от даты возможного отзыва лицензии становится сложнее корректно оценить вероятность будущего банкротства. Однако, чем раньше будут выявлены проблемы в финансовом состоянии, тем большую гибкость в принятии решений смогут проявить регулятор и менеджмент банка, что позволит снизить издержки на его оздоровление.

В данном исследовании с шагом в 1 месяц тестировался период, на 8 месяцев предшествующий отзыву лицензии.

На всех временных промежутках знаки коэффициентов сохранялись, что свидетельствует об устойчивости найденных оценок и постоянстве выявленных экономических взаимосвязей. Однако при увеличении горизонта прогнозирования значимость оценок коэффициентов, как и значимость модели в целом, постепенно снижается. На протяжении первых пяти периодов значимыми в пределах 15% остаются все отобранные финансовые показатели, при последующем увеличении горизонта прогнозирования из их числа исключается доля собственного капитала и размер банка. Невысокая значимость коэффициента перед размером банка может быть связана с тем, что используемая выборка составлялась по принципу подобия, в основе которого лежало равенство величин валют балансов на дату, ближайшую к отзыву лицензии. На всех горизонтах прогнозирования наиболее устойчивым остается коэффициент перед долей ликвидных активов, что демонстрирует особую важность ликвидности для поддержания финансовой устойчивости банка в посткризисный период.

Сложность прогнозирования на более длинные горизонты появляется и в снижающейся точности классификации по модели (табл. 3–4).

При расширении горизонта прогнозирования резко снижается способность модели классифицировать банки-банкроты. Для поддержания чувствительности на приемлемом уровне, помимо построения модели на основе сбалансированной выборки, следует использовать пороговый

Таблица 3. Таблица классификации для сбалансированной выборки (за 1–4 месяца)

Модель	Факт							
	Горизонт прогнозирования, мес.							
	1		2		3		4	
	Небанкрот	Банкрот	Небанкрот	Банкрот	Небанкрот	Банкрот	Небанкрот	Банкрот
Небанкрот, ед.	55	9	52	10	53	11	52	11
Банкрот, ед.	5	21	8	20	7	19	8	19
Верно, %	91,7	70	86,7	66,6	88,3	63,3	86,7	63,3
Всего верно, %	84,4		80		80		78,8	
<i>WE</i>	47,7		38		37		35,2	
Пороговая вероятность	0,48		0,48		0,46		0,43	

Таблица 4. Таблица классификации для сбалансированной выборки (за 5–8 месяцев)

Модель	Факт							
	Горизонт прогнозирования, мес.							
	5		6		7		8	
	Небанкрот	Банкрот	Небанкрот	Банкрот	Небанкрот	Банкрот	Небанкрот	Банкрот
Небанкрот, ед.	51	11	50	11	44	11	40	10
Банкрот, ед.	9	19	10	19	16	19	20	20
Верно, %	85	63,3	83,3	63,3	73,3	63,3	66,7	66,7
Всего верно, %	77,7		76,7		70		66,7	
<i>WE</i>	33,4		31,8		24,1		22,23	
Пороговая вероятность	0,48		0,45		0,45		0,44	

уровень вероятности, рассчитанный с учетом максимизации взвешенного показателя эффективности, для классификации банков. В таком случае при более длительных горизонтах прогнозирования (3–8 мес.) дальнейшее увеличение периода не приводит к снижению чувствительности модели.

Более наглядно сравнить точность моделей, оценивающих вероятность банкротства на разные временные горизонты, можно с использованием ROC-анализа. Построение ROC-кривой позволяет выявить зависимость доли истинно положительных случаев от доли ложно положительных случаев. Чем выше способность модели верно распределять банки по их априорным категориям, тем ближе к левому верхнему углу проходит соответствующая ей ROC-кривая. На рисунке представлены ROC-кривые, соответствующие горизонтам прогнозирования в 2, 5 и 8 месяцев. Однако их расположение отражает общую тенденцию снижения точности модели при удалении от даты потенциального банкротства.

Для более точного сравнения результатов моделей были рассчитаны площади под каждой из кривых (табл. 5). На коротких

Таблица 5. Значения площадей под ROC-кривыми

Период прогнозирования, мес.	Площадь
1	0,75
2	0,73
3	0,72
4	0,72
5	0,72
6	0,69
7	0,66
8	0,60




Рисунок. ROC-кривые за 2, 5 и 8 месяцев

временных промежутках точность модели сокращается незначительно, оставаясь постоянной в период от 3 до 5 месяцев, дальнейшее снижение происходит более резко.

Оптимальный горизонт прогнозирования следует выбирать в зависимости от целей применения моделей. При необходимости выявления всех банков, выживание которых в последующих периодах находится под угрозой, возможно применение модели даже на горизонте прогнозирования в 8 месяцев, что создает максимальные возможности для проведения мер, направленных на оздоровление банка. При ориентации на общую классификационную точность модели следует выбирать более короткие периоды прогнозирования.

С учетом классификационной точности модели и значимости коэффициентов в качестве оптимального горизонта прогнозирования предлагается использовать пять месяцев.

РЕЗУЛЬТАТЫ ЭМПИРИЧЕСКОГО ИССЛЕДОВАНИЯ

Результатом проведенного исследования стало создание модели, позволяющей оценивать вероятность банкротства банков за пять месяцев до его наступления. Модель построена на основе 150 подвыборок, состоящих из 30 банков-банкротов и 60 банков-небанкротов. В табл. 6 представлены медианные значения и 95%-ные доверительные интервалы для коэффициентов перед каждым объясняющим фактором.

Была выявлена обратная зависимость между вероятностью дефолта банка в посткризисный период и его размером, а также долями в активах собственного капитала, ликвидных активов и кредитов нефинансовым организациям. Наличие инвестиций в ГКО, напротив, повышает риск банкротства банка. Обнаруженные взаимосвязи вполне согласуются с экономическим смыслом и сделанными ранее предположениями. Так, у крупного банка – больше возможностей для диверсификации деятельности и привлечения дополнительного капитала, что положительно сказывается на его финансовой устойчивости. Активная вовлеченность в операции с реальным сектором отражает приверженность банка к традиционным видам деятельности, а не спекуляциям на финансовом рынке, что также повышает его надежность. Инвестиции в ГКО нельзя считать безрисковыми, что объясняет их положительное влияние на вероятность дефолта, хотя они и могли бы служить дополнительным источником ликвидности.

Для определения количественного влияния каждого фактора на вероятность банкротства были рассчитаны соответствующие предельные эффекты. Значения показателей для среднего и медианного банков и их предельные эффекты представлены в табл. 7.

Таблица 6. Характеристика коэффициентов модели (за пять месяцев)

Объясняющие факторы модели	95%-ный доверительный интервал	Медианное значение
Доля собственного капитала	[−0,67; −0,61]	−0,64* (0,118)
Доля инвестиций в ГКО	[3,08; 3,28]	3,18** (0,047)
Доля ликвидных активов	[−1,16; −1,1]	−1,1*** (0,005)
Размер банка	[−0,06; −0,05]	−0,05* (0,149)
Доля кредитов нефинансовым организациям	[−0,59; −0,53]	−0,57* (0,12)
Константа	[1,62; 1,74]	1,63** (0,049)

Таблица 7. Значения показателей в разных точках

Объясняющие факторы модели	Среднее	Медиана	Эффект (среднее)	Эффект (медиана)
Доля собственных средств	0,24	0,18	−0,1	−0,16
Доля инвестиций в ГКО	0	0	0,49	0,77
Доля ликвидных активов	0,25	0,2	−0,18	−0,27
Размер банка	13,87	13,8	−0,01	−0,01
Доля кредитов нефинансовым организациям	0,36	0,36	−0,09	−0,14

Полученные значения для медианного банка позволяют говорить о том, что при росте соответствующего показателя на 10% вероятность банкротства изменяется следующим образом:

- при росте доли собственных средств в валюте баланса вероятность банкротства банка снижается на 1,6%;
- при увеличении доли ликвидных активов в общей сумме активов вероятность банкротства уменьшается на 2,7%;
- результатом увеличения доли вложений в государственные ценные бумаги является рост вероятности банкротства на 7,7%;
- при росте доли кредитов нефинансовым организациям происходит сокращение вероятности банкротства на 1,4%;
- при росте величины активов вероятность банкротства снижается на 0,1%.

Порядок факторов по степени влияния остается постоянным для разных временных горизонтов. Другими словами, наибольший эффект создает изменение доли вложений в государственные ценные бумаги, а наименьший – изменение размера банка. Высокое значение предельных эффектов от изменения доли вложения возникает из-за того, что она относительно низкая для всех банков выборки.

При любом горизонте прогнозирования предельные эффекты значительно ниже для банков, определенно являющихся банкротами или небанкротами. При этом максимальная величина предельных эффектов сохраняется постоянной, меняется лишь уровень финансовой устойчивости, при котором она достигается. Наблюдается снижение уровня процентиля банков, в котором достигается максимальное значение предельных эффектов. При увеличении горизонта прогнозирования изменение финансовых показателей оказывает все большее влияние на самые устойчивые банки. В случае высокого уровня финансовой устойчивости эффект от изменения выявленных

Таблица 8. Таблица классификации для тестирующей выборки (за пять месяцев)

Модель	Факт	
	Небанкрот	Банкрот
Небанкрот, ед.	50	3
Банкрот, ед.	10	7
Верно, %	83,33	70
Всего верно, %	81,43	
<i>WE</i>	46,03	

факторов имеет более долгосрочный характер и отражается в основном на вероятности банкротства через длительный промежуток времени. Для банков, уже испытывающих трудности, улучшение показателей приводит к снижению риска банкротства только в коротком периоде и не гарантирует стабилизации положения впоследствии. Поддерживать хорошее состояние в долгосрочной перспективе проще, чем восстанавливать его. Использовать модель, которая позволяет оценивать вероятность банкротства и следить за уровнем финансового состояния в любой момент, может быть крайне полезным.

Возможность применения построенной модели проверялась на тестирующей выборке, составленной в соответствии с принципом хронологии. Как уже было отмечено, в качестве тестирующей выборки использовалась подвыборка, состоящая из 70 банков (10 банкротов и 60 небанкротов), не входивших в первоначальную выборку. Результаты, полученные с использованием модели, представлены в табл. 8.

В целом модель продемонстрировала достаточно высокий уровень точности, верно распределив по априорным категориям 81,43% банков, что даже превосходит результаты, полученные для исходной выборки. Признание большей значимости ошибок рода II и построение модели на основе сбалансированной выборки позволило добиться приемлемой точности классификации банков-банкротов. Для анализируемой модели взвешенный показатель эффективности составил 46,03%. Тем не менее построенная модель демонстрирует несколько более высокий уровень специфичности (83,33%), чем чувствительности (70%).

ЗАКЛЮЧЕНИЕ

В работе построена модель вероятности отзыва лицензии российских коммерческих банков с использованием бинарной логистической регрессии. Анализ охватывал случаи отзыва лицензии, связанные с ухудшением финансового состояния банков, в посткризисный период 2010–2011 гг.

В ходе исследования была выявлена ключевая роль показателя ликвидности в определении финансового состояния банков в анализируемый период. Интересно отметить, что высокая значимость доли ликвидных активов является отличительной характеристикой посткризисного периода, что напрямую связано с деятельностью ЦБ по регулированию ликвидности банковского сектора. При оценке вероятности дефолта в кризисный период 2008–2009 гг. определяющей роли ликвидности не наблюдалось (Дробышевский, Зубарев, 2011).

Основная ошибка банков заключалась в проведении рискованной кредитной политики без создания адекватной величины резервов на возможные потери по ссудной задолженности и прочим активам. Величина резервов не отражала реального уровня рискованности активов и была одинаково мала для банков обеих категорий, что объясняет отсутствие значимого влияния данного показателя на вероятность дефолта. В период кризиса кредитоспособность заемщика снижается, что при отсутствии достаточных резервов в последующие периоды может привести к возникновению проблем у банка. У ненадежных банков появляются стимулы к предоставлению недостоверной отчетности, скрывающей реальное снижение величины собственных средств, что может быть причиной невысокой значимости соответствующего показателя в модели.

Кроме того, в работе был рассмотрен вопрос о влиянии несбалансированности исходных данных на качество модели. В рамках данного исследования подвыборка с наиболее оптимальной структурой состояла из 30 банков-банкротов и 60 банков-небанкротов (33% банков-банкротов). Балансировка выборки стала хорошим инструментом повышения точности классификации банкротов без значительного снижения общего качества модели, что позволило увеличить горизонт прогнозирования, на котором модель с высокой достоверностью выявляет потенциальных банкротов.

Представленные в работе результаты могут быть полезны как исследователям, занимающимся вопросами банкротства, так и менеджменту банков. Менеджеры могут оценить финансовое состояние своего банка и контрагентов с использованием всего пяти показателей, содержащихся в бухгалтерской отчетности: величины активов, долей в активах собственного капитала, ликвидных активов, кредитов нефинансовым организациям и вложений в ГКО. Сохранение классификационных возможностей на высоком уровне для тестирующей выборки говорит о высоком качестве полученной модели. Построенная модель позволяет получать приемлемые результаты за пять месяцев до наступления потенциального банкротства, что является достаточным периодом для проявления менеджментом гибкости в осуществлении управления и проведения мероприятий по оздоровлению. Простота модели и доступность входных параметров делают возможным анализ банка также и крупными вкладчиками.

СПИСОК ЛИТЕРАТУРЫ

- Головань С.А., Евдокимов А.М., Карминский А.М., Пересецкий А.А. (2004). Модели вероятности дефолта российских банков. Влияние макроэкономических факторов на устойчивость банков. М.: РЭШ.
- Головань С.А., Карминский А.М., Копылов А.В., Пересецкий А.А. (2003). Модели вероятности дефолта российских банков. Предварительное разбиение банков на кластеры. М.: РЭШ.
- Дробышевский С.М., Зубарев А.В. (2011). Факторы устойчивости российских банков 2007–2009. М.: Институт им. Е.Т. Гайдара.
- Емельянов А.М., Брюхова О.О. (2013). Оценка вероятности банкротства банков // *Финансы и кредит*. № 27 (555). С. 47–58.
- Карминский А.М., Костров А.В. (2013). Модели вероятности дефолта российских банков: расширенные возможности // *Журнал Новой экономической ассоциации*. № 1. С. 64–86.
- Карминский А.М., Костров А.В., Мурзенков Т.Н. (2012). Моделирование вероятности дефолта российских банков с использованием эконометрических методов. М.: Изд. дом ГУ ВШЭ.
- Пересецкий А.А. (2007). Методы оценки вероятности дефолта банка // *Экономика и математические методы*. Т. 43. № 3. С. 37–62.
- Пересецкий А.А. (2013). Модели причин отзыва лицензий российских банков. Влияние неучтенных факторов // *Прикладная эконометрика*. Т. 30. № 2. С. 49–64.
- Федеральный закон от 25 февраля 1999 г. № 40-ФЗ (ред. от 2 июля 2013 г.) «О несостоятельности (банкротстве) кредитных организаций».
- Altman E. (1968). Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy // *The Journal of Finance*. Vol. 4. P. 589–610.
- Bell T.B. (1997). Neural Nets or the Logit Model? A Comparison of Each Model's Ability to Predict Commercial Bank Failures // *International Journal of Intelligent Systems in Accounting, Finance and Management*. Vol. 6. P. 249–264.
- Berg S.A., Hexeberg B. (1994). Early Warning Indicators for Norwegian Banks: A Logit Analysis of the Experiences from the Banking Crisis. Norges Bank Working Paper.
- Bongini P., Claessens S., Ferri G. (2001). The Political Economy of Distress in East Asian Financial Institutions // *Journal of Financial Services Research*. Vol. 19. P. 5–25.
- Charnes A., Cooper W.W., Rhodes E. (1978). Measuring the Efficiency of Decision-Making Units // *European Journal of Operation Research*. Vol. 6. P. 429–444.

- Erdogan B.E.** (2008). Bankruptcy Prediction of Turkish Commercial Banks Using Financial Ratios // *Applied Mathematical Sciences*. Vol. 60. P. 2973–2982.
- Estrella A., Park S., Peristiani S.** (2000). Capital Ratios as Predictors of Bank Failure // *FRBNY Economic Policy Review*. P. 33–52.
- He H., Edwards A.** (2009). Learning from Imbalanced Data // *IEEE Transactions on Knowledge and Data Engineering*. Vol. 9. P. 1263–1284.
- Kahn C., Papanikolaou N.** (2013). What Problem Banks Reveal about Future Financial Distress: Evidence from the Late 2000s Financial Crisis. (April 30, 2013). Available at SSRN: <http://ssrn.com/abstract=1913710>
- Kolari J., Caputo M., Wagner D.** (1996) Trait Recognition: An Alternative Approach to Early Warning Systems in Commercial Banking // *Journal of Business Finance and Accounting*. Vol. 23. P. 1415–1434.
- Kolari J., Glennon D., Shin H., Caputo M.** (2002). Predicting Large US Commercial Bank Failures // *Journal of Economics and Business*. Vol. 54. P. 361–387.
- Lanine G., Vennet R.** (2006) Failure Prediction in the Russian Bank Sector with Logit and Trait Recognition Models // *Expert Systems with Applications*. Vol. 30. P. 463–478.
- Logan A.** (2000). The Early 1990s Small Banking Crisis: Leading Indicators // *Bank of England Financial Stability Review*. No. 9. P. 130 – 145.
- Louzada F., Ferreira-Silva P.H., Diniz C.A.R.** (2012). On the Impact of Disproportional Samples in Credit Scoring Models: An Application to a Brazilian Bank Data // *Expert Systems with Application*. Vol. 39. P. 8071–8078.
- Martin D.** (1977). Early Warning of Bank Failure: A Logit Regression Approach // *Journal of Banking and Finance*. Vol. 1. P. 249–276.
- Paola B., Laeven L., Majnoni G.** (2002). How Good is the Market at Assessing Bank Fragility? A Horse Race between Different Indicators // *Journal of Banking and Finance*. Vol. 26. P. 1011–1028.
- Zhao H., Sinha A., Ge W.** (2009). Effects of Feature Construction on Classification Performance: An Empirical Study in Bank Failure Prediction // *Expert Systems with Applications*. Vol. 36. P. 2633–2644.

Поступила в редакцию
27.03.2014 г.

Drivers of Banks License Withdrawal: the after Crisis (2010–2011) Study

A.M. Emelyanov, O.O. Briukhova

The article presents the reasons for withdrawal of licenses from the Russian commercial banks in the post-crisis period from 01 January 2010 to 31 December 2011. Logistic regression is used to predict the financial stability of the banks. The model is built on the basis of monthly balance sheet statements, taken five months before observing the status of the bank. The impact of unbalanced sample on the forecasting accuracy of the model is also discussed.

Keywords: bank, failure prediction, logit-model, financial ratios.

JEL Classification: G210, C530.