

МОДЕЛИРОВАНИЕ РИСКА ДЕФОЛТА РОССИЙСКИХ БАНКОВ, 2015–2020 гг.¹

*М.А. Щепелева, К. Тусипкалиев,
М.И. Столбов*

DOI: 10.33293/1609-1442-2024-2(105)-101-124

EDN: CXQVQD

Аннотация. Исследование посвящено моделированию вероятности дефолта российских банков на данных за период 2015–2020 гг. Исследований дефолтов российских банков после 2015 г. сравнительно немного. Наша работа призвана восполнить этот пробел. Цель исследования состоит в выявлении переменных, статистически значимо влияющих на риск дефолта российских банков в условиях относительно стабильного развития российской экономики (2015–2020 гг.) без таких внешних шоков, как COVID-19 или международные санкции. В работе используется комплексный подход к моделированию риска дефолтов банков. Модельный аппарат представлен логит-, пробит-моделями, а также регрессией Кокса. В качестве объясняющих переменных ис-

пользовались индикаторы, характеризующие различные аспекты функционирования кредитных организаций (в соответствии с методологией CAMELS), а также макроэкономические переменные. Наиболее значимыми предикторами дефолта оказались норматив достаточности капитала Н1, чистые активы банка, отношение кредитного портфеля к активам, обеспеченность кредитного портфеля имуществом, отношение выданного количества межбанковских кредитов к активам, а также инфляция (INF) и цена закрытия индекса Московской биржи (MOEXIN). В целом полученные результаты согласуются с системой показателей устойчивости коммерческих банков CAMELS, при этом влияние общих макроэкономических показателей оказывается незначимым. Результаты исследования представляют интерес для регулятора в целях текущего надзора и предупреждения риска дефолта, самих кредитных организаций с целью построения внутренних систем мониторинга финансовой устойчивости и участников финансового рынка для выбора наиболее устойчивых компаний с точки зрения инвестирования и размещения средств. Дальнейшие направления исследования связаны с включением в анализ кризисного периода и сравнением значимых предикторов в кризис и в стабильный период развития экономики, а также с использованием альтернативных методов, в частности, алгоритмов машинного обучения. *Ключевые слова:* банковский дефолт, кредитный рейтинг, CAMELS, логистическая регрессия, регрессия Кокса, методы машинного обучения.

Классификация JEL: G17, G21, G33.

Для цитирования: Щепелева М.А., Тусипкалиев К., Столбов М.И. (2024). Моделирование риска дефолта российских банков, 2015–2020 гг. // Экономическая наука современной России. № 2 (105). С. 101–124. DOI: 10.33293/1609-1442-2024-2(105)-101-124; EDN: CXQVQD

¹ Исследование выполнено за счет гранта Российского научного фонда (проект № 23-18-00756).

© Щепелева М.А., Тусипкалиев К., Столбов М.И., 2024 г.

Щепелева Мария Александровна, кандидат экономических наук, доцент, Национальный исследовательский университет «Высшая школа экономики», Москва, Россия; mshchepeleva@hse.ru, mschepeleva@yandex.ru; ORCID: 0000-0001-9107-3173; eLibrary SPIN: 6588-5218
Тусипкалиев Кайрат, Национальный исследовательский университет «Высшая школа экономики», Москва, Россия; ktusipkaliev@edu.hse.ru.

Столбов Михаил Иосифович, доктор экономических наук, профессор, заведующий кафедрой прикладной экономики, Московский государственный институт международных отношений (МГИМО МИД России), Москва, Россия; stolbov.m@my.mgimo.ru; eLibrary SPIN: 7045-0570

ВВЕДЕНИЕ

В российской экономике кредитные организации играют определяющую роль, поскольку на них приходится наибольшая доля в активах всех институтов финансовой системы. В этой связи кредитные организации являются объектами пруденциального регу-

лирования и надзора. В частности, банкам необходимо соответствовать жестким требованиям для получения лицензии, а в дальнейшем – неукоснительно соблюдать регуляторные нормативы для ведения операционной деятельности.

Если кредитная организация нарушает установленные нормативы регулирования, Банк России может отозвать ее лицензию. Вместе с тем отзыв лицензии вряд ли можно признать оптимальным решением. В этом случае начинается процесс погашения задолженности перед кредиторами банка. Он, как правило, занимает длительное время. Кроме того, данный процесс сопряжен с так называемым риском неполного взыскания задолженности, возникающим в случае недостаточного объема средств для погашения долгов перед кредиторами.

В этой связи анализ факторов дефолта кредитных организаций представляет значительный теоретический и практический интерес. Несмотря на наличие ряда влиятельных работ, посвященных причинам дефолтов российских банков, которые были опубликованы десять и более лет назад (например, (Lanine, Vennet, 2006; Peresetsky, Karminsky, Golovan, 2011; Андреасян, 2000; Карминский, Костров, 2013; Пересецкий, 2013)), исследований, опирающихся на данные после 2015 г., сравнительно немного. Наше исследование призвано отчасти восполнить данный пробел в литературе². Отличительными особенностями этой работы являются комплексный эконометрический подход к моделированию вероятности дефолта российских банков, включающий построение логит-, пробит-моделей и регрессии Кокса на данных за 2015–2020 гг., которые предваряет развернутый литературный обзор количественных методов, используемых для этой цели. Поскольку на современном этапе

традиционные эконометрические методы, используемые при моделировании вероятности дефолта, конкурируют с алгоритмами машинного обучения, в исследование также было включено приложение, характеризующее особенности применения этого относительно нового инструментария. В дальнейшем на базе составленного обзора методов машинного обучения можно будет провести расчеты для проверки устойчивости результатов, полученных с помощью перечисленных выше традиционных эконометрических моделей.

Выводы, полученные по итогам проведенного нами эмпирического анализа, отличаются новизной в части использованных данных, а также выявления показателей, которые клиенты коммерческих банков и мегарегулятор (Банк России) могут использовать для дистанционного мониторинга финансовой устойчивости кредитных организаций.

Представленное исследование структурировано следующим образом. В разделе 1 обсуждаются теоретические подходы к моделированию дефолтов банков. Раздел 2 характеризует данные и методологию, которые применяются в настоящем исследовании. В разделе 3 обсуждаются полученные результаты. В разделе 4 суммируются основные выводы по итогам эмпирического исследования.

1. ОСНОВНЫЕ ПОДХОДЫ К МОДЕЛИРОВАНИЮ ВЕРОЯТНОСТИ ДЕФОЛТА БАНКОВ

Одними из наиболее популярных показателей устойчивости кредитных организаций, широко представленных во многих эмпирических исследованиях, являются размер активов и капитализации (Peresetsky, Karminsky, Golovan, 2011). При этом размер банка, как правило, измеряется через натуральный логарифм абсолютной величины активов, а капитализация – через отношение капитала к активам.

² При подготовке статьи использовались материалы выпускной квалификационной работы «Моделирование риска дефолта банков» выпускника бакалавриата Факультета экономических наук НИУ ВШЭ 2023 г. К. Тусипкалиева.

В исследовании (Peresetsky, Karminsky, Golovan, 2011) оценивается нелинейный характер влияния достаточности капитала. Данный эффект находит подтверждение, так как банк, у которого капитализация находится на низком уровне, сталкивается с риском нехватки средств на покрытие принятых обязательств (рисков). В то же время если у банка данный показатель достигает чрезвычайно высоких значений, это может указывать на неэффективное привлечение и использование заемного финансирования.

Как правило, существенное воздействие на устойчивость банка оказывают показатели ликвидности. В условиях нехватки ликвидности вероятность дефолта кредитной организации может повышаться, поскольку, хотя достаточный объем ликвидности и не увеличивает отдачи от инвестиций, он позволяет банку уверенно рассчитывать с кредиторами и вкладчиками (Lanine, Vennet, 2006). В то же время применительно к российским банкам имеются некоторые свидетельства того, что чрезмерное создание ликвидности банками (liquidity creation) также сопряжено с повышенным риском дефолта, так как относительно неликвидные активы при этом вынужденно фондируются высоколиквидными пассивами (Fungáčová, Turk, Weill, 2021).

В отношении российских банков значимость нормативов капитала и ликвидности подтверждается в работе (Класс, Класс, 2018). Авторы строят модель прогнозирования риска дефолта банка на основе 16 показателей, из которых наиболее значимыми оказывается показатель достаточности основного капитала (Н1.2), отношение совокупной величины крупных кредитных рисков к капиталу (Н7), а также отношение ликвидных активов к краткосрочным обязательствам (Н3).

В качестве других потенциальных предикторов дефолтов, относящихся к деятельности банка, часто рассматривают показатели рентабельности. В работе (Хасянова, Цыганова, 2018) на выборке из 49 банков Московского региона было показано, что большой пользой для оценки устойчивости банков обладает по-

казатель рентабельности капитала наряду с чистой процентной маржи. На основе сигнального подхода авторы установили, что эти показатели отличались наибольшей волатильностью на протяжении нескольких лет до банкротства. Соответственно, их можно рассматривать как эффективные опережающие показатели банкротства банков из рассматриваемой группы.

В работе (Бывшев, Прокопчина, Мищенко, 2021) тем не менее авторы утверждают, что коэффициенты ROA и ROE не могут быть использованы в анализе для выявления проблемных банков из-за их неудовлетворительного отражения состояния банков. При этом авторы все же отмечают, что эти показатели содержат некоторую информацию о состоянии банка, при этом немного большей дискриминационной способностью обладает коэффициент ROA.

Помимо специфических отраслевых предикторов вероятности дефолта, было установлено, что качество прогнозных моделей вероятности дефолта может быть улучшено за счет включения макроэкономических и институциональных факторов. Это обусловлено тем, что некоторые из макроэкономических и институциональных переменных имеют потенциал в качестве опережающих индикаторов дефолта. Среди них чаще всего в модели оценки вероятности дефолта включают темп инфляции, норму безработицы, динамику роста ВВП и доходов населения, а также чистый экспорт (Карминский, Пересецкий, Петров, 2005).

В работе (Яшина и др., 2017) также используется широкий спектр как макро-, так и микроэкономических переменных, из которых затем путем корреляционного анализа отбираются наиболее релевантные для логит-регрессии. Согласно полученным результатам, среди четырех наиболее значимых факторов для прогнозирования банкротств российских банков в 2015–2016 гг. присутствуют две макроэкономические переменные – курс доллара и отток капитала из страны.

Форма собственности банка, а также индексы Лернера и Герфиндаля – наиболее популярные институциональные переменные.

В частности, применительно к России в исследовании экспертов Института переходных экономик Банка Финляндии было установлено, что для банков с государственным участием риск несостоятельности менее выражен по сравнению с кредитными организациями с участием иностранного капитала (Fungacova, Solanko, 2009). Такой результат может быть связан с тем, что государственные банки при возникновении финансовых проблем имеют возможность получать от регулятора рефинансирование и облегченный доступ к рынку межбанковских кредитов, что снижает вероятность наступления дефолта.

Уровень конкуренции и рыночной власти, как правило, измеряют индексом Лернера. Большинство исследователей солидарны в том, что рыночная власть банка отрицательно коррелирована с вероятностью дефолта. Такой вывод связан с тем, что, не испытывая серьезной конкуренции, банк не нуждается в использовании рискованных стратегий расширения ресурсной базы, следуя консервативной политике и тем самым экономя средства. Применительно к российскому банковскому сектору отрицательная взаимосвязь между рыночной властью и вероятностью дефолта подтверждается в работе (Fungáčová, Weill, 2013).

В литературе обсуждается большое число методов оценки вероятности дефолта кредитных организаций. В частности, в исследовании (Тотьмянина, 2011) приводятся наиболее значимые методы моделирования риска дефолта, которые могут быть классифицированы следующим образом:

- рыночные модели;
- модели на основе фундаментальных показателей;
- модели на основе макроэкономических показателей;
- модели на основе финансовых показателей;
- модели на основе методологии рейтинговых агентств;
- продвинутые модели.

Для построения *рыночных моделей* используются ежедневные котировки ценных

бумаг. В свою очередь, рыночные модели включают структурные и модели сокращенных форм.

Главная предпосылка *структурных моделей* состоит в том, что стоимость акции компании представляет собой колл-опцион (call) на активы данной фирмы. При этом размер долга компании равняется цене исполнения данного опциона. Американские экономисты Р. Мертон, Ф. Блэк и М. Шоулз стали основоположниками структурных моделей вероятности дефолта. В частности, Р. Мертон рассматривал выдачу ссуды как покупку активов у собственников компании с последующей передачей опциона call на эти активы, где цена исполнения опциона равна стоимости кредита, а срок погашения кредита равен времени исполнения опциона. В этих расчетах он использовал формулу ценообразования опционов Блэка–Шоулза. Однако основанием для критики применения структурных моделей является предположение о нормальности распределения доходности актива. Эта предпосылка вменяется нормальностью распределения, заложенной в формулу Блэка–Шоулза.

Модели сокращенных форм базируются на текущей стоимости долговых бумаг и спредов их доходности к безрисковой ставке. Позволяя оценить риск наступления дефолта, они не дают возможности выявить факторы, влияющие на его наступление.

Опора на рыночные данные является широко распространенным методом моделирования вероятности дефолта. Тем не менее такие модели имеют существенный недостаток, который заключается в предпосылке эффективности функционирования финансового рынка. В случае развивающихся стран и стран с формирующимся рынком, включая Россию, гипотеза о сильной форме эффективности финансового рынка, как правило, не выполняется. Это обстоятельство ограничивает возможности применения данной подгруппы моделей вне развитых экономик.

Далее рассмотрим класс моделей, основанных на *фундаментальных показателях*.

Они базируются на показателях финансовой отчетности кредитных организаций и макроэкономические индикаторах.

В моделях на основе *макроэкономических показателей* подразумевается, что вероятность дефолта коррелирует с фазой делового цикла и, соответственно, повышается накануне и в период рецессии. В подобные модели включаются индикаторы, отражающие деловую активность в различных фазах бизнес-цикла и связанные с долгосрочным экономическим ростом: темпы роста промышленного производства, динамика ВВП, темпы инфляции и др. Данный метод позволяет оценить вероятность наступления дефолта на протяжении всего цикла.

Модели прогнозирования риска наступления дефолта, в основе которых лежат *низкочастотные макроэкономические индикаторы*, соответствуют так называемому методу оценки «по циклу» (through-the-cycle, TTC). Напротив, модели вероятности дефолта, рассчитанные на краткосрочный период, соответствуют методу оценки «в точке» (point-in-time, PIT). Как известно, факторы, воздействующие на переменную интереса, в экономической теории подразделяются на внутренние, или эндогенные, и внешние, т.е. экзогенные. В этой связи модели, которые базируются на макроэкономических показателях, также подразделяются на две группы. Модель Уилсона (Wilson, 1997, pp. 111–117) использует экзогенные макроэкономические переменные. На базе этой модели международная консалтинговая компания McKinsey разработала программный пакет Credit Portfolio View.

Также были предложены модели с внутренними (эндогенными) макроэкономическими факторами. Они основываются на методологии векторных авторегрессий. В практической деятельности модели такого типа используют в рамках программы оценки финансового сектора FSAP (Financial Sector Assessment Programme), которая реализуется Международным валютным фондом (МВФ) (Chan-Lau, 2006). Достоинством моделей на базе макроэкономических показателей явля-

ется возможность оценки долгосрочной вероятности наступления дефолта. Однако их слабая сторона состоит в том, что, как правило, они не пригодны для оценки вероятности дефолта отдельно взятого банка. Вследствие этого на микроуровне такие показатели используют для уточнения ранее созданных моделей оценки вероятности дефолта.

Значительную роль в настоящее время играют модели, построенные по принципу присвоения кредитных рейтингов. М. Тамари (Tamari, 1966) впервые предложил подход, согласно которому тому или иному компоненту финансовой устойчивости банка ставился в соответствие определенный балл. При этом, как правило, использовалась шкала от 0 до 100 баллов. Число баллов, близкое к 100, – признак финансовой устойчивости фирмы. При вычислении интегрального балла наиболее значимые компоненты финансовой устойчивости получали больший вес.

В рамках моделей на основе методологии рейтинговых агентств используется так называемый *метод матриц межгрупповых переходов* (cohort approach). Построение матрицы перехода необходимо для оценки частоты пересмотра кредитного рейтинга заемщика (Chan-Lau, 2006). Вероятность дефолта моделируется либо на основе исторических данных, либо как марковский процесс. Основное свойство марковского процесса состоит в том, что будущие значения вероятности дефолта определяются исключительно ее значением в текущий момент времени, а влияние лагов не учитывается. В рамках рассматриваемого класса также разработан метод, учитывающий не только результат деятельности банка на конец отчетного периода, но и временную структуру активов и пассивов. Он основан на расчете показателя дюрации, учитывая постепенный переход заемщика к состоянию дефолта на рассматриваемом временном горизонте. Этот метод демонстрирует хорошую предсказательную способность при прогнозировании вероятности дефолта. В то же время его сравнительно просто применять. Тем не менее он не может использоваться в случаях,

когда заемщики не имеют кредитного рейтинга. Кроме того, объективные временные лаги сказываются на его эффективности, причем эти лаги связаны с пересмотром кредитных рейтингов.

В настоящее время растет популярность методов, которые составляют класс так называемых *продвинутых моделей* (advanced models) оценки вероятности дефолта. В большинстве случаев речь идет о непараметрических методах. В качестве примеров можно назвать метод ближайших соседей, нейросетевые модели и др. Для построения нейросетевых моделей используются те же данные, что и для традиционных эконометрических моделей. Однако влияние переменных основывается не на выборе наилучшей модели, а на многократном повторении расчетов компьютерного алгоритма (Bigus, 1996).

Среди продвинутых моделей также широкое распространение получил метод оценки «стоимости под риском» (VaR, Value-at-Risk). Данный метод изначально был разработан для оценки рыночного риска. Он помогает определить потенциальные (максимальные) убытки по кредитному портфелю. Моделирование дефолта с помощью продвинутых моделей дает в основном хорошие результаты, но является трудоемким. Этот факт заставлял исследователей искать компромисс между сложностью модели и приемлемым уровнем ее прогнозной точности. Соответственно, не всегда выбор делался в пользу более продвинутого инструментария. Например, Э. Альтман и соавторы в своем исследовании добились лучшей предсказательной силы модели, основанной на более простом дискриминантном анализе по сравнению с нейросетевыми моделями (Altman, Marco, Varetto, 1994).

Еще один класс моделей основывается на данных финансовой отчетности. Подобный подход является весьма распространенным, так как получение доступа к отчетности кредитных организаций не представляет большого труда, за исключением форс-мажорных внешних обстоятельств, когда раскрытие информации ограничивается регулятором. Моде-

ли на основе финансовой отчетности подразделяются на несколько групп в зависимости от статистического подхода к ее обработке:

- скоринговые модели;
- модели на основе дискриминантного анализа;
- модели бинарного выбора.

Скоринговые модели были введены в научный и практический оборот в 1940-е годы. Данный подход подразумевает присвоение каждому заемщику определенного рейтинга. Заемщик попадает в одну из рейтинговых групп, где каждому баллу поставлена в соответствие определенная вероятность риска дефолта. Применение скоринговых моделей широко распространено в практической и исследовательской деятельности.

Однако в российских реалиях такие модели имеют существенный недостаток. Речь идет о нехватке исторических данных, так как по сравнению с большинством развитых стран российский банковский сектор оперирует в рыночных условиях сравнительно недавно. Это представляет существенную проблему для корректного анализа рисков наступления дефолта при использовании скорингового подхода.

Среди многомерных статистических методов модели на основе дискриминантного анализа стали применяться одними из первых в целях моделирования дефолтов. В 1968 г. Э. Альтман предложил модель Z-Score на основе многомерного дискриминантного анализа (Altman, 1968). Однако точность предсказания вероятности дефолта с помощью этих моделей вызывает вопросы, так как они главным образом предназначены для классификации банков, исходя из размера риска наступления дефолта, но сами не генерируют точных вероятностей.

Следующая группа включает модели бинарного выбора. Вряд ли будет преувеличением утверждать, что данные модели до недавнего времени оставались основными при моделировании вероятности дефолта (Ploeg, 2010) как среди зарубежных, так и российских исследователей.

В целом в исследованиях по данной проблематике до начала 1980-х годов основным методом был дискриминантный анализ. Тем не менее эмпирические данные не всегда соответствовали предпосылкам, обеспечивающим корректное применение данного метода. Например, как правило, нарушались предпосылки о нормальном законе распределения данных финансовой отчетности, а также о равенстве ковариационных матриц банков, испытавших дефолт и продолжающих работать. В статье Д. Мартина, вышедшей в 1977 г., был предложен альтернативный подход к моделированию вероятности дефолта, который не требовал соблюдения указанных выше предпосылок и основывался на логистической регрессии (Martin, 1977).

В своем исследовании Мартин проанализировал выборку из 5598 коммерческих банков, подотчетных Федеральной резервной системе США по состоянию на 1974 г., из которых 23 были признаны банкротами. 25 показателей, рассчитанных на основе финансовой отчетности банков, которые составили данную выборку, рассматривались в качестве предикторов вероятности дефолта. Регрессоры были распределены на четыре группы, которые характеризовали соответственно прибыльность банка, ликвидность, достаточность капитала и качество активов.

Позже, в 1984 г., Эйвери и Ханвек провели похожее исследование также с использованием логистической регрессии (Avery, Hanweck, 1984). Их выборка охватывала 1290 банков, из которых 100 были признаны банкротами. В исследовании рассматривался период с 1978 по 1983 г. Изначально в модель вошли девять показателей. Пять из них показали значимость и были включены в итоговую модель. Статистически значимые переменные из работы Эйвери и Ханвека также можно разделить на группы, предложенные в работе Мартина, что стало подтверждением перспективности оценок вероятности дефолта банков с помощью логистической регрессии.

Применительно к российскому банковскому сектору *логистическая регрессия* по

сей день остается одной из наиболее часто используемых моделей для прогнозирования риска дефолта банка. Так, этот метод был применен в недавно опубликованных работах (Широбокова, 2018), а также (Давыденко, Козаченко, 2021).

В диссертационной работе (Андреасян, 2000) показано, что логит-, наряду с пробит-моделью и дискриминантным анализом, дает хорошие результаты для российского банковского сектора, в то время как моделирование с помощью нейронных сетей зачастую связано с проблемой «переобучения» модели, сложностями в подборе параметров, архитектурой сети, выбором функции активации и общей слабой интерпретируемостью результатов. При этом автор отмечает, что указанные выше статистические методы хорошо работают только для группы банков, которые не находятся в сильной зависимости от мощных холдингов и финансово-промышленных групп. Оценка риска банкротства в рассматриваемой работе проводилась по 32 показателям, среди которых есть показатели достаточности капитала, качества активов, уровня менеджмента банка, доходности, ликвидности (CAMEL – см. ниже), а также показатели структуры пассивов и обороты за месяц по некоторым счетам.

На раннем этапе внедрения количественных методов в оценку вероятности дефолта Федеральной резервной системой (ФРС) США была разработана *рейтинговая система дистанционного анализа банков*, известная под аббревиатурой CAMEL. Первоначально ее название, действительно, состояло из этих пяти букв, но с 1997 г. появилась еще одна буква S – sensitivity, означающая уязвимость кредитных организаций к рыночному риску.

В период глобального финансового кризиса 2008–2009 гг. с помощью рейтинговой системы CAMELS осуществлялся отбор американских банков, которым предоставлялась финансовая поддержка в рамках плана мероприятий, направленных на спасение финансового сектора США, известного как План Полсона.

В данной рейтинговой системе предусмотрена пятибалльная шкала, в которой балл,

равный единице, означает наиболее прочное финансовое положение кредитной организации, а балл, равный пяти, – наименьшую степень финансовой устойчивости. Важно отметить, что для предотвращения набегов на банки (bank-runs), при которых вкладчики стали бы массово изымать средства из банков с низким уровнем финансовой устойчивости, согласно CAMELS, балльные оценки не публикуются. Важно отметить, что речь идет как недопущении набега на банки как со стороны физических лиц, так и предприятий. В недавнем исследовании (Chernykh, Mityakov, 2022) на примере банковской паники 2004 г. в России продемонстрировано, что вывод депозитов инициировали наиболее тесно связанные с банком корпоративные вкладчики, тогда как менее информированные юридические и физические лица ориентировались на слухи относительно устойчивости того или иного банка.

Само название рейтинговой системы образовано по первым буквам наименований компонентов оценки положения банков (более подробное описание можно посмотреть, например, в работе (Makinen, Solanko, 2018)).

1. *C* – capital. Данный компонент показывает, насколько хорошо капитализирован банк. Для его оценки, как правило, рассчитывают отношение капитала к активам или используют норматив достаточности капитала (Н1 – в российской практике). Высокие значения свидетельствуют о должном уровне капитализации кредитной организации. Однако капитализация банка, заметно превышающая средний уровень по системе в целом, может трактоваться и с негативной стороны, указывая на недостаточный уровень долгового финансирования либо на увеличение резервов (Зубарев, Бекирова, 2020). Экстремальным частым случаем является переход капитала к отрицательным значениям, который, как правило, сопровождается фабрикацией отчетности (Karminsky, Kostrov, 2016).

2. *A* – assets. Этот компонент аппроксимируется логарифмом чистых активов. Увеличение масштаба банковского бизнеса может формировать определенные паттер-

ны поведения, которые подрывают финансовую устойчивость. В силу уверенности топ-менеджмента крупных кредитных организации в предоставлении государственной поддержки в условиях финансовой турбулентности в форме рефинансирования или даже рекапитализации они зачастую принимают на себя избыточные риски. Государство же рассматривает такие банки как системно значимые для экономики (“too-big-to-fail”, т.е. «слишком большие, чтобы обанкротиться»). Несмотря на многолетние попытки создать эффективные подходы к регулированию таких институтов, в лучшем случае имеется некоторый прогресс на уровне теоретических подходов (Philippon, Wang, 2023).

3. *M* – management. Качество управления банком можно оценить с помощью логарифма отношения оборота средств на корреспондентских счетах к чистым активам. Повышенные значения данного показателя могут трактоваться двояко: либо он указывает на здоровое увеличение операций банка, либо иногда, напротив, он указывает на хаотичный характер проводимых операций, панику топ-менеджмента, а, возможно, и на вывод средств. В то же время низкое значение показателя практически всегда сигнализирует о структурных проблемах организации в осуществлении расчетов и платежей.

4. *E* – earnings. Этот компонент CAMELS можно оценить с помощью отношения балансовой прибыли к чистым активам. Отрицательные значения свидетельствуют об убыточности кредитной организации. Считается, что с точки зрения прогнозирования дефолта роль данного компонента CAMELS – наиболее весомая. Однако чрезмерно высокие значения отношения балансовой прибыли к чистым активам также могут иметь негативную интерпретацию. А. Зубарев и К. Шилов (Зубарев, Шилов, 2022) доказывают, что для российских банков нормальное значение этого показателя близко к среднему по сектору.

5. *L* – liquidity. Отношение вложений в ценные бумаги к чистым активам банка – один из ключевых параметров состояния

ликвидности. Когда данный показатель существенно превышает средний уровень по системе в целом, банк сталкивается с более высокой вероятностью дефолта. Рассматриваемый показатель имеет также отношение и к чувствительности кредитной организации к рыночному риску (компонент S), поскольку вложения в ценные бумаги не только влияют на ликвидную позицию, но в зависимости от видов финансовых инструментов и рынков, на которых оперирует банк, воздействуют на величину фондового, валютного и процентного рисков.

Согласно исследованию (Makinen, Solanko, 2018), показатели, входящие в рейтинговую систему CAMELS, обладают прогностическим потенциалом в отношении вероятности дефолта также и российских банков. При этом наиболее существенно влияет именно компонент ликвидности, так как (в отличие от других индикаторов) он оказывается статистически значимым на интервале до четырех кварталов, предшествующих дефолту. Недавнее исследование (Barajas, Krakovich, Lopez-Iturriaga, 2023) демонстрирует, что на вероятность дефолта российских банков влияют практически все компоненты CAMELS. Они дополнительно подчеркивают, что важным фактором, отрицательно коррелированным с вероятностью дефолта, является участие в капитале иностранных банков. Признавая значимость компонентов CAMELS, авторы работы (Chernykh, Kotomin, 2022) также отмечают, что важным предиктором банковского дефолта выступает стоимость привлечения депозитных ресурсов. Уровень процентных ставок, существенно превышающий среднерыночный уровень, должен восприниматься как фактор, увеличивающий вероятность дефолта. Аналогичный вывод сделан в работе (Bondarenko, Semenova, 2018).

Проведенный нами обзор литературы позволяет констатировать, что проблематика прогнозирования дефолтов кредитных организаций сохраняет актуальность. Интерес в разработке новых подходов к минимизации вероятности дефолта проявляют как сами кредитные организации, так и регуляторы, в том числе Банк России.

На фоне опережающего развития информационных технологий для этой цели все шире применяют различные *алгоритмы машинного обучения*. Тем не менее пока не очевидно, являются ли они более удачной альтернативой традиционным эконометрическим методам. Во многом подобная неопределенность объясняется недостаточным числом исследований, опирающихся на методы машинного обучения, а также довольно обширным меню этих алгоритмов. На российских данных, насколько известно, было подготовлено всего несколько работ, в которых в целях моделирования вероятности дефолта банков использовались методы машинного обучения. Применив «модель случайного леса» для оценки факторов банковских дефолтов в 2015–2016 гг., У. Синельникова-Мурылева и соавторы (Синельникова-Мурылева, Горшкова, Макеева, 2018) показали, что рост показателей прибыльности и достаточности капитала предсказуемо уменьшает вероятность наступления дефолта, тогда как удельный вес совокупного кредитного портфеля в активах, наряду с повышенной долей кредитов, выданных промышленным предприятиям, оказывают противоположное воздействие. В исследовании (Shibitov, Mamedli, 2019) проведено сравнение эффективности применения ряда методов машинного обучения в целях прогнозирования дефолтов российских банков, а также нарушения ими ключевых регуляторных нормативов в период с февраля 2014 г. по октябрь 2018 г. Авторы показали, что в целом примененные методы способны составить конкуренцию логистической регрессии. Наиболее перспективными из них были признаны *модель случайного леса* и *стекинг*, которые превосходили альтернативные подходы – *нейронные сети* и *градиентный бустинг*.

На фоне усиливающейся конкуренции со стороны альтернативных методов логистическая регрессия тем не менее сохраняет состоятельность при оценке риска неплатежеспособности банков. Спустя более чем полвека после внедрения этого метода он демонстрирует удовлетворительную прогнозную

силу при изучении проблемных банков. В следующих разделах он применяется для оценки вероятности дефолта на выборке российских банков в период 2015–2020 гг.

2. МЕТОДОЛОГИЯ И ДАННЫЕ ЭМПИРИЧЕСКОГО ИССЛЕДОВАНИЯ

2.1. Модельные подходы к оценке вероятности дефолта

2.1.1. Логистическая регрессия

После того как в 1977 г. логистическая регрессия была впервые применена для прогнозирования вероятности дефолта банков, данный метод обошел по уровню востребованности все прочие альтернативы. Он представляет один из частных случаев обобщенной линейной модели (GLM), основанной на биномиальном выборе. При дальнейшей работе с логистической регрессией обозначим зависимую переменную – вероятность дефолта – через DEF . Она определяется как функция вектора ковариант X_i и вектора коэффициентов регрессии β . Ее можно записать в общем виде следующим образом:

$$DEF_i = f(X_i\beta + \varepsilon_i). \quad (1)$$

В случае функции DEF_i прогнозные значения могут выходить за пределы интервала от 0 до 1. Это связано с тем, что X_i и β , строго говоря, могут принимать любые значения. Чтобы устранить данную проблему в получении эконометрических оценок, представим вероятность дефолта PD_i как отношение шансов, т.е. как вероятность дефолта, деленную на вероятность сохранения банком состояния платежеспособности:

$$Ratio_i = \frac{DEF_i}{1 - DEF_i}. \quad (2)$$

В отличие от значений, принимаемых PD_i , отношение шансов может быть исключительно положительной величиной, которая

при значениях вероятности дефолта, превышающей 50%, будет больше 1. Затем переходим к логарифму отношения шансов, так называемому логиту:

$$\log\left(\frac{DEF_i}{1 - DEF_i}\right) = \text{logit}(DEF_i). \quad (3)$$

Логарифмирование позволяет снять нулевую нижнюю границу для отношения шансов. Если DEF_i близка к нулю, то отношение шансов также стремится к 0, тогда как логит устремлен к $-\infty$. Данный принцип начинает работать в обратном направлении, когда DEF_i стремится к 1, отношение шансов и логит стремятся к $+\infty$. Таким образом, при логарифмировании отношения шансов диапазон значений, которая пробегает функция DEF_i расширяется до диапазона $(-\infty, +\infty)$.

$$\text{logit}(DEF_i) = X_i\beta;$$

$$\begin{cases} (DEF_i = 1) \rightarrow 1, & \text{если } X_i\beta \rightarrow +\infty; \\ (DEF_i = 1) \rightarrow 0, & \text{если } X_i\beta \rightarrow -\infty. \end{cases} \quad (4)$$

Необходимо подчеркнуть, что зависимой переменной выступает именно логит-вероятность, а не сама вероятность дефолта, так как коэффициент β влияет на изменение логит-вероятности. Путем возведения уравнения (3) в степень имеем:

$$\frac{DEF_i}{1 - DEF_i} = \exp(X_i\beta). \quad (5)$$

Далее преобразуем в логистическую функцию распределения вероятностей события:

$$DEF_i = \frac{\exp(X_i\beta)}{[1 + \exp(X_i\beta)]}. \quad (6)$$

2.1.2. Регрессия Кокса

В отличие от логистической регрессии, риск дефолта в данной модели не тождественен вероятности этого события. Соответственно, значения зависимой переменной могут выходить за пределы диапазона, ограниченного 0 и 1.

По аналогии с пациентами, находящимися в критическом состоянии в медицинском учреждении, объектами наблюдений в данной модели выступают кредитные организации, пребывающие на грани дефолта. Для наблюдения над ними объект (банк) включается в специальную группу риска, который может реализоваться в любой момент. После того как событие (дефолт) случилось, банк исключается из группы риска.

Время в модели – интервал между моментом включения банка в группу риска и его выбытием из данной группы после наступления дефолта. Он должен быть достоверно определен для каждого банка в составе группы. Предикторы в регрессии Кокса характеризуют объект, т.е. уровень функционирования банков. В случае с анализом выживаемости в буквальном смысле примером предиктора может быть, например, возраст и/или пол пациента, а в случае оценки риска дефолта, например, величина чистых активов кредитной организации и другие индикаторы, которые обсуждались выше в обзоре литературы.

Перечислим ключевые предпосылки, лежащие в основе корректной оценки регрессии Кокса:

- независимость предикторов между собой;
- линейное влияние предикторов на логарифм риска наступления события;
- пропорциональность рисков наступления событий для двух объектов в любой момент времени.

На основе предшествующих рассуждений риск наступления события для объекта i может быть представлен как:

$$hazart_i(t) = hazart_0(t) \cdot \exp(B_1 X_{i1} + B_2 X_{i2} + \dots + B_p X_{ip}), \quad (7)$$

где $hazart_0(t)$ – базовый риск, эквивалентный для всех наблюдений; B_1, \dots, B_p – коэффициенты; X_1, \dots, X_p – предикторы.

Показатель базового риска $hazart_0(t)$ представляет собой риск наступления определенного события для наблюдения из иссле-

дуемой (референтной) группы. При этом все регрессоры X_1, \dots, X_p равняются 0.

B_1, \dots, B_p – коэффициенты, показывающие, какое влияние оказывает регрессор на функцию риска. Это означает, что если регрессор X_j увеличивается на единицу при условии неизменности прочих предикторов, то риск наступления события возрастает в $\exp(B_j)$ раз.

Необходимо отметить, что регрессия Кокса, или модель пропорциональных рисков, идеологически близка к логистической регрессии как с точки зрения тестируемой нулевой гипотезы – отсутствия влияния предиктора на риск наступления события, так и способов эконометрической оценки – метода максимального правдоподобия. Однако, несмотря на «родственный» характер двух моделей, регрессия Кокса, насколько известно, использовалась при моделировании дефолтов российских банков считанное число раз (в работах (Carree, 2003; Orbe, Núñez-Antón, 2011; Tankoyeva, Bazzana, Gabriele, 2018)). Результаты перечисленных работ в целом согласуются с исследованиями по России, упомянутыми в разделе 1. При использовании регрессии Кокса наиболее значимыми предикторами дефолтов оказались показатели достаточности капитала и ликвидности.

2.2. Данные

Данные для эмпирической части исследования взяты с сайта banki.ru. Массив используемых данных состоит из ежемесячных рядов банковских и макроэкономических индикаторов, взятых за период с февраля 2015 г. по апрель 2020 г. Данный интервал выбран целенаправленно с целью оценить вероятность дефолта российских кредитных организаций в отсутствие таких значимых внешних шоков, как острый период пандемии COVID-19 в 2020–2021 г. и усиление санкционного давления с марта 2022 г.

Всего в выборку вошло 817 банков, имевших лицензию и осуществлявших деятельность на территории России на 01.02.2015.

Основное внимание уделяется показателям, характеризующим финансовое состояние кредитных организаций. Для оценки достаточности капитала и ликвидности банков была получена динамика нормативов Н1 и Н3. Для оценки прибыльности использовались показатели рентабельности активов и собственного капитала – ROA и ROE. Остальные банковские переменные, представленные в виде финансовых коэффициентов, также согласуются с рейтинговым подходом CAMELS.

Блок макроэкономических индикаторов представлен индексом выпуска товаров и услуг по базовым видам деятельности, темпами роста ВВП и инфляции. С учетом ресурсной специализации российской экономики была также включена динамика нефтяных цен и чистого экспорта. Включение нефтяных цен в состав регрессоров не только диктует-

ся общими соображения. В недавней работе (Albulescu, 2022) показано, что рост нефтяных цен консолидирует устойчивость крупнейших российских банков в долгосрочном периоде, хотя подобный краткосрочный эффект и не наблюдается.

Для учета ситуации на финансовых рынках в состав предикторов вошел индекс Мосбиржи. Полный перечень показателей, которые использовались в расчетах, приведен в табл. 1.

3. РЕЗУЛЬТАТЫ РАСЧЕТОВ И ИХ ОБСУЖДЕНИЕ

Полученный массив данных был разбит на тестовую и тренировочную выборки. При этом соблюдались следующие условия:

Таблица 1

Перечень индикаторов, использованных в расчетах

Сокращенное название	Тип	Определение
ROE	Банковский	Рентабельность капитала
ROA	Банковский	Рентабельность активов
Н1	Банковский	Норматив достаточности капитала
Н3	Банковский	Норматив среднесрочной ликвидности
NLGAS	Банковский	Логарифм чистых активов
DLF/ASS	Банковский	Доля вкладов физических лиц в пассивах
INV/ASS	Банковский	Отношение вложений в ценные бумаги к активам
IS_MKB	Банковский	Отношение выданных МБК к активам
CRP/ASS	Банковский	Отношение кредитного портфеля к активам
RA_MKB	Банковский	Отношение полученных МБК к активам
SECURITY	Банковский	Показатель уровня обеспеченности кредитного портфеля имуществом
GDP_GRW	Макроэкономический	Темп прироста ВВП
INF	Макроэкономический	Темп инфляции
CASH/ASS	Банковский	Отношение наличных средств к активам
LVL_NPL	Банковский	Доля просроченной задолженности в совокупном кредитном портфеле
OIL	Макроэкономический	Цена на нефть
PROV	Банковский	Показатель уровня резервирования кредитного портфеля
MOEXIN	Показатель финансового рынка	Цена закрытия индекса Московской биржи
INX_ECON	Макроэкономический	Темп прироста индекса выпуска товаров и услуг по базовым видам деятельности
NET_EX	Макроэкономический	Чистый экспорт
DEFAULT	Зависимая переменная	Бинарная переменная, характеризующая наличие банковского дефолта (1) или его отсутствие (0)

Источники: составлено авторами.

1) тренировочная выборка составляет 70% совокупного числа наблюдений (24 125 наблюдений месяц-банк); 2) временные промежутки в выборках различны, так что наблюдения, включенные в тестовую выборку, принадлежат к более поздним интервалам времени по сравнению с тренировочной выборкой.

Удельный вес дефолтов в тренировочной и тестовой выборках одинаковый и равен проценту дефолтов по всей выборке (0,4%) за счет использования стратификации.

Очевидно, что для всего рассматриваемого нами набора данных характерна несбалансированность данных, когда число дефолтов существенно ниже числа положительных исходов. В эконометрике и машинном обучении существуют разные способы решения этой проблемы: дублирование примеров миноритарного класса (oversampling), сокращение числа примеров мажоритарного класса (undersampling), алгоритм SMOTE, фиксация определенного гиперпараметра при построении той или иной модели. Мы руководствовались последним приемом, а именно добавлением в рассматриваемые пробит- и логит-регрессии гиперпараметра “class_weight = balanced”. Именно этот прием позволяет получать наилучшие прогнозы с помощью логит- и пробит-моделей на тестовой выборке. Другие методы работы с дисбалансом классов приводят к тому, что модели теряют точность прогнозов.

Описательные статистики для тренировочной и тестовой выборок в целом относительно гомогенны, что позволяет оценивать эконометрические модели на этих данных (см. табл. А1, А2 в Приложении)³.

Согласно анализу VIF-множителей (variance inflation factors), или множителей, увеличивающих дисперсию переменных в нашем массиве данных (см. табл. А3 в Приложении), можно сделать вывод, что ни один из рассчитанных множителей не превышает 10. Это означает, что проблема мультиколлинеарности в нашем массиве данных отсутствует.

³ Все модели, используемые в анализе, были реализованы с использованием языка Python.

В то же время коэффициенты корреляции между отдельными переменными указывают на довольно тесную линейную связь. Так, например, коэффициент корреляции между рентабельностью активов и собственного капитала составляет порядка 0,6. С учетом природы этих индикаторов такой результат является во многом естественным, но следует признать, что он может негативно отразиться на качестве итоговых моделей.

Далее производим обучение моделей пробит- и логит-регрессий на тренировочной выборке, а их качество оцениваем на базе тестовой выборки (табл. 2 и 3).

Значимыми предикторами банковских дефолтов на конвенциональном уровне ($p < 0.05$) оказываются норматив достаточности капитала (H1), норматив ликвидности (H3), логарифм чистых активов (NET_LOG_ASS), отношение выданных межбанковских кредитов к чистым активам (IS_MBK), отношение кредитного портфеля к активам (CRP/ASS), отношение полученных межбанковских кредитов (МБК) к активам (RA_MBK), показатель обеспечения выданных кредитов залоговым имуществом (SECURITY), темп инфляции (INF), а также цена закрытия индекса Московской биржи (MOEXIN). Обе модели – относительно хорошего качества: псевдо- R^2 в них достигает 0,18, что с учетом числа наблюдений можно считать довольно хорошим уровнем.

В целом результаты моделирования на данном этапе указывают на существенную роль показателей, характеризующих различные аспекты функционирования банков, т.е. согласуются с подходом на базе CAMELS. Этот вывод соответствует ранее проведенным исследованиям на российских данных, рассмотренным в разделе 1, а также с результатами мета-анализа международных исследований факторов вероятности дефолта банков, которые подтверждают роль переменных CAMELS на фоне отсутствия значимости прочих показателей (институциональных, макроэкономических и т.д.) (Koçenda, Iwasaki, 2022).

Статистическая значимость размера активов хорошо согласуется с экономической

Таблица 2
Результаты оценивания пробит-модели

Зависимая переменная: DEFAULT. Число наблюдений: 24 125

Модель: Probit

Число степеней свободы остатков: 24 104

Метод: Наибольшее правдоподобие

Число степеней свободы модели: 20

Псевдо- R^2 : 0,1765

Log-Likelihood: -600,79

LLR p -value: 3,561e-43

Название переменной	Коэффициент	Стандартная ошибка	z	$P > z $	[0,025	0,975]
Константа	0,2488	0,691	0,36	0,719	-1,106	1,604
H1	-0,0138	0,004	-3,532	0	-0,021	-0,006
H3	-0,0011	0	-2,548	0,011	-0,002	0
NET_LOG_ASS	-0,0961	0,028	-3,413	0,001	-0,151	-0,041
DLF/ASS	0,0042	0,003	1,603	0,109	-0,001	0,009
INV/ASS	-0,0103	0,004	-2,287	0,022	-0,019	-0,001
IS_MBK	-0,0202	0,006	-3,543	0	-0,031	-0,009
CRP/ASS	0,009	0,002	3,732	0	0,004	0,014
RA_MBK	0,0091	0,004	2,564	0,01	0,002	0,016
ROA	0,0045	0,004	1,266	0,205	-0,002	0,011
ROE	-0,0008	0,001	-0,591	0,555	-0,004	0,002
CASH/ASS	0,0002	0,003	0,052	0,959	-0,006	0,007
SECURITY	-0,0032	0,001	-4,532	0	-0,005	-0,002
LVL_NPL	0,0004	0,005	0,079	0,937	-0,009	0,01
PROV	0,002	0,004	0,513	0,608	-0,006	0,009
INF	-0,4251	0,198	-2,15	0,032	-0,813	-0,038
MOEXIN	-0,0004	0	-2,333	0,02	-0,001	-0,000
INX_ECONOMY	-0,0044	0,004	-1,019	0,308	-0,013	0,004
GDP_GROWTH	4,0035	5,366	0,746	0,456	-6,513	14,52
OIL	0,0055	0,006	0,854	0,393	-0,007	0,018
NET_EX	-0,0101	0,018	-0,547	0,584	-0,046	0,026

Источники: расчеты авторов,

Примечание: полужирным шрифтом выделены переменные, характеризующиеся статистической значимостью на уровне 1, 5 и 10%.

интуицией. Поскольку выборка охватывает крупнейшие кредитные организации, которые характеризуются системной значимостью, Банк России не может допустить их несостоятельности. Дефолт одного такого банка может спровоцировать масштабный набег вкладчиков, т.е. привести к оттоку средств вкладчиков также из других банков. Потенциально это может вылиться в эффект домино и начало банковского кризиса, чему регулятор должен всячески пре-

пятствовать. В то же время есть альтернативное объяснение отрицательной взаимосвязи величины активов и вероятности дефолта – наличие у более крупных кредитных организаций лучших возможностей диверсификации кредитного портфеля и вложений в ценные бумаги (Радионова, Приступина, 2017).

Значимость нормативов H1 и H3 также была ожидаемой. Эти нормативы являются обязательными для всех кредитных организа-

Таблица 3
Результаты оценивания логит-модели

Зависимая переменная: Результаты оценивания логит-модели DEFAULT

Число наблюдений: 24 125

Модель: Logit

Число степеней свободы остатков: 24 104

Метод: Наибольшее правдоподобие

Число степеней свободы модели: 20

Псевдо- R^2 : 0,1832

Log-Likelihood: -595,88

LLR p -value: 3,659e-45

Название переменной	Коэффициент	Стандартная ошибка	z	$P > z $	[0,025	0,975]
Константа	2,4467	1,772	1,381	0,167	-1,026	5,919
H1	-0,0542	0,013	-4,135	0	-0,08	-0,029
H3	-0,0029	0,001	-2,238	0,025	-0,006	0
NET_LOG_ASS	-0,2428	0,068	-3,581	0	-0,376	-0,11
DLF/ASS	0,0088	0,007	1,291	0,197	-0,005	0,022
INV/ASS	-0,0231	0,012	-1,905	0,057	-0,047	0,001
IS_MBK	-0,0661	0,018	-3,602	0	-0,102	-0,03
CRP/ASS	0,0253	0,007	3,877	0	0,013	0,038
RA_MBK	0,0191	0,009	2,089	0,037	0,001	0,037
ROA	0,0129	0,008	1,553	0,121	-0,003	0,029
ROE	-0,0031	0,004	-0,808	0,419	-0,011	0,004
CASH/ASS	0,0021	0,009	0,245	0,807	-0,015	0,019
SECURITY	-0,008	0,002	-4,214	0	-0,012	-0,004
LVL_NPL	0,0049	0,014	0,36	0,719	-0,022	0,031
PROV	0,0023	0,011	0,217	0,828	-0,018	0,023
INF	-1,1167	0,531	-2,101	0,036	-2,158	-0,075
MOEXIN	-0,0011	0	-2,481	0,013	-0,002	0
INX_ECONOMY	-0,0096	0,011	-0,836	0,403	-0,032	0,013
GDP_GROWTH	12,4652	14,062	0,886	0,375	-15,096	40,027
OIL	0,0099	0,017	0,6	0,548	-0,022	0,042
NET_EX	-0,026	0,048	-0,54	0,589	-0,121	0,069

Источники: расчеты авторов.

Примечание: полужирным шрифтом выделены переменные, характеризующиеся статистической значимостью на уровне 1, 5 и 10%.

ций. Их выполнение обеспечивает банкам возможность покрыть затраты, связанные с непредвиденными шоками, за счет собственных средств.

В то же время неожиданной является значимость отношения выданных межбанковских кредитов к чистым активам (IS_MBK). Такие кредиты, как правило, выдаются на очень короткий срок, в основном по ставке

overnight, т.е. на один день. Вероятно, способность кредитной организации выдать больший объем межбанковских кредитов (МБК) относительно активов трактуется рынком как признак устойчивости, который автоматически снижает предрасположенность такого банка к дефолту. При этом отношение объема полученных МБК к чистым активам (RA_MBK) также является значимой переменной: увели-

чение объема полученных МБК положительно влияет на вероятность дефолта.

Среди статистически значимых переменных присутствует отношение кредитного портфеля к чистым активам банка (CRP/ASS). Кредиты, выданные физическим и юридическим лицам, выступают главным источником дохода банка. Однако политика в отношении целевой аудитории заемщиков и допустимый уровень риска ссуд определяются каждой кредитной организацией самостоятельно. Поэтому, анализируя каждый конкретный банк, находящийся в неустойчивом финансовом положении, целесообразно внимательно изучить структуру кредитного портфеля, так как банкротство может быть обусловлено именно принятием избыточного кредитного риска в результате неверного определения целевой аудитории заемщиков.

В список значимых факторов-предикторов дефолта банков также попал показатель цены закрытия индекса Московской биржи (MOEXIN). Направление влияния на вероятность дефолтов банков – отрицательное, т.е. увеличение индекса ведет к снижению вероятности дефолтов, что, по-видимому, объясняется улучшением состояния торговых и инвестиционных банков в этот период.

Что касается макроэкономических переменных, то, за исключением темпов инфляции,

все они оказались незначимыми. При этом влияние данного показателя соответствует экономической интуиции: ускорение инфляции, как правило, ведет к удорожанию пассивов, выступая в то же время демпфером кредитного бремени заемщиков. Соответственно, формируются предпосылки сокращения процентного дохода банков и увеличения риска дефолта. Расчеты также не подтвердили значимость темпов роста ВВП, цен на нефть, а также динамики фондового индекса Московской Биржи. Возможно, ограниченная роль переменных, характеризующих состояние макроэкономической среды, связана с тем, что при построении моделей использовались их фактические значения, а не показатели волатильности, как было предложено в работе (Биджоян, Богданова, 2017).

Судя по показателю правдоподобия (LL ratio), обе оцененные модели значимы. Их оценки псевдо- R^2 весьма близки, равно как и знаки и величины коэффициентов при регрессорах. В случае обеих моделей ROC-AUC на тестовой выборке превысил 0,5 и составил 0,77 и 0,79 соответственно (рис. 1). Таким образом, пробит- и логит-модели могут в равной степени использоваться для дальнейшего анализа.

Следующим этапом будет расчет предельных эффектов. С их помощью можно не только установить, снижает или повышает

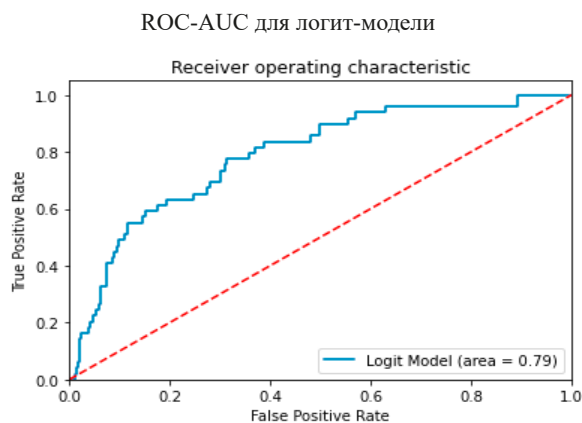
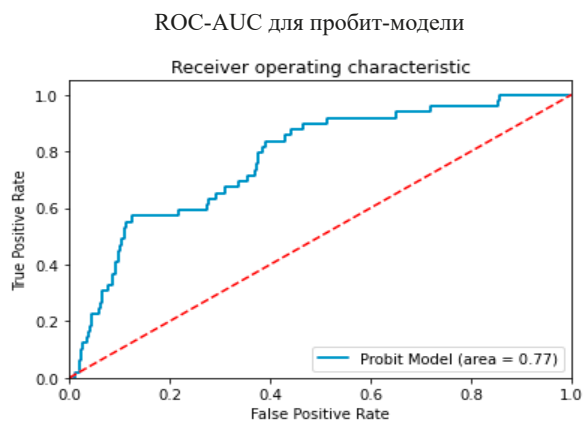


Рис. 1. Графики ROC-AUC для пробит- и логит-моделей

Примечание. По горизонтальной оси отмечена доля ложноположительных результатов, по вертикальной оси – доля истинно положительных результатов. В легенде указаны размеры метрики ROC-AUC (значение площади, ограниченной ROC-кривой).

вероятность дефолта та или иная переменная, но и определить масштаб изменения вероятности дефолта, если данная независимая переменная уменьшится или возрастет на единицу. Согласно пробит-регрессии⁴ наиболее существенно на росте вероятности дефолта сказывается показатель инфляции (INF). Оценка предельного эффекта данного индикатора составляет $-0,16$. Таким образом, если темп инфляции возрастал в России на 1 п.п., то вероятность дефолта банков в среднем снижается на $0,16$ ⁵. Согласно данным табл. 4,

⁴ Все предельные эффекты для логит-регрессии оказываются статистически незначимыми, поэтому соответствующая таблица для логит-регрессии в статье не приводится.

⁵ Справедливости ради стоит отметить, что в модель изначально включались недефлированные

среди статистически значимых регрессоров, наряду с инфляцией, определенное понижающее влияние на вероятность дефолта оказывали показатели H1, H3, логарифм чистых активов, отношение выданных МБК к активам, инфляция и цена закрытия индекса Московской Биржи, в то время как доля кредитного портфеля в чистых активах и отношение полученных МБК к активам положительно влияли на вероятность дефолта.

Теперь оценим регрессию Кокса с временными эффектами. Для этого необходимо осуществить небольшое преобразование дан-

показатели. Соответственно, значимость инфляции может быть следствием того, что этот показатель оттянул на себя значимость других недефлированных переменных, тем более учитывая, что получившееся направленное влияние не имеет интуитивного объяснения.

Таблица 4
Предельные эффекты в пробит-модели

Название переменной	Коэффициент	Стандартная ошибка	z	$P > z $	[0,025	0,975]
H1	-0,0053	0,002	-3,458	0,001	-0,008	-0,002
H3	-0,0004	0	-2,285	0,022	-0,001	0,000
NET_LOG_ASS	-0,0372	0,01	-3,831	0	-0,056	-0,018
DLF/ASS	0,0016	0,001	1,505	0,132	0	0,004
INV/ASS	-0,004	0,002	-2,063	0,039	-0,008	0
IS_MBK	-0,0078	0,003	-2,894	0,004	-0,013	-0,003
CRP/ASS	0,0035	0,001	3,198	0,001	0,001	0,006
RA_MBK	0,0035	0,001	2,383	0,017	0,001	0,006
ROA	0,0017	0,001	1,221	0,222	-0,001	0,004
ROE	-0,0003	0,001	-0,586	0,558	-0,001	0,001
CASH/ASS	0,000	0,001	0,052	0,959	-0,002	0,003
SECURITY	-0,0013	0	-3,703	0	-0,002	-0,001
LVL_NPL	0,0002	0,002	0,079	0,937	-0,004	0,004
PROV	0,0008	0,001	0,507	0,612	-0,002	0,004
INF	-0,1644	0,075	-2,185	0,029	-0,312	-0,017
MOEXIN	-0,0002	0,000	-2,57	0,01	0	0,000
INX_ECONOMY	-0,0017	0,001	-1,151	0,25	-0,005	0,001
GDP_GROWTH	1,5485	2,105	0,735	0,462	-2,578	5,675
OIL	0,0021	0,003	0,838	0,402	-0,003	0,007
NET_EX	-0,0039	0,007	-0,54	0,589	-0,018	0,01

Источники: расчеты авторов.

Примечание: полужирным шрифтом выделены переменные, характеризующиеся статистической значимостью на уровне 1, 5 и 10%.

ных, задав интервалы времени для каждого наблюдения. Данное преобразование выполняется следующим образом: интервал с февраля (начальная точка в выборке) до марта 2015 г. описывается диапазоном значений от 0 по 1, с марта до апреля 2015 г. – от 1 по 2 и т.д. Результаты приведены в табл. 5.

Хотя на этапе разведочного анализа данных VIF-множители не выявили наличие мультиколлинеарности в данных, регрессия Кокса была оценена только посредством регуляризации из-за неудовлетворительной обусловленности ковариационной матрицы.

Интерпретация коэффициентов регрессии Кокса также не является интуитивной. Если коэффициент при переменной положительный (иными словами, его экспонента превышает единицу), то это повышает риск

дефолта банка относительно его базового сценария. Если коэффициент меньше нуля, то увеличение соответствующей переменной снижает риск дефолта. Если же коэффициент при регрессоре значимо не отличается от нуля, то он не влияет на выживаемость банков.

Исходя из данных табл. 5, видно, что пул значимых переменных корреспондирует с результатами пробит- и логит-моделей. Риск дефолта банков снижают рост норматива достаточности капитала H1, логарифма чистых активов, отношение вложений в ценные бумаги к активам, а также обеспечение выданных кредитов залоговым имуществом и инфляция. Напротив, увеличение такого показателя, как отношение кредитного портфеля к величине чистых активов, ведет к повышению вероятности дефолта.

Таблица 5
Оценки регрессии Кокса с временными эффектами

Название переменной	Коэффициент	exp (коэффициент)	Стандартная ошибка (коэффициент)	<i>z</i>	<i>p</i>
H1	-0,06	0,94	0,01	-5,53	0,00
H3	0,00	1,00	0,00	-0,10	0,92
NET_LOG_ASS	-0,25	0,78	0,05	-4,77	0,00
DLF/ASS	0,00	1,00	0,01	0,86	0,39
INV/ASS	-0,03	0,97	0,01	-2,77	0,01
IS_MBK	-0,08	0,93	0,02	-5,00	0,00
CRP/ASS	0,03	1,03	0,01	5,02	0,00
RA/MBK	0,01	1,01	0,01	1,68	0,09
ROA	0,01	1,01	0,01	1,98	0,05
ROE	0,00	1,00	0,00	-0,88	0,38
CASH/ASS	0,00	1,00	0,01	0,39	0,69
SECURITY	-0,01	0,99	0,00	-4,68	0,00
LVL_NPL	0,00	1,00	0,01	0,29	0,77
PROV	0,00	1,00	0,01	0,39	0,69
INF	-0,89	0,41	0,41	-2,14	0,03
MOEXIN	0,00	1,00	0,00	-2,24	0,02
INX_ECONOMY	-0,02	0,98	0,01	-1,74	0,08
GDP_GROWTH	21,10	1,46E+09	11,75	1,80	0,07
OIL	0,00	1,00	0,01	0,13	0,89
NET_EX	-0,01	0,99	0,04	-0,36	0,72

Источники: расчеты авторов.

Примечание: полужирным шрифтом выделены переменные, характеризующиеся статистической значимостью на уровне 1, 5 и 10%.

Обобщение результатов моделирования позволяет сделать вывод об устойчивой значимости показателя норматива $H1$, логарифма чистых активов (NET_LOS_ASS), отношения кредитного портфеля к активам (CRP/ASS), обеспеченности кредитного портфеля имуществом ($SECURITY$), отношения объема выданных межбанковских кредитов к активам (IS_MBK), а также инфляция (INF) и цена закрытия индекса Московской Биржи ($MOEXIN$). Соответственно, именно на эти индикаторы следует обращать внимание в приоритетном порядке при анализе устойчивости отдельно взятого проблемного банка.

ЗАКЛЮЧЕНИЕ

В рамках исследования был предложен комплекс моделей (пробит-, логит-регрессии и регрессия Кокса), способных прогнозировать вероятность дефолта кредитных организаций. Были выявлены предикторы, наиболее тесно ассоциированные с утратой банком финансовой устойчивости. Сопоставление трех моделей оценки вероятности дефолта (логит-, пробит-регрессии и регрессии Кокса) показало, что наибольший вклад в прогнозирование неплатежеспособности банков вносят регрессоры, характеризующие различные аспекты функционирования банков в соответствии с системой показателей CAMELS. К ним относятся значение норматива достаточности капитала $H1$, логарифм чистых активов, отношение кредитного портфеля к чистым активам, а также коэффициент обеспеченности кредитного портфеля имуществом. В то же время роль макроэкономических индикаторов, за исключением темпов инфляции, оказалась незначительной. Помимо решения задачи отбора регрессоров, были оценены их предельные эффекты. Среди значимых показателей наибольшее влияние на изменение вероятности дефолта оказывает темп инфляции. Далее следуют логарифм чистых активов,

доля кредитного портфеля в чистых активах, а также доля выданных МБК.

При разбиении выборки на тренировочную и тестовую построенные логит- и пробит-модели продемонстрировали удовлетворительную прогнозную силу: величина площади под ROC-кривой оказалась равной 0,77 и 0,79 соответственно.

Разработанный модельный комплекс может представлять интерес для регулятора как с точки зрения текущего надзора, так и упреждения риска дефолта. Кроме того, он может быть полезен и самим кредитным организациям, прежде всего в части мониторинга финансового положения контрагентов. Полученные в исследовании результаты также могут быть использованы при размещении средств клиентами кредитных организаций – юридическими и физическими лицами – для отбора банков, наименее подверженных риску дефолта и отзыва лицензии по экономическим причинам. Такой анализ со стороны нефинансовых организаций и физических лиц способствовал бы укреплению рыночной дисциплины в российском банковском секторе.

Естественными направлениями развития проведенного нами исследования являются: 1) анализ периода «кризисных» наблюдений, т.е. рассмотрение периода пандемии и геополитической турбулентности и 2) применение альтернативных методов, прежде всего методов машинного обучения. Так, учитывая опыт международных исследований, можно в приоритетном порядке протестировать применение алгоритмов «случайного леса», бустинга и нейронных сетей.

Список литературы / References

- Андреасян Г. (2000). Дистанционный анализ финансово-экономического состояния российских банков: Эконометрический подход: дис. ... канд. экон. наук: 08.00.13 М.: ЦЭМИ РАН.

- 140 с. [Andreasjan G. (2000). *Remote Analysis of Financial and Economic Condition of Russian Banks: Econometric Approach*: dis. ... Cand. Sc. (Economics): 08.00.13 Moscow: CEMI RAS. 140 p. (in Russian).] URL: <https://rsl.ru>
- Биджоян Д., Богданова Т. (2017). Концепция моделирования и прогнозирования вероятности отзыва лицензий российских банков // *Экономическая наука современной России*. № 4 (79). С. 88–103. [Bidzhojan D., Bogdanova T. (2017). The Concept of Modeling and Forecasting the Probability of Revoking a License of Russian Banks. *Economics of Contemporary Russia*, no. 4, pp. 88–102 (in Russian).]
- Бывшев В., Прокопчина С., Мищенко С. (2021). Исследование дискриминационной способности финансовых коэффициентов ROA и ROE выявлять проблемные банки (российский опыт) // *Мягкие измерения и вычисления*. № 38 (1). С. 60–65. [Byvshev V., Prokopchina S., Mishhenko S. (2021). Study of the Discriminatory Ability of ROA and ROE Financial Ratios to Identify Problem Banks (Russian Experience). *Soft Measurements and Computing*, no. 38 (1), pp. 60–65 (in Russian).]
- Давыденко И., Козаченко Е. (2021). Возможности и границы использования модели бинарной логистической регрессии для оценки финансовой устойчивости и риска дефолта банка // *Экономика устойчивого развития*. № 1 (45). С. 141–145. [Davydenko I., Kozachenko E. (2021). Possibilities and Limits of Using the Binary Logistic Regression Model for Assessing Financial Stability and the Risk of Bank Default. *Economics of Sustainable Development*, no. 1 (45), pp. 141–145 (in Russian).]
- Зубарев А., Бекирова О. (2020). Анализ факторов банковских дефолтов 2013–2019 гг. // *Экономическая политика*. Т. 15. № 3. С. 106–133. [Zubarev A., Bekirova O. (2020). Analysis of Bank Default Factors in 2013–2019. *Economic Policy*, vol. 15, no. 3, pp. 106–133 (in Russian).]
- Зубарев А., Шилов К. (2022). Дифференциация факторов банковских дефолтов по причинам отзыва лицензий // *Экономический журнал ВШЭ*. № 26 (1). С. 69–103. [Zubarev A., Shilov K. (2022). Bank default's differentiation based on license withdrawal reasons. *HSE Economic Journal*, no. 26 (1), pp. 69–103 (in Russian).]
- Карминский А.М., Пересецкий А.А., Петров А.Е. (2005). Рейтинги в экономике: методология и практика. М: Финансы и статистика. 470 с. [Karminsky A.M., Peresetsky A.A., Petrov A.E. (2005). *Ratings in Economics: Methodology and Practice*. Moscow: Finance and Statistics. 470 p. (in Russian).]
- Карминский А.М., Костров А.В. (2013). Моделирование вероятности дефолта российских банков: расширенные возможности // *Журнал Новой экономической ассоциации*. № 1 (17). С. 64–70. [Karminsky A.M., Kostrov A.V. (2013). Modeling the Default Probabilities of Russian Banks: Extended Abilities. *The Journal of the New Economic Association*. No. 1(17), pp. 64–70 (in Russian).]
- Класс Я., Класс Т. (2018). Идентификация факторов риска банкротства кредитных организаций и их моделирование // *Финансы и кредит*. № 24(1). С. 19–32. [Klass Ja., Klass T. (2018). Identification of Risk Factors of Bankruptcy of Credit Institutions and Their Modelling. *Finance and Credit*, no. 24(1), pp. 19–32 (in Russian).]
- Пересецкий А.А. (2013). Модели причин отзыва лицензий российских банков. Влияние неучтенных факторов // *Прикладная эконометрика*. № 30 (2). С. 49–64. [Peresecky A.A. (2013). Modeling Reasons for Russian Bank License Withdrawal: Unaccounted Factors. *Applied Econometrics*, no. 30 (2), pp. 49–64 (in Russian).]
- Радионова М., Приступина Ю. (2017). Моделирование вероятности дефолта российских банков // *Финансовая аналитика: теория и практика*. № 10 (2). С. 226–240. [Radionova M., Pristupina Ju. (2017). Modeling the probability of default of Russian banks. *Financial Analytics: Science and Experience*, no. 10 (2), pp. 226–240 (in Russian).]
- Синельникова-Мурылева Е., Горшкова Т., Макеева Н. (2018). Прогнозирование дефолтов в российском банковском секторе // *Экономическая политика*. Т. 13. № 2. С. 8–27. [Sinelnikova-Muryljova E., Gorshkova T., Makeeva N. (2018). Default Forecasting in the Russian Banking Sector. *Economic Policy*, vol. 13, no. 2, pp. 8–27 (in Russian).]

- Тотьмянина К.М. (2011). Обзор моделей вероятности дефолта // Управление финансовыми рисками. № 1. С. 12–24. [Totmjanina K.M. (2011). Overview of models of default probability. *Financial Risk Management Journal*, no. 1, pp. 12–24 (in Russian).]
- Хасянова С., Цыганова В. (2018). Качество риск-менеджмента в банке: предпосылки возникновения финансовых проблем // Российский журнал менеджмента. № 16 (2). С. 187–204. Hasjanova S., Cyganova V. (2018). The Quality of Bank Risk Management: Triggers of Financial Problems. *Russian Management Journal*, no. 16 (2), pp. 187–204 (in Russian).]
- Широбокова М.А. (2018). Модель оценки риска дефолта на всем протяжении жизни кредита // Вестник Удмуртского университета. Серия «Экономика и право». № 28(2). С. 228–233. [Shirobokova M. (2018). Model of Evaluating the Default Credit Risk throughout the Whole Life of the Loan. *Bulletin of Udmurt University. Series "Economics and Law"*, no. 28(2), pp. 228–233 (in Russian).]
- Яшина Н., Макарова С., Макаров И. и др. (2017). Прогнозирование дефолта коммерческих банков на основе вероятностной модели // Экономический анализ: теория и практика. № 16 (12 (471)). С. 2376–2391. [Jashina N., Makarova S., Makarov I., et al. (2017). Forecasting the Commercial Bank Default Based on a Probabilistic Model. *Economic Analysis: Theory and Practice*, no. 16, vol. 12 (471), 2376–2391 (in Russian).]
- Albulescu C. (2022). Bank Financial Stability and International Oil Prices: Evidence from Listed Russian Public Banks. *Eastern European Economics*, vol. 60(3), pp. 217–246.
- Altman E.I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *Journal of Finance*, no. 23(4), pp. 589–609.
- Altman E.I., Marco G., Varetto F. (1994). Corporate distress diagnosis: comparisons using linear discriminant analysis and neural networks (the Italian experience). *Journal of Banking and Finance*, no. 18 (3), pp. 505–529.
- Avery R.B., Hanweck G.A. (1984). A dynamic analysis of bank failures. *Board of Governors of the Federal Reserve System*, no. 74.
- Barajas A., Krakovich V., Lopez-Iturriaga F. (2023). Survival of Russian Banks: How Efficient are the Control Measures? *European Journal of Management and Business Economics*, vol. 32, no. 3, pp. 320–341.
- Bigus J.P. (1996). *Data mining With Neural Networks: Solving Business Problems from Application Development to Decision Support*. Hightstown: McGraw-Hill, Inc.
- Bondarenko M., Semenova M. (2018). Do High Deposit Interest Rates Signal Bank Default? Evidence from the Russian Retail Deposit Market. National Research University "Higher School of Economics". *HSE Working Paper*, no. BRP 65/FE/2018.
- Bräuning M., Malikkidou D., Scalone S., et al. (2019). A New Approach to Early Warning Systems for Small European Banks. *ECB Working Paper*, no. 2348.
- Carree M. (2003). A Hazard Rate Analysis of Russian Commercial Banks in the Period 1994–1997. *Economic Systems*, no. 27(3), pp. 255–269.
- Chan-Lau J.A. (2006). Fundamentals-based estimation of default probabilities: a survey. *IMF Working Paper*, no. 149.
- Chernykh L., Kotomin V. (2022). Risk-based Deposit Insurance, Deposit Rates and Bank Failures: Evidence from Russia. *Journal of Banking and Finance*, vol. 138, article 106438.
- Chernykh L., Mityakov S. (2022). Behaviour of Corporate Depositors during a Bank Panic. *Management Science*, vol. 68 (12), pp. 9129–9159.
- Erdogan B. (2013). Prediction of Bankruptcy Using Support Vector Machines: An Application to Bank Bankruptcy. *Journal of Statistical Computation and Simulation*, vol. 83 (8), pp. 1543–1555.
- Fungáčová Z., Solanko L. (2009). Risk-Taking by Russian Banks: Do Location, Ownership and Size Matter? Bank of Finland. Institute for Economics in Transition. *BOFIT Discussion Papers* 21.
- Fungáčová Z., Turk R., Weill L. (2021). High Liquidity Creation and Bank Failures. *Journal of Financial Stability*, vol. 57, 100937.
- Fungáčová Z., Weill L. (2013). Does Competition Influence Bank Failures? Evidence from Russia. *Economics of Transition and Institutional Change*, vol. 21, no. 2, pp. 301–322.

- Jing Z., Fang Y. (2018). Predicting US Bank Failures: A Comparison of Logit and Data Mining Models. *Journal of Forecasting*, vol. 37 (2), pp. 235–256.
- Karminsky A., Kostrov A. (2016). The Back Side of Banking in Russia: Forecasting Bank Failures with Negative Capital. *International Journal of Computational Economics and Econometrics*, vol. 7, no. 1–2, pp. 170–209.
- Kočenda E., Iwasaki I. (2022). Bank Survival around the World: A Meta-analytic Review. *Journal of Economic Surveys*, vol. 36 (1), pp. 108–156.
- Lanine G., Vennet R. (2006). Failure Prediction in the Russian Bank Sector with Logit and Trait Recognition Models. *Expert Systems with Applications*, vol. 30 (3), pp. 463–478.
- Makinen, M., Solanko L. (2018). Determinants of Bank Closures: Do Levels or Changes of CAMEL Variables Matter? *Russian Journal of Money and Finance*, vol. 77(2), pp. 3–21.
- Martin D. (1977). Early Warning of Bank Failure: A Logit Regression Approach. *Journal of Banking & Finance*, vol. 1, pp. 249–276.
- Orbe J., Núñez-Antón V. (2011) Analysis of the Determinants of Survival for the Russian Commercial Banking Industry: A New Approach. *Applied Stochastic Models in Business and Industry*, vol. 27 (3), pp. 301–314.
- Peresetsky A.A., Karminsky A.M., Golovan S.V. (2011) Probability of Default Models of Russian Banks. *Economic Change and Restructuring*, vol. 44, no. 4.
- Philippon, T., Wang O. (2023). Let the Worst One Fail: A Credible Solution to the Too-Big-To-Fail Conundrum. *Quarterly Journal of Economics*, vol. 138 (2), pp. 1233–1271.
- Ploeg S. (2010). *Bank Default Prediction Models: A Comparison and an Application to Credit Rating Transitions*. Ernst & Young – Financial Services Risk Management. Rotterdam: Erasmus University.
- Shibitov D., Mamedli M. (2019). The Finer Points of Model Comparison in Machine Learning: Forecasting Based on Russian Banks' Data. *Bank of Russia Working Paper*, no. 43. August.
- Tamari M. (1966). Financial ratios as a means of forecasting bankruptcy. *Management International Review*, no. 4, pp.15–21.
- Tankoeva V., Bazzana F., Gabriele R. (2018). The Stability of the Financial System: An Analysis of Russian Bank Failures. In: *Research Handbook of Investing in the Triple Bottom Line: Finance, Society and Environment*. Ed. by S. Boubaker, D. Cumming, D.K. Nguyen. Cheltenham (UK), Northampton (USA): Edward Elgar.
- Wilson T. (1997). Portfolio Credit Risk: Part I. *Risk Magazine*, September.

ПРИЛОЖЕНИЕ

Таблица А1
Описательные статистики для тренировочной выборки

	Число наблюдений	Среднее	Стандартное отклонение	min	max
N1	24125	32,10	35,86	0,00	1703,62
N3	24125	25308,06	1576886,87	0,00	99999999,99
NET_LOG_ASS	24125	15,79	2,03	0,00	24,16
DLF/ASS	24125	30,17	23,47	0,00	88,17
INV/ASS	24125	10,46	14,72	0,00	178,97
IS_MBK	24125	18,25	21,17	0,00	778,20
CRP/ASS	24125	44,69	23,36	0,00	99,28
RA_MBK	24125	6,12	13,35	0,00	99,44
ROA	24125	3,63	9,13	0,00	645,56
ROE	24125	17,24	58,65	0,00	3701,67
CASH/ASS	24125	26,45	17,69	0,00	131,75

Окончание табл. А1

	Число наблюдений	Среднее	Стандартное отклонение	min	max
SECURITY	24125	111,67	96,16	0,00	5336,68
LVL_NPL	24125	8,65	14,63	0,00	100,00
PROV	24125	16,82	17,72	0,00	100,30
INF	24125	0,14	0,22	0,00	1,13
MOEXIN	24125	2125,24	375,89	1609,19	3076,65
INX_ECONONY	24125	100,99	9,22	70,90	115,50
GDP_GROWTH	24125	0,01	0,01	0,00	0,03
OIL	24125	56,30	11,58	22,62	80,71
NET_EX	24125	12,63	3,83	5,10	21,00
DEFAULT	24125	0,00	0,07	0,00	1,00

Источники: расчеты авторов по данным ресурса banki.ru.

Таблица А2

Описательные статистики для тестовой выборки

	Число наблюдений	Среднее	Стандартное отклонение	min	max
N1	10340	32,10412	34,7872	0	754,16
N3	10340	19659,55	1390700	0	1E+08
NET_LOG_ASS	10340	15,8086	2,01566	9,11	24,1
DLF/ASS	10340	30,17469	23,55479	0	87,5
INV/ASS	10340	10,57069	14,6381	0	87,78
IS_MBK	10340	18,42859	21,0871	0	447,33
CRP/ASS	10340	44,64986	23,43597	0	99,08
RA_MBK	10340	6,250249	13,82522	0	99,32
ROA	10340	3,661157	10,9996	0	763,14
ROE	10340	18,42094	128,9717	0	8875,98
CASH/ASS	10340	26,20543	17,69259	0	96,81
SECURITY	10340	112,8543	120,0351	0	5530,23
LVL_NPL	10340	9,265791	15,58528	0	100
PROV	10340	17,25716	18,13134	0	100
INF	10340	0,136845	0,218324	0	1,13
MOEXIN	10340	2132,409	378,8201	1609,19	3076,65
INX_ECONONY	10340	100,9933	9,30132	70,9	115,5
GDP_GROWTH	10340	0,014846	0,010523	0	0,03
OIL	10340	56,35306	11,54594	22,62	80,71
NET_EX	10340	12,66138	3,795691	5,1	21
DEFAULT	10340	0,004739	0,06868	0	1

Источники: расчеты авторов по данным ресурса banki.ru.

Таблица А3
Значения VIF-множителей для переменных

Константа	578,1
H1	1,4
H3	1,0
NET_LOG_ASS	1,6
DLF/ASS	2,1
INV/ASS	1,6
IS_MBK	1,8
CRP/ASS	2,0
RA_MBK	1,8
ROA	1,5
ROE	1,5
CASH/ASS	1,6
SECURITY	1,0
LVL_NPL	2,0
PROV	2,1
INF	1,5
MOEXIN	5,7
INX_ECONOMY	1,0
GDP_GROWTH	5,1
OIL	3,7
NET_EX	3,2

Расчеты авторов.

Рукопись поступила в редакцию 29.02.2024

MODELING THE RISK OF BANK DEFAULT

M.A. Shchepeleva, K. Tusipkaliev, M.I. Stolbov

DOI: 10.33293/1609-1442-2024-2(105)-101-124

EDN: CXQVQD

Marija A. Shchepeleva, National Research University “Higher School of Economics” (HSE University), Moscow, Russia; mshchepeleva@hse.ru; ORCID: 0000-0001-9107-3173; eLibrary SPIN: 6588-5218

Kajrat Tusipkaliev, National Research University “Higher School of Economics” (HSE University), Moscow, Russia; ktusipkaliev@edu.hse.ru

Mihail I. Stolbov, Moscow State Institute of International Relations, Moscow, Russia, stolbov.m@my.mgimo.ru; eLibrary SPIN: 7045-0570

Acknowledgment. The research was carried for grant from the Russian Scientific Foundation (project no. 23-18-00756).

Abstract. This paper is devoted to modeling the probability of default of Russian banks in 2015–2020. There are relatively few studies on defaults of Russian banks after 2015, and our work intends to partly fill this gap. The purpose of this research is to determine the main variables which significantly impact the risk of default of Russian banks. The work seeks to identify additional factors associated with an increased risk of bank defaults during a relatively stable period of development of the Russian economy (2015–2020) without external shocks, such as COVID-19 or international sanctions. We apply an integrated approach to modeling the risk of bank defaults. Empirical methodology is represented by logit and probit models, as well as Cox regression. The set of potential predictors for bank defaults include the variables, characterizing various aspects of credit institutions functioning (in accordance with the CAMELS system), as well as macroeconomic variables. The most significant predictors of default turn out to be the capital adequacy ratio N1, bank net assets, the ratio of total loans to assets and the size of secured loan portfolio. In general, the results we obtain are consistent with the CAMELS system of indicators assessing the sustainability of commercial banks, while the impact of macroeconomic indicators tends to be insignificant. The results of the study could be of interest to the regulator both for the purposes of ongoing monitoring of financial stability as well as for default risk prevention; to credit institutions which elaborate internal systems for monitoring their financial soundness; and to financial market participants to select the most stable companies in terms of investment and allocation of funds. Further directions of research are related to the inclusion of a crisis period into the analysis and comparing the set of significant predictors for bank defaults during a crisis and a stable period of economic development, as well as the use of alternative methods, in particular, machine learning algorithms.

Keywords: bank default, credit rating, camels, logistic regression, cox regression, machine learning methods.

Classification JEL: G17, G21, G33.

For reference: Shchepeleva M.A., Tusipkaliev K., Stolbov M.I. (2024). Modeling the risk of bank default. *Economics of Contemporary Russia*, no. 2 (105), pp. 101–124. DOI: 10.33293/1609-1442-2024-2(105)-101-124; EDN: CXQVQD

Manuscript received 29.02.2024