

Политика по урегулированию банковских кризисов и новая нестабильность

Александр Паталаха

E-mail: aleks.patalaha@yandex.ru

Национальный исследовательский университет

«Высшая школа экономики»

г. Москва, Российская Федерация

Мария Александровна Щепелева

E-mail: mshchepeleva@hse.ru, ORCID: 0000-0001-9107-3173

Национальный исследовательский университет

«Высшая школа экономики»

г. Москва, Российская Федерация

Аннотация

Исследование посвящено изучению факторов, значимых для прогнозирования банковских кризисов. Актуальность работы определяется тем, что, несмотря на все усилия по созданию систем опережающих индикаторов, кризисы в банковской сфере продолжают случаться, приводя к негативным последствиям не только в финансовом, но и в реальном секторе экономики. Цель исследования заключается в определении того, как характеристики прошлых банковских кризисов, в частности объем финансовой помощи со стороны государства для поддержки банковской системы, связаны с вероятностью последующих банковских кризисов. Для ответа на этот вопрос мы используем методологию классификационного дерева, которое строим для выборки из 56 стран за период с 2000 по 2021 г. Для прогнозирования банковских кризисов, помимо характеристик прошлых кризисных эпизодов, используются показатели, относящиеся к глубине, структуре, эффективности банковского сектора; институциональные и макроэкономические показатели; индекс макропруденциальной политики. Для проверки на устойчивость результатов произведен отбор предикторов банковских кризисов с помощью байесовского усреднения моделей. В результате анализа было выявлено, что высокой значимостью для прогнозирования банковских кризисов обладает объем государственной поддержки в период прошлого кризиса. Таким образом, наши результаты демонстрируют, что чрезмерный объем государственного вмешательства для стабилизации системы в период кризиса может негативно отразиться на будущей стабильности банковского сектора, главным образом из-за повышения уровня риска недобросовестного поведения.

Ключевые слова: классификационное дерево, банковский кризис, байесовское усреднение моделей, риск недобросовестного поведения

JEL: G01, G17, G28

Финансирование: исследование выполнено за счет гранта Российского научного фонда (проект № 23-18-00756).

Для цитирования: Паталаха А., Щепелева М. А. Политика по урегулированию банковских кризисов и новая нестабильность // Финансовый журнал. 2023. Т. 15. № 6. С. 43–60.
<https://doi.org/10.31107/2075-1990-2023-6-43-60>.

© Паталаха А., Щепелева М. А., 2023

<https://doi.org/10.31107/2075-1990-2023-6-43-60>

Bank Crisis Management Policies and the New Instability

Alexandr Patalaha¹, Maria A. Shchepeleva²

^{1,2} HSE University, Moscow, Russian Federation

¹ aleks.patalaha@yandex.ru

² mshchepeleva@hse.ru, <https://orcid.org/0000-0001-9107-3173>

Abstract

This research focuses on the determinants of banking crises. Despite all efforts to create systems of leading indicators, banking crises still occur, leading to negative consequences not only in the financial but also in the real sector of the economy. Our objective is to figure out how the characteristics of past banking crises, in particular the amount of liquidity support provided by the government, are related to the probability of subsequent banking crises. To accomplish this task, we use a classification tree methodology which we apply to a sample of 56 countries over the period 2000–2021. In addition to the characteristics of past crisis episodes, we add to the list of potential predictors of banking crises indicators related to the depth, structure and efficiency of the banking sector; institutional and macroeconomic indicators; and the index of macroprudential policy. To test the robustness of our results, we perform variable selection through Bayesian model averaging. Our results suggest that liquidity support during the past banking crisis is important for future crises. We demonstrate that excessive government support aimed at stabilizing the system during a crisis may affect future banking sector stability mainly by increasing the level of moral hazard in the financial system.

Keywords: *classification tree, banking crisis, Bayesian model averaging, moral hazard*

JEL: G01, G17, G28

Funding: *The research was funded by the Russian Science Foundation (project No. 23-18-00756).*

For citation: Patalaha A., Shchepeleva M.A. (2023). *Bank Crisis Management Policies and the New Instability. Financial Journal*, 15 (6), 43–60 (In Russ.).
<https://doi.org/10.31107/2075-1990-2023-6-43-60>.

© Patalaha A., Shchepeleva M.A., 2023

ВВЕДЕНИЕ

Экономический рост тесно связан с эффективным функционированием банковского сектора. Несмотря на большое количество исследований, посвященных поиску причин банковских кризисов и разработке различных методов их прогнозирования, кризисы продолжают случаться как в развитых, так и в развивающихся странах. Глобальный финансово-экономический кризис 2007–2009 г. заставил пересмотреть существующие подходы к прогнозированию кризисов вместе со всей архитектурой финансового регулирования. Стали активно разрабатываться меры макропруденциальной политики, были предприняты особые ограничения в отношении так называемых «слишком больших, чтобы рухнуть» финансовых институтов. Несмотря на все предпринятые усилия, в 2022 г. произошел крах банка Silicon Valley, который вновь поставил под угрозу стабильность банковского сектора США. Таким образом, вопросы о механизмах развития банковских кризисов, о том, какие факторы помогли бы регуляторным властям превентивно узнать о надвигающемся кризисе, до сих пор остаются открытыми.

Объектом исследования в данной работе являются банковские кризисы. Факторы, которые могут быть использованы для прогнозирования вероятности банковских кризисов, составляют предмет исследования.

Цель работы заключается в определении того, как характеристики прошлых банковских кризисов влияют на вероятность возникновения нового кризиса в банковской системе.

Работа структурирована следующим образом. В первой части рассматриваются основные характеристики банковских кризисов, их причины и последствия. Также в данном разделе представлен обзор эмпирических исследований, посвященных различным методам прогнозирования банковских кризисов. Во второй части представлены данные и методология эмпирического исследования. Третий раздел содержит результаты, их обсуждение и выводы для политики по поддержанию финансовой стабильности.

ОПРЕДЕЛЕНИЕ И ПРИЧИНЫ БАНКОВСКИХ КРИЗИСОВ

Существует большое количество определений банковских кризисов. Так, в работах [Caprio, Klingebiel, 1996; Laeven, Valencia, 2008], а также [Reinhart, Rogoff, 2009] банковские кризисы определяются как ситуации, в которых происходит «существенное истощение капитала банков». В работе [Calomiris, 2012] такие кризисы рассматриваются как «паника или череда банкротств банков». Более широкое определение предполагает ситуацию, в которой «набеги на банки» (*bank run*) или банкротства отдельных банковских институтов ведут к тому, что банки приостанавливают внутреннюю конвертацию обязательств или государство осуществляет крупномасштабное вмешательство для восстановления нормального функционирования банковского сектора [IMF, 1998]. В исследовании [Laeven, Valencia, 2010] банковский кризис описывается как ситуация, характеризующаяся многочисленными признаками финансового дистресса, в частности банковской паникой, финансовыми потерями банков, случаями ликвидации банковских институтов или существенным государственным вмешательством. Авторы определяют порог для такого государственного вмешательства. Если вливания ликвидности его превышают, то случай классифицируется как банковский кризис.

Среди российских исследователей также нет единого мнения по поводу понятия «банковский кризис». Есть работы, в которых банковский кризис рассматривается как стремительное и масштабное ухудшение качества банковских активов под влиянием неблагоприятных факторов макроэкономического, институционального, регуляторного характера. Согласно другой точке зрения, банковский кризис представляет собой денежно-кредитный кризис, то есть кризис, выражающийся в нарушении сбалансированности денежно-кредитной системы. Это характеризуется сокращением коммерческого и банковского кредита, массовыми изъятиями вкладов и крахами банков, погоней за наличными деньгами и золотом, падением курсов акций и облигаций, резким повышением нормы процента [Ларина, 2017].

В целях нашего исследования для выявления факторов, влияющих на вероятность банковских кризисов, применяется классификация [Laeven, Valencia, 2010], используемая в большинстве эмпирических исследований. Датировка кризисов также осуществлялась на основе работы [Laeven, Valencia, 2010].

В зависимости от масштаба банковские кризисы делятся на локальные — это кризис отдельного некрупного банка; региональные — это кризис банков в рамках одного региона; системные, которые затрагивают деятельность банков в масштабах всей страны или большинства ее регионов; международные (глобальные), охватывающие банковские системы нескольких государств [Ларина, 2017].

В течение долгого времени существенные усилия исследователей были направлены на создание адекватной хронологии кризисных явлений [Bordo et al., 2001; Reinhart, Rogoff, 2009; Laeven, Valencia, 2020]. Первоначально для создания подобной базы данных использовались качественные суждения относительно определенных экономических событий [Kindleberger, 1978; Wicker, 2000]. В последние годы для классификации события

как «банковский кризис» ученые используют оцифрованные коллекции периодических изданий прошлых лет [Frydman, Xu, 2023].

Хронология финансовых кризисов является важным моментом для анализа кризисных событий, но очевидно, что одной этой информации недостаточно. Решение о том, классифицировать ли данное событие как кризисное, зависит от критериев, применяемых к каждому временному ряду. Эти критерии включают свидетельства крупномасштабных банкротств банков, системные банкротства банков, банковские паники. Основные базы данных чаще всего согласованы в определении крупных кризисов, как, например, банковский кризис в США в 1931 г., но иногда расходятся в отношении менее масштабных происшествий. Такие разногласия могут отразиться на выводах эмпирических исследований, которые используют подобные хронологии. Более того, большая часть исследований ретроспективны, что способно привести к «ошибке выжившего»¹, заключающейся в том, что выводы исследователи делают только в отношении самых крупных разрушительных событий, игнорируя незначительную степень нестабильности [Romer, Romer, 2019].

«Ошибка выжившего» проявляется тем сильнее, чем раньше правительство вмешивается в функционирование финансового сектора для смягчения последствий кризиса. Подобные вмешательства скрывают понимание истинных причин, которые привели к кризису, а также потенциальных последствий.

Банковские кризисы представляют собой многофакторные явления, вызванные как внутренними, так и внешними причинами. Чаще всего внутренние проблемы накапливаются в банковской системе в течение определенного времени, а внешние неблагоприятные факторы становятся триггером, запускающим череду негативных событий. К внутренним факторам относят в первую очередь циклические колебания в объемах кредитных ресурсов и цен на активы, а к внешним — нестабильную макроэкономическую ситуацию, провалы рынка, пробелы в регулировании, которые могут вести к регуляторному арбитражу и разрастанию теневого банковского сектора, некорректное вмешательство государства в рыночные процессы на финансовом рынке.

Последствия банковских кризисов негативно отражаются как на финансовом, так и на реальном секторе экономики, на социальной и политической жизни страны, на качестве функционирования институтов. Реальные эффекты банковских кризисов связаны главным образом с уменьшением предоставляемых производственному сектору кредитных ресурсов, что может вести к снижению темпов экономического роста. Финансовый сектор сталкивается со снижением доверия населения к его способности эффективно выполнять свои функции. Также часто отмечается падение рентабельности коммерческих банков и повышение кредитного риска. Социальные последствия банковских кризисов включают возможный рост безработицы, увеличение социального неравенства [Shchepeleva et al., 2022], политические — рост нестабильности, оппозиционных настроений среди различных слоев населения и даже увеличение активности террористических группировок [Gries, Meierrieks, 2013], ослабление демократических институтов и ухудшение ситуации в области защиты прав человека [Gutmann et al., 2017]. С другой стороны, кризисы несут в себе некоторые позитивные элементы, в частности, согласно [Andersson, 2016] в результате крупных банковских кризисов чаще всего происходит укрепление рыночных отношений между экономическими агентами, а также улучшается подотчетность (*accountability*) политических институтов.

¹ «Ошибка выжившего» — когнитивное искажение, когда по одной группе наблюдений («выжившие») информации много, а по другой группе («погибшие») — почти нет. В результате при формулировании выводов учитывается только часть информации. В нашем случае для определения факторов, которые влияют на финансовую стабильность, ученые руководствуются информацией только о наиболее разрушительных и крупномасштабных кризисах, игнорируя локальные эпизоды финансовой нестабильности.

ОБЗОР ЭМПИРИЧЕСКИХ ИССЛЕДОВАНИЙ

Системы раннего предупреждения (*early warning systems, EWS*) о банковских кризисах начали разрабатываться в 1990-х гг. Это были модели, которые относились к так называемому первому поколению систем раннего оповещения. В тот период для прогнозирования различных видов финансовых кризисов использовались преимущественно модели дискретного выбора, в частности логит- и пробит-регрессии. После глобального финансово-экономического кризиса 2007–2009 гг. активнее стали использоваться методы машинного обучения.

В данном обзоре сделан акцент на работах, относящихся ко второму поколению моделей раннего предупреждения. В рассматриваемых работах обычно активно используются деревья решений (здесь и далее термины «дерево решений», «классификационное дерево», CART используются как синонимы), композиции деревьев (случайный лес), и реже — байесовские методы, а также методы, пригодные для работы с разреженными данными, например LASSO-регрессии.

Одной из первых работ, в которой использовалось дерево решений, было исследование [Duttagupta, Cashin, 2011]. Авторы рассматривали эпизоды банковских кризисов в 50 развитых экономиках и странах с переходной экономикой. Классификационное дерево позволяет идентифицировать условия, при которых вероятность банковского кризиса повышается. Согласно выводам этой работы, наиболее значимыми предикторами банковских кризисов являются высокая инфляция, низкая прибыльность банковского сектора, высокая степень долларизации банковских депозитов вкупе с номинальным обесценением валютного курса и низкой ликвидностью банковского сектора. В работах [Frankel, Wei, 2004], а также [Kaminsky, 2006] деревья решений использовались для задачи регрессии, то есть зависимая переменная — количество кризисов — рассматривалась не как дискретная, а как непрерывная величина.

Более совершенным методом для прогнозирования кризисов является случайный лес, который представляет собой набор классификационных или регрессионных деревьев. Главный недостаток решающего дерева заключается в высокой склонности к переобучению, то есть дерево сильно «подгоняется» под обучающую выборку, но на других данных его прогнозы могут быть неудачными. Для случайного леса вероятность «подгонки» под обучающую выборку невелика, так как алгоритм строит много некоррелированных между собой деревьев и использует каждый раз разные переменные-предикторы. Точность прогнозов, получаемых при применении случайного леса, выше, чем при построении отдельного дерева.

Так, основываясь на методе случайного леса, [Tanaka et al., 2016] показывают, что банковская финансовая отчетность может использоваться как предиктор кризиса. В работе [Joy et al., 2017] определяются ключевые предикторы для разных типов финансовых кризисов как в краткосрочном, так и в долгосрочном периоде путем комбинации CART и метода случайного леса.

Исследователи [Manasse et al., 2016], а также [Gabriele, 2019] применяют алгоритм под названием CRAGGING. Идея заключается в том, чтобы сгенерировать многочисленные искусственные наборы из общей массы данных, использовать их для оценки большого количества моделей и генерации прогнозов, которые впоследствии усредняются. Для получения интерпретируемой модели авторы используют предсказанные вероятности кризисов в качестве эндогенных переменных и строят модель, которая объясняет эти вероятности. Другими словами, на втором шаге авторы заменяют бинарные значения кризисов (1/0) на полученные прогнозы вероятностей этих кризисов. Используя такой же метод, [Manasse et al., 2016] фокусируются на прогнозировании кризисов в странах с развивающимися рынками. Набор потенциальных предикторов очень обширен и включает 540 различных переменных. Авторы приходят к выводу, что существует две опасные зоны для

функционирования банковского сектора. Первая — высокие процентные ставки в условиях кредитного бума и оттока капитала; вторая — инвестиционный бум, финансируемый за счет роста банковских открытых позиций в иностранной валюте. Используя тот же метод, [Gabriele, 2019] сосредотачивает свое внимание на развитых странах ЕС. Автор заключает, что высокие значения кредитных агрегатов и недооценка рыночных рисков являются наиболее значимыми переменными с точки зрения прогнозирования банковских кризисов.

В своем исследовании [Tölö et al., 2018] представили агрегированную таблицу, какие индикаторы включаются в системы раннего предупреждения банковских кризисов согласно различным эмпирическим исследованиям. Из таблицы следует, что наиболее устойчивыми предикторами банковских кризисов, которые фигурируют в большинстве работ, являются объем кредитных ресурсов, предоставляемый частному сектору, и показатель «совокупный кредит к ВВП». Цены на недвижимость, цены на акции и кредитные спреды также отмечаются как значимые предикторы. В то же время макроэкономические индикаторы, за исключением темпа роста ВВП, оказываются значимы лишь в половине из рассматриваемых авторами работ и никогда не являются наиболее важными прогностическими.

В последнее время появилось большое количество исследований, которые сравнивают эффективность прогнозирования различных видов кризисов с помощью традиционной логит-модели и различных методов машинного обучения. В большинстве из них утверждается, что методы машинного обучения превосходят логит-регрессии. [Manasse et al., 2003; Joy et al., 2017; Alessi, Detken, 2018] доказывают этот факт для классификационных деревьев и случайного леса; [Savona, Vezzoli, 2015] — для CRAGGING, [Bluwstein et al., 2020; Ward, 2017] — для BAGGING, случайного леса и сетевых методов, [Ristolainen, 2018] — для искусственной нейронной сети, [Casabianca et al., 2019] — для адаптивного бустинга (AdaBoost)². В работе [Holopainen, Sarlin, 2017] проводится сравнение эффективности 12 методов, относящихся как к традиционным статистическим методам, так и к машинному обучению, включая LASSO, классификационное дерево, случайный лес. Авторы показывают, что классификационные деревья по степени эффективности находятся в середине рейтинга после байесовских методов и LASSO, в то же время опережая традиционную логистическую регрессию.

В противовес этим исследованиям [Beutel et al., 2019] не находят преимуществ у классификационных деревьев, случайных лесов, метода *k*-ближайших соседей (*k*-nearest neighbours, KNN), метода опорных векторов (*Support Vector Machines*, SVM) или нейронных сетей по сравнению с обычными логит-моделями. Авторы утверждают, что модели машинного обучения нуждаются в значительном усовершенствовании и на данном этапе их существенного превосходства, даже при прогнозировании вне выборки, не обнаруживается.

Что касается байесовских методов и моделей для работы с разреженными данными, они используются для прогнозирования финансовых кризисов или оценки финансовой нестабильности гораздо реже.

В исследовании [Eidenberger et al., 2014] конструируется система раннего предупреждения для Австрии, где в качестве зависимой переменной выступает национальный индекс финансового стресса. Авторы применяют байесовское усреднение моделей для выявления релевантных предикторов этого индекса из набора в 30 переменных.

Для оценки последствий кризиса субстандартного ипотечного кредитования в США [Tsay, Ando, 2012], а также [Guidolin et al., 2019] используют байесовскую модель.

² Один из алгоритмов бустинга (наряду с XGBoost, LightGBM, CatBoost). Бустинг представляет собой процедуру последовательного построения композиции алгоритмов машинного обучения, когда каждый следующий алгоритм должен компенсировать недостатки предыдущего.

В первой упомянутой работе используется байесовская панельная регрессия для определения последствий кризиса в отношении американского фондового рынка, в то время как во второй для изучения процессов заражения между различными классами активов на американском финансовом рынке строятся байесовские векторные авторегрессии с изменяющимися во времени коэффициентами.

[Lang et al., 2018] впервые применили логистическую регрессию LASSO для прогнозирования финансовых кризисов. Авторы детально рассматривают все этапы моделирования и обсуждают, с какими проблемами сталкивались более ранние исследования. Затем [Lang et al., 2018] предлагают собственную методологию для построения системы опережающих индикаторов на основе логит-LASSO. Модель тестируется на микроданных для европейских банков. Авторы демонстрируют, что модель позволяет заблаговременно выявить проблемы у отдельных системно значимых банков, а также отследить эволюцию риска на агрегированном уровне.

В статье [Alessi, Savona, 2021] регрессия LASSO была применена для прогнозирования кризисов суверенного долга. В частности, авторы предпринимали попытку с помощью этого метода отобрать макроэкономические индикаторы, релевантные для объяснения динамики цен на CDS.

ПРЕДВАРИТЕЛЬНЫЙ АНАЛИЗ ДАННЫХ

Для моделирования вероятности банковских кризисов в нашем исследовании в список потенциальных предикторов были включены следующие переменные (табл. 1).

Таблица 1

Список переменных

Переменная	Описание	Источник
Показатели прошлых банковских кризисов		
LIQ_SUPP	Объем финансовой помощи банковскому сектору*, % от совокупного объема активов банков	[Leaven, Valencia, 2020]
Peak_NPL	Максимальное значение доли просроченных долгов*, % от совокупного объема выданных кредитов	
PUB_DEBT	Размер государственного долга*, % от ВВП	
Характеристики банковской системы		
DEP_ASSET	Банковские активы к ВВП	GFDD, World Bank
DOM_CRED	Объем банковских кредитов, предоставленных частному сектору / ВВП, %	
CONCENTR	Доля активов трех крупнейших банков в активах всей банковской системы, %	
COST_TO_INCOMERATIO	Операционные расходы как процент от операционной прибыли, %	
FOR_BANKS	Доля активов иностранных банков в активах национальной банковской системы, %	
GOV_BANKS	Доля активов государственных банков в активах национальной банковской системы, %	
INSURE	Максимальная сумма, покрываемая государственной программой страхования вкладов, к ВВП, %	[Anginer et al., 2014]
Индекс макропруденциальной политики		
IMAPP	Индекс макропруденциальной политики, ед.	[Alam et al., 2017]
Макроэкономические показатели		
GDPGR	ВВП на душу населения в долл. США (2010), % год к году	GFDD, World Bank

* В период последнего произошедшего в определенной стране банковского кризиса.
Источник: сформировано авторами на основе работы [Shchepeleva et al., 2022].

Мы собрали панель данных годовой частоты для 56 стран за период с 2000 по 2021 г. Количество стран и временные рамки обусловлены доступностью информации по всем переменным, участвующим в анализе. Описательные статистики представлены в Приложении 1.

Как было уже отмечено выше, банковские кризисы тесно связаны с предшествующими им кредитными бумагами, отслеживать которые можно по динамике такого показателя, как «кредитный разрыв»³. Судя по эмпирическим исследованиям, этот индикатор действительно обладает существенной прогностической силой [Drehman, Juselius, 2014; Geršl, Jašová, 2018; Tööl et al., 2018]. Мы не включили эту переменную в список потенциальных предикторов, так как данные по этому показателю доступны по ограниченному набору стран.

Для проверки нашей основной гипотезы о влиянии характеристик прошлых банковских кризисов на вероятность последующих кризисов мы включили такие переменные, как объем финансовой помощи банковскому сектору, максимальное значение доли просроченных кредитов, а также увеличение государственного долга в период последнего произошедшего в данной стране кризиса⁴.

Дополнительно в наш пул предикторов были включены показатели «глубины» национального банковского сектора (показатели «банковские активы к ВВП», «объем банковских кредитов, предоставленных частному сектору к ВВП»), структуры (уровень концентрации банковского сектора, доля иностранных банков, доля государственных банков в общих активах банковской системы), эффективности (операционные расходы как процент от операционной прибыли). Также мы добавили такой институциональный показатель, как максимальная сумма, покрываемая государственной программой страхования вкладов. В исследовании [Anginer et al., 2014] утверждается, что банковские кризисы чаще всего происходят в условиях неблагоприятной макроэкономической среды, в частности при низких темпах роста ВВП и высокой инфляции, а также при наличии предусмотренного национальным законодательством страхования депозитов. Система страхования депозитов оказывает двойственный эффект на вероятность возникновения кризисов: с одной стороны, она помогает снизить вероятность «самосбывающейся» банковской паники, но, с другой стороны, повышает риск недобросовестного поведения в банковском секторе, снижает рыночную дисциплину.

Помимо этого, в список потенциальных предикторов мы внесли индекс макропруденциальной политики, так как в недавних исследованиях было показано, что корректное применение инструментов макропруденциальной политики снижает вероятность банковских кризисов [Nakatani, 2020; Belkhir et al., 2022].

Из макроэкономических показателей мы оставили лишь темп прироста ВВП. В [Tööl et al., 2018] показано, что макроэкономические показатели в целом никогда не являются первостепенно значимыми для прогнозирования банковских кризисов. Лишь темп прироста ВВП в некоторых работах определяется как релевантный фактор, который может быть связан с повышенной вероятностью банковских кризисов.

Для избежания проблем с эндогенностью независимые переменные были взяты с лагом 1⁵.

Зависимая переменная имеет бинарный вид:

$$BANK_CRISIS_{it} = \begin{cases} 1, & \text{если в год } t \text{ в стране } i \text{ был банковский кризис} \\ 0, & \text{иначе} \end{cases}$$

³ Соотношение между текущими значениями объемов кредитования к ВВП и долгосрочным трендом этого показателя. Рассчитывается для определения фазы кредитного цикла.

⁴ В большинстве стран, входящих в выборку, последний произошедший кризис датируется 2008 г. Соответственно, для таких стран показатели LIQ_SUP, PEAK_NPL и PUB_DEBT берутся за 2008 г. Есть страны, в которых последний кризис произошел в 2014 г., тогда показатели берутся за 2014 г.

⁵ Рассматривались также 2-й и 3-й лаги переменных, но наилучшие метрики качества были у модели с переменными, имеющими лаг 1.

Как и в большинстве задач такого рода, в данных присутствует выраженный дисбаланс классов: всего мы имеем 1176 наблюдений, из которых только 2% приходится на кризисные эпизоды⁶.

ДЕРЕВО РЕШЕНИЙ ДЛЯ ПРОГНОЗИРОВАНИЯ БАНКОВСКИХ КРИЗИСОВ

Деревья решений, как следует из обзора литературы, стали активно использоваться в рамках второго поколения систем опережающих индикаторов банковских кризисов. Примеры эмпирических исследований, использующих этот метод, включают [Dutttagupta, Cashin, 2011; Diaz-Martinez et al., 2011; Manasse et al., 2013].

Отличие дерева решений от традиционно используемой в эконометрике логит-регрессии заключается в том, что это непараметрический метод, то есть для его применения не требуется предположение о характере распределения переменных. Логит-регрессии показывают хорошие результаты для данных, где преобладают линейные взаимосвязи. Однако если переменные связаны между собой нелинейно (что может быть применимо и к наборам данных для прогнозирования финансовых кризисов), то лучшие результаты демонстрируют непараметрические методы.

В нашем исследовании дерево решений было построено с помощью метода CART. Алгоритм работает следующим образом: во-первых, он определяет из всего пула данных переменную, которая наилучшим образом позволяет разделить наблюдения по целевой переменной на две относительно чистые группы — 0 (отсутствие кризиса) или 1 (кризис). Эта переменная находится в самом верхнем листе дерева, в так называемом родительском узле. После того как все данные были разделены на две группы (или два «дочерних» листа), на следующем шаге алгоритм берет каждую из групп отдельно и продолжает делить пополам до тех пор, пока не добьется «максимальной чистоты» в каждом из оставшихся листов.

Ограничения использования деревьев решений связаны со следующими фактами:

— нестабильность структуры дерева. Первая переменная, которая отбирается алгоритмом для родительского узла, имеет непропорционально большой эффект на последующий отбор предикторов, так как именно эта переменная определяет группы, над которыми проводятся все последующие разбиения. В результате, если небольшие изменения в наборе данных приводят к отбору другой переменной для родительского узла, все последующие деревья могут существенно отличаться от первоначального варианта;

— высокая вероятность переобучения;

— CART не является методом для определения причинно-следственных связей;

— в основе CART не лежит вероятностная модель. Таким образом, мы не можем получить вероятность или доверительный интервал, ассоциированный с полученным прогнозом [Yohannes, Hoddinott, 1999]. Также нет возможности получить маргинальные эффекты, как в традиционных эконометрических моделях.

Несмотря на все эти факторы, деревья решений часто используют при прогнозировании финансовых кризисов из-за возможности не только отобрать наиболее значимые предикторы для целевой переменной, но и получить информацию по их пороговым значениям. Также к их преимуществам относят:

а) возможность учитывать нелинейные взаимосвязи между переменными;

б) выбросы, пропущенные значения, мультиколлинеарность, гетероскедастичность в данных не оказывают существенного влияния на результаты классификации;

в) дерево решений является эффективным методом при работе с большими наборами данных [Yohannes, Hoddinott, 1999].

⁶ Проблема дисбаланса классов учитывалась нами при построении дерева решений с использованием разных техник: дублирование примеров миноритарного класса (*oversampling*), сокращение числа примеров мажоритарного класса (*undersampling*), алгоритм SMOTE, фиксация определенного гиперпараметра при построении дерева.

Для подбора параметров дерева в нашем случае использовался алгоритм случайного поиска (*Random Search*). Итоговый список наилучших параметров представлен в табл. 2.

Таблица 2

Список наилучших гиперпараметров, используемых для CART

Гиперпараметр	Оптимальное значение
min_samples_split	274
min_samples_leaf	4
max_features	sqrt
max_depth	5
criterion	entropy
class_weight	balanced

Источник: расчеты авторов.

Примечание

Мы используем стандартную реализацию алгоритма дерева решений в python из библиотеки *scikit-learn*, где: *min_samples_split* – минимальное число объектов, необходимое для того, чтобы узел дерева мог расщепиться. *min_samples_leaf* – минимальное число объектов в листьях.

max_features определяет максимальное число признаков, используемых для разделения, от совокупного числа рассматриваемых предикторов.

max_depth определяет максимальную глубину дерева. Дерево большой глубины может собрать больше информации из данных и сгенерировать наиболее точный прогноз, однако в этом случае выше вероятность переобучения. *criterion* – критерий информативности (*impurity criterion*), который оценивает качество разбиения. Чем меньше разнородность объектов в группе, тем меньше значение этого критерия. Выбор осуществляется между «критерием Джини» и «энтропийным» критерием.

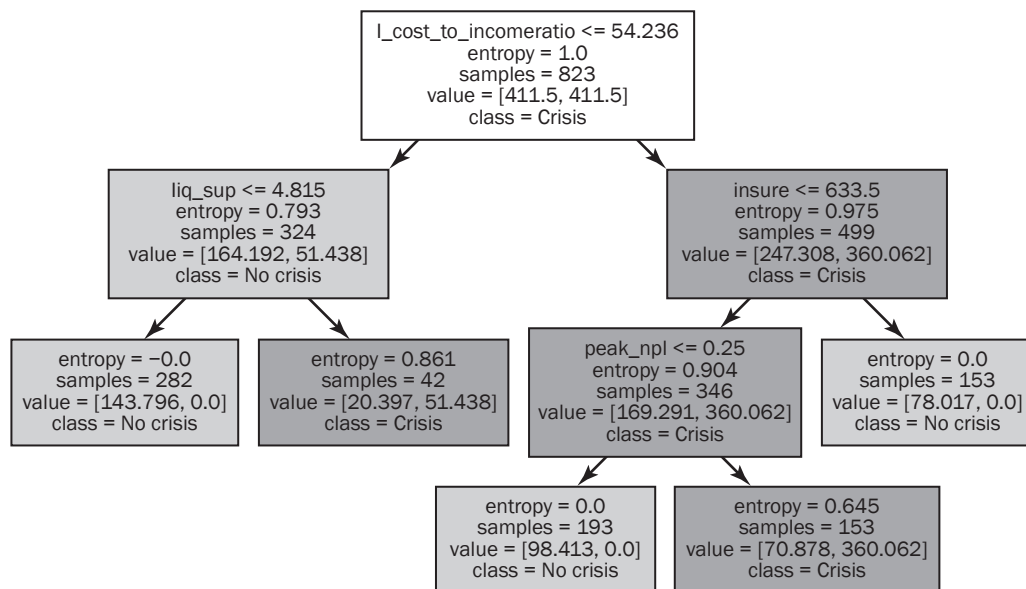
Для *class_weight* мы фиксируем значение *balanced*, что позволяет определять весовые коэффициенты классов для расчета показателя качества разбиения. Именно дерево с фиксацией этого гиперпараметра дает наилучшие характеристики на тестовой выборке. Другие методы работы с дисбалансом классов приводят к тому, что деревья теряют в точности прогнозов.

РЕЗУЛЬТАТЫ

Полученное нами дерево для прогнозирования банковских кризисов выглядит следующим образом:

Рисунок 1

Классификационное дерево для банковских кризисов



Источник: расчеты авторов.

В каждом из узлов представлена следующая информация: сначала идет название переменной и ее пороговое значение, что позволяет алгоритму осуществлять разбиение наблюдений на две группы. Далее идет значение показателя энтропии. Так как энтропия показывает степень хаоса в пуле наблюдений, то разделение считается «хорошим», если для каждой образованной группы показатель энтропии снижается. Затем следует показатель числа объектов, оказавшихся в той или иной группе (*values*). Учитывая то, что мы использовали гиперпараметр `class_weight = balanced`, который присваивает каждому из классов определенные веса, мы получаем не целое число наблюдений, отнесенное к той или иной группе, а дробное «взвешенное» количество наблюдений. Наконец, последняя строка показывает прогноз для данной группы стран — относятся они к группе, где выше вероятность кризиса, или к группе со стабильным развитием экономики.

Модель имеет следующие метрики качества прогноза на тренировочных и тестовых данных:

Таблица 3


Метрики качества на тестовых данных

Метрики качества	Значения для дерева решений с наилучшими гиперпараметрами
Accuracy	0,76
ROC_AUC	0,8
Precision	0,07
Recall	0,86
f1	0,13
Logloss	0,49

Источник: расчеты авторов.

Рисунок 2

ROC-кривая для дерева решений с наилучшими гиперпараметрами на тестовых данных



Источник: расчеты авторов.

Мы ориентируемся в первую очередь на показатель ROC-AUC, который достаточно высок для модели на тестовых данных. Это значит, что в целом построенная нами модель умеет неплохо разделять наблюдения на классы.

«Родительский» узел включает в себя переменную `COST_TO_INCOME_RATIO`. Пороговое значение для этой переменной устанавливается на уровне 54,2. Это значит, что если мы возьмем случайное наблюдение из нашего набора данных и соответствующее

ему отношение операционных расходов к операционным доходам банковского сектора превышает 54,2%, то это является вероятным признаком наступления кризиса.

На первом уровне разбиение всех наблюдений на кризисные и некризисные не является совершенным. Соответственно, мы переходим далее, где отдельно будем искать переменную для лучшего разбиения каждого из листов на втором уровне. Для некризисной группы наиболее сильной переменной, отделяющей кризисные наблюдения от спокойных, является LIQ_SUP — объем ликвидности, предоставленной во время предыдущего банковского кризиса. Для правого листа в качестве разбивающей переменной устанавливается INSURE — максимальная сумма по страхованию депозитов. И в правой части мы видим, что есть еще один уровень разбиения по переменной PEAK_NPL.

Полученное дерево демонстрирует набор простых правил (если индикатор ниже порогового значения, наблюдение попадает в лист справа, если выше — в лист слева), комбинация которых приводит в итоге к определенному прогнозу — 0 или 1. Судя по полученным цепочкам, комбинации признаков, ведущие к кризисам, могут быть различны, что подтверждает тот факт, что каждому кризису соответствует особенный сценарий.

В нашем случае мы наблюдаем следующие кризисные комбинации:

$$\text{COST_TO_INCOME_RATIO} > 54 + \text{INSURE} < 633 + \text{PEAK_NPL} > 0,25$$

$$\text{либо } \text{COST_TO_INCOME_RATIO} < 54 + \text{LIQ_SUP} > 4,8.$$

Полученные результаты свидетельствуют о значимости характеристик прошлых банковских кризисов, в частности высокой поддержки ликвидности со стороны государства (LIQ_SUP), а также страхования депозитов (INSURE) для прогнозирования будущих негативных событий. Оба показателя наряду с установлением и контролем за выполнением требований к капиталу, а также разработкой процедур банкротства банков входят в так называемую систему банковской безопасности (*banking safety net*).

Положительное влияние обеих этих переменных на вероятность новых кризисов связано с понятием «риск недобросовестного поведения», что означает менее ответственное поведение финансовых институтов в отношении рискованных активов и операций. Получается, что банки рассматривают и поддержку центрального банка в кризис, и систему страхования депозитов как некую «страховку» от банкротства, и раз они ею обладают, то могут снизить собственное внимание к устойчивости.

Предоставление чрезвычайной ликвидности в период кризиса центральным банком относится к его функции кредитора последней инстанции. Это до сих пор одна из самых противоречивых функций регулятора. С одной стороны, учитывая двойственный мандат по ценовой и финансовой стабильности, деятельность по предоставлению чрезвычайной ликвидности неизбежна, так как центральный банк несет ответственность за предотвращение банкротств институтов, которые могут угрожать функционированию всей финансовой системы, а также за распространение заражения на финансовом рынке. С другой стороны, это повышает риск недобросовестного поведения на финансовом рынке.

До глобального финансово-экономического кризиса 2007–2009 гг. господствовало мнение, что в целях избежания риска недобросовестного поведения в отношении предоставления экстренной помощи в кризис центральные банки должны придерживаться «конструктивной двусмысленности» (*constructive ambiguity*). Это означало, что реализация помощи финансовому сектору со стороны центрального банка в период кризиса является полностью дискреционной, и таким образом поддерживается неопределенность ожиданий агентов в отношении того, будет ли предоставлена ликвидность или нет, а также в отношении условий, на которых такая помощь может быть гарантирована.

Однако кризис 2007–2009 гг. сделал затруднительным реализацию принципа «конструктивной двусмысленности» в США и в ряде других стран. Во-первых, в период кризиса оказалось невозможным отделить институты, испытывающие проблемы с ликвидностью, от неплатежеспособных. Во-вторых, во избежание краха финансовой системы регулятор приходилось предоставлять помощь институтам, обеспечиваемую достаточными, но неликвидными активами, а в некоторых случаях — вообще без обеспечения, так как предоставление помощи по высокой кредитной ставке для некоторых институтов могло усугубить их проблемы. Все это привело к расширению списка институтов, куда вошли и небанковские организации (в США), которым была предоставлена финансовая помощь. Такая ситуация создает риски, что в будущем эти институты также могут ожидать помощи от регулятора.

В период кризиса наблюдалась конвергенция операционных процедур центральных банков в разных странах. Регуляторы перенимали друг у друга опыт использования наиболее эффективных инструментов по «успокоению рынка». Такие инструменты включали: 1) срочное предоставление ликвидности различным участникам рынка, в том числе под обеспечение более широким кругом активов, чем это предполагалось в стабильные периоды (США, Великобритания, Канада); вообще без обеспечения (Россия); в том числе небанковским институтам, которые не значились в списке тех, кому центральный банк мог предоставлять ликвидность (США); 2) конвергенцию политик в отношении обеспечения по мере изменения состояния рынка; 3) увеличение срока, на который предоставляется ликвидность; 4) сотрудничество центральных банков по взаимному предоставлению ликвидности (своп-линии). Гибкое использование этих инструментов было направлено на избежание стигмы банкротства, связанной с использованием автоматических операций постоянного действия⁷, и позволяло центральным банкам поддерживать базовые функции финансового рынка. Тем не менее подобные случаи гибкого использования инструментов со стороны центрального банка требуют тщательного определения пределов их использования [Chailloux et al., 2008].

Проведенные нами расчеты подчеркивают, насколько важно учитывать уровень риска недобросовестного поведения в отношении будущих кризисных событий. Наши результаты согласуются с эмпирическими исследованиями о положительной взаимосвязи новой посткризисной системы безопасности банков и будущих кризисов, в частности с работами [Bordo, 2014; Goodfriend, 2014; Haltom, Lacker, 2015; Ferguson et al., 2023]. На данный момент есть достаточно большое количество исследований относительно новых принципов работы центрального банка как кредитора последней инстанции [Domanski, Sushko, 2014; Hauser, 2014; Nijskens, 2014; Tucker, 2014; Dobler et al., 2016], но все они носят общий характер, в них нет количественных оценок того, когда предоставление ликвидности может иметь дестабилизирующий эффект; каков риск недобросовестного поведения в системе после таких действий центрального банка. На наш взгляд, необходимо более детальное, в том числе и количественное, исследование, каким образом финансовая помощь со стороны регулятора влияет на поведение финансовых институтов, как это зависит от структуры банковской системы, каковы косвенные эффекты такой помощи, какая из форм предоставления ликвидности — отдельным финансовым институтам или всему рынку — в большей степени связана с вероятностью новых банковских кризисов.

⁷ Стигма связана с тем, что сам факт использования кредитных инструментов постоянного действия может быть трактован как наличие проблем у финансового института, который в этой процедуре участвует. В период кризиса, чтобы поддержать рынок, центральный банк снижал стоимость такого заимствования и продлевал срок, на который оно предоставлялась, однако в большинстве случаев этого все равно было недостаточно, чтобы побороть стигму.

Устойчивость результатов

Для проверки результатов на устойчивость мы применяем метод байесовского усреднения моделей, который традиционно используется для преодоления проблемы неопределенности относительно истинной модели. Работа алгоритма заключается в следующем. Предполагается, что каждой модели соответствует некая случайная величина M , принимающая значение из множества $s = 1, \dots, S$. В том случае, когда $M = s$, истинной моделью является модель s .

Изначально исследователь имеет априорные представления о вероятностном распределении моделей $p(M = s)$. Имеющийся набор данных X дает дополнительную информацию о вероятностях моделей. На основе новых данных рассчитываются апостериорные вероятности моделей, а также апостериорные вероятности включения рассматриваемых переменных в эту истинную (лучшую) модель.

Апостериорная вероятность модели в общем виде может быть рассчитана по следующей формуле:

$$\text{Prob}(Z|S) = \sum_{k \in N} \text{Prob}(Z = 1|S, M_k) * \text{Prob}(M_k|S),$$

где $\text{Prob}(Z|S)$ – апостериорная вероятность переменной Z с учетом набора данных S ;
 $\text{Prob}(Z|S, M_k)$ – апостериорная вероятность переменной Z с учетом набора данных S и модели M_k ;

$\text{Prob}(M_k|S)$ – апостериорная вероятность модели M_k с учетом набора данных S .

В табл. 4 представлены стандартные результаты, которые мы получаем при применении байесовского усреднения моделей.

Согласно общепринятой практике значимыми переменными считаются те, для которых апостериорная вероятность включения в наилучшую модель превышает 50%. В нашем случае это переменная LIQ_SUP. Все остальные переменные имеют апостериорную вероятность включения ниже 50%, следовательно, включение их в модель для прогнозирования банковских кризисов является дискуссионным.

Таблица 4

Вероятность включения переменных в финальную модель

Переменная	Апостериорная вероятность включения переменных в финальную модель (<i>Posterior Inclusion Probability, PIP</i>)	Среднее значение оценки коэффициента (MEAN)	Стандартное отклонение оценки коэффициента (SD)
LIQ_SUP	0,91	0,0025	0,0011
PEAK_NPL	0,45	0,0007	0,0009
L_GDPGR	0,30	0,0008	0,0014
PUB_DEBT	0,18	0,0002	0,0004
L_GOV_BANKS	0,18	-0,0001	0,0003
L_DEP_ASSET	0,13	0,0000	0,0001
L_DOM_CRED	0,09	0,0000	0,0001
L_FOR_BANKS	0,05	0,0000	0,0001
L_COST_TO_INCOMERATIO	0,03	0,0000	0,0001
L_Z	0,02	0,0000	0,0001
L_GOVDEBT	0,02	0,0000	0,0000
INSURE	0,02	0,0000	0,0000
L_CONCENTR	0,02	0,0000	0,0000
L_IMAPP	0,02	0,0000	0,0016

Источник: расчеты авторов.

Таким образом, размер финансовой помощи регуляторов в течение предыдущего банковского кризиса действительно оказывает значимое положительное влияние на вероятность нового кризисного события. Результаты байесовского усреднения моделей в целом подтверждают те выводы, которые мы получили с помощью CART.

ЗАКЛЮЧЕНИЕ

Цель данной работы заключалась в определении тех факторов, которые могут быть релевантны для прогнозирования банковских кризисов. Также мы стремились уточнить, как характеристики прошлых банковских кризисов влияют на вероятность новых негативных событий в финансовой сфере.

Для достижения этой цели мы собрали данные по 56 странам за период с 2000 по 2021 г. В число потенциальных предикторов были включены показатели прошлых банковских кризисов, характеристики национальных банковских секторов, институциональные и макроэкономические показатели. Для прогнозирования мы использовали дерево решений, которое позволяет определить наиболее вероятные комбинации разных факторов, которые ведут к кризису, а также устанавливает пороговые значения для переменных, превышение которого может увести экономику в опасную зону.

Полученные нами результаты свидетельствуют о том, что характеристики прошлых банковских кризисов релевантны для определения вероятности новых кризисов. Мы связываем это с тем, что чрезмерно активная государственная поддержка финансовых институтов в период кризиса снижает их стимулы к более ответственному поведению. Вкупе со снижением показателей эффективности банков такая ситуация в последующем повышает вероятность новых банковских кризисов.

Результаты нашего исследования свидетельствуют о необходимости дальнейшего количественного анализа того, какая сумма финансовой поддержки в период кризиса будет оптимальной. Задача регулятора как кредитора последней инстанции с учетом этого оказывается более сложной — ему необходимо соблюдать баланс не только между финансовой и ценовой стабильностью в период кризисных событий в банковском секторе, но и учитывать последствия таких действий для стабильности банковской системы в будущем.

Список литературы / References

1. Ларина О. И. Банковские кризисы: проблемы их идентификации и преодоление // Управление. 2017. № 70. С. 9–15. https://doi.org/10.12737/article_59537e6a9b2da4.92003456 / Larina O.I. (2017). Banking Crises: Identification Problems and Resolution. *Upravlenie – Management*, 70, 9–15 (In Russ.). https://doi.org/10.12737/article_59537e6a9b2da4.92003456.
2. Alessi L., Detken C. (2018). Identifying Excessive Credit Growth and Leverage. *Journal of Financial Stability*, 35, 215–225. <https://doi.org/10.1016/j.jfs.2017.06.005>.
3. Alessi L., Savona R. (2021). Machine learning for financial stability Data Science for Economics and Finance: Methodologies and Applications. Springer International Publishing. https://doi.org/10.1007/978-3-030-66891-4_4.
4. Andersson F. (2016). A Blessing in Disguise? Banking Crises and Institutional Change. *World Development*, 83, 135–147. <https://doi.org/10.1016/j.worlddev.2016.02.002>.
5. Anginer D., Demircuc-Kunt A., Zhu M. (2014). How Does Deposit Insurance Affect Bank Risk? Evidence From the Recent Crisis. *Journal of Banking and Finance*, 48, 312–321. <https://doi.org/10.1016/j.jbankfin.2013.09.013>.
6. Belkhir M., Naceur S., Candelon B. et al. (2022). Macroprudential Policies Economic Growth and Banking Crises. *Emerging Markets Review*, 53, 100936. <https://doi.org/10.1016/j.ememar.2022.100936>.
7. Beutel J., List S., von Schweinitz G. (2018). An Evaluation of Early Warning Models for Systemic Banking Crises: Does Machine Learning Improve Predictions? *Deutsche Bundesbank Discussion Paper Series*, 48, 1–49.
8. Bluwstein K., Buckmann A., Joseph M. et al. (2020). Credit Growth the Yield Curve and Financial Crisis Prediction: Evidence from A Machine Learning Approach. *Journal of International Economics*, 103773.

9. Bordo M., Eichengreen B., Klingebiel D. et al. (2001). Is The Crisis Problem Growing More Severe? *Economic Policy*, 16, 51–82. <https://doi.org/10.1111/1468-0327.00070>.
10. Bordo M. (2014). Rules for a Lender of Last Resort: A Historical Perspective. *Journal of Economic Dynamics and Control*, 49, 126–134. <https://doi.org/10.1016/j.jedc.2014.09.023>.
11. Calomiris C. (2012). The Great Depression and other 'contagious' events. The Oxford Handbook of Banking (1ed.). <https://doi.org/10.1093/oxfordhb/9780199640935.013.0027>.
12. Caprio G., Klingebiel D. (1996). Bank insolvencies cross-country experience. *Working Paper*, 1620, 1–60.
13. Casabianca E. et al. (2019). An early warning system for banking crises: From regression-based analysis to machine learning techniques. Orebro: Orebro University.
14. Díaz-Martínez Z., Sánchez-Arellano A., Segovia-Vargas M.J. (2011). Prediction of Financial Crises by Means of Rough Sets and Decision Trees. *INNOVAR. Revista De Ciencias Administrativas Y Sociales*, 21, 39, 83–100.
15. Doblér M., Gray M., Murphy D. et al. (2016). The Lender of Last Resort Function After the Global Financial Crisis. *International Monetary Fund Working Paper*, 16/10.
16. Domanski D., Sushko V. (2014). Rethinking the Lender of Last Resort: Workshop Summary. BIS Paper (79a).
17. Drehmann M., Juselius M. (2014). Evaluating Early Warning Indicators of Banking Crises: Satisfying Policy Requirements. *International Journal of Forecasting*, 30, 3, 759–780. <https://doi.org/10.1016/j.ijforecast.2013.10.002>.
18. Duttagupta R., Cashin P. (2011). Anatomy of Banking Crises in Developing and Emerging Market Countries. *Journal of International Money and Finance*, 30 (2), 354–376. <https://doi.org/10.1016/j.jimonfin.2010.08.006>.
19. Eidenberger J., Sigmund M., Neudorfer B. et al. (2014). What Predicts Financial (In)Stability? A Bayesian Approach. *Deutsche Bundesbank Discussion Paper*, 36, 1–40.
20. Ferguson N., Kornejew M., Schmelzing P. et al. (2023). The Safety Net: Central Bank Balance Sheets and Financial Crises. *CERP (Centre for Economic Policy Research) Discussion Paper*, 17858.
21. Frydman C., Xu Ch. (2023). Banking Crises in Historical Perspective. *NBER Working Papers*, 31092.
22. Gabriele C. (2019). Learning from Trees: A Mixed Approach to Building Early Warning Systems for Systemic Banking Crises. *Vie & Sciences De L'entreprise*, 1, 37–69. <http://dx.doi.org/10.2139/ssrn.3486928>.
23. Geršl A., Jašová M. (2018). Credit-Based Early Warning Indicators of Banking Crises in Emerging Markets. *Economic Systems*, 42 (1), 18–31. <https://doi.org/10.1016/j.ecosys.2017.05>.
24. Goodfriend M. (2014). Lessons from a Century of FED Policy: Why Monetary and Credit Policies Need Rules and Boundaries. *Journal of Economic Dynamics and Control*, 49, 112–120. <https://doi.org/10.1016/j.jedc.2014.09.005>.
25. Gries T., Meierrieks D. (2013). Do Banking Crises Cause Terrorism? *Economics Letters*, 119 (3), 321–324. <https://doi.org/10.1016/j.econlet.2013.03.009>.
26. Guidolin M., Hansen E., Pedio M. (2019). Cross-Asset Contagion in The Financial Crisis: A Bayesian Time-Varying Parameter Approach. *Journal of Financial Markets*, 45, 83–114. <https://doi.org/10.1016/j.finmar.2019.04.001>.
27. Gutmann J., Pfaff K., Voigt S. (2017). Banking Crises and Human Rights. *Applied Economics Letters*, 24 (19), 1374–1377. <https://doi.org/10.1080/13504851.2017.1279264>.
28. Haltom R., Lacker J.M. (2015). Should The Fed Have a Financial Stability Mandate? Lessons From the Fed's First 100 Years. *Economic Quarterly* (1Q), 49–75. <http://dx.doi.org/10.21144/eq1010104>.
29. Hauser A. (2014). Lender of Last Resort Operations During the Financial Crisis: Seven Practical Lessons from the United Kingdom. *BIS Paper*, 79e.
30. Holopainen M., Sarlin P. (2017). Toward Robust Early-Warning Models: A Horse Race Ensembles and Model Uncertainty. *Quantitative Finance*, 17 (12), 1933–1963. <https://doi.org/10.1080/14697688.2017.1357972>.
31. International Monetary Fund (1998). World Economic Outlook. Financial Crises: Causes and Implications.
32. Frankel J., Wei S. (2004). Managing Macroeconomic Crises. *NBER Working Papers*, 10907.
33. Joy M., Rusnk M., Smdkova K. et al. (2017). Banking and Currency Crises: Differential Diagnostics for Developed Countries. *International Journal of Finance and Economics*, 22 (1), 44–67. <http://dx.doi.org/10.2139/ssrn.2621627>.
34. Kaminsky G. (2006). Currency Crises: Are They All the Same. *Journal of International Money and Finance*, 25, 503–527. <https://doi.org/10.1016/j.jimonfin.2006.01.002>.
35. Kindleberger C. (1978). Manias Panics and Crashes: A History of Financial Crises. New York: Basic Books.
36. Laeven L., Valencia F. (2008) Systemic Banking Crises: A New Database. *International Monetary Fund Working Paper*, 08/224. <https://doi.org/10.5089/9781451870824.001>.
37. Laeven L., Valencia F. (2010). Resolution of Banking Crises: The Good, the Bad and the Ugly. *International Monetary Fund Working Paper*, 10/146.
38. Laeven L., Valencia F. (2020). Systemic Banking Crises Database II. *IMF Economic Review*, 68, 307–361. <https://doi.org/10.1057/s41308-020-00107-3>.
39. Lang H. Peltonen T., Sarlin P. (2018). A Framework for Early-Warning Modeling with an Application to Banks. *European Central Bank Working Paper*, 2182.
40. Manasse P., Roubini N., Schimmlerpfennig A. (2003). Predicting Sovereign Debt Crises. IMF Working Paper WP 03/221.
41. Manasse P., Savona R., Vezzoli M. (2016). Danger Zones For Banking Crises in Emerging Markets. *International Journal of Finance and Economics*, 21, 360–381.

42. Manasse P., Savona R., Vezzoli M. (2013). Rules of Thumb for Banking Crises in Emerging Markets. *IGIER (Innocenzo Gasparini Institute for Economic Research) Working Paper*, 481.
43. Nakatani R. (2020). Macroprudential Policy and the Probability of a Banking Crisis. *Journal of Policy Modeling*, 42 (6), 1169–1186. <https://doi.org/10.1016/j.jpolmod.2020.05.007>.
44. Nijskens R. (2014). A Sheep in Wolf's Clothing: Can a Central Bank Appear Tougher Than It Is? *Journal of Banking and Finance*, 48, 94–103. <https://doi.org/10.1016/j.jbankfin.2014.07.009>.
45. Reinhart C., Rogoff K. (2009). *This Time Is Different: Eight Centuries of Financial Folly*. Princeton, NJ: Princeton University Press. 496 p.
46. Ristolainen K. (2018). Predicting Banking Crises with Artificial Neural Networks: The Role of Nonlinearity and Heterogeneity. *The Scandinavian Journal of Economics*, 120 (1), 31–62. <https://doi.org/10.1111/sjoe.12216>.
47. Romer C., Romer D. (2019). Fiscal Space and The Aftermath of Financial Crises: How It Matters and Why. *National Bureau of Economic Research Working Paper*, 25768.
48. Savona R., Vezzoli M. (2015). Fitting and Forecasting Sovereign Defaults Using Multiple Risk Signals. *Oxford Bulletin of Economics and Statistics*, 77 (1), 66–92. <https://doi.org/10.1111/obes.12052>.
49. Shchepeleva M., Stolbov M., Weill L. (2022). Has the Global Financial Crisis Increased Wealth Inequality? *International Economics*, 169, 148–160. <http://dx.doi.org/10.2139/ssrn.3916062>.
50. Tanaka K., Kinkyo T., Hamori S. (2016). Random Forests-Based Early Warning System for Bank Failures. *Economics Letters*, 148, 118–121. <https://doi.org/10.1016/j.econlet.2016.09.024>.
51. Tölö E., Laakkonen H., Kalatie S. (2018). Evaluating Indicators for Use in Setting the Countercyclical Capital Buffer. *International Journal of Central Banking*, 53, March.
52. Tsay R., Ando T. (2012). Bayesian Panel Data Analysis for Exploring the Impact of Subprime Financial Crisis on The US Stock Market. *Computational Statistics and Data Analysis*, 56 (11), 3345–3365. <https://doi.org/10.1016/j.csda.2010.11.028>.
53. Tucker P. (2014). The Lender of Last Resort and Modern Central Banking: Principles and Reconstruction. *BIS Paper*, 79b.
54. Ward F. (2017). Spotting the Danger Zone: Forecasting Financial Crises with Classification Tree Ensembles and Many Predictors. *Journal of Applied Econometrics*, 32 (2), 359–378. <https://doi.org/10.1002/jae.2525>.
55. Wicker E. (2000). *The Banking Panics of the Great Depression*. Cambridge University Press.
56. Yohannes Y., Hoddinott J. (1999). *Classification and Regression Trees: An Introduction*. International Food Policy Research Institute.

ПРИЛОЖЕНИЯ

Приложение 1

Описательные статистики
для объясняющих переменных

	count	mean	std	min	0,25	0,5	0,75	max
cost_to_income ratio	1176	57,21	15,22	0	49,73	56,92	65,21	237,05
peak_npl	1176	4,26	9,91	0	0	0	3,2	55,11
pub_debt	1176	6,55	14,76	-5,03	0	0	3,78	81,89
insure	1176	1043,57	3545,89	21	244,75	340	721	26 846
l_cost_to_incomeratio	1176	57,38	15,09	0	49,8	56,99	65,21	237,05
l_gdpgr	1176	3,11	4,21	-21,4	1,34	3,15	5,37	34,5
l_govdebt	1176	37,23	75,91	0	0	9,71	52,27	746
l_imapp	1176	0,02	0,33	-5	0	0	0	4
l_gov_banks	1176	4,36	12,22	0	0	0	0	72,26
l_for_banks	1176	10,54	23,15	0	0	0	1,82	96
l_dom_cred	1176	61,02	50,83	0	24,5	48,83	91,01	255,31
l_dep_asset	1176	71,02	45,32	0	35,65	61,05	104,82	225,33
l_concentr	1176	72,71	21,93	0	64,16	76,21	88,2	100

Источник: расчеты авторов.

Приложение 2

Список стран, которые вошли в выборку

Албания, Аргентина, Армения, Австрия, Азербайджан, Бангладеш, Беларусь, Бельгия, Бразилия, Болгария, Хорватия, Кипр, Чехия, Эквадор, Сальвадор, Эстония, Финляндия, Франция, Германия, Венгрия, Индия, Индонезия, Италия, Япония, Иордания, Казахстан, Кения, Киргизия, Латвия, Ливан, Литва, Малайзия, Мексика, Молдавия, Монголия, Марокко, Непал, Нидерланды, Норвегия, Парагвай, Перу, Польша, Португалия, Румыния, Россия, Словения, Испания, Швеция, Швейцария, Таиланд, Уганда, Украина, Великобритания, США, Уругвай, Вьетнам

Источник: составлено авторами.

Информация об авторах

Александр Паталаха, Национальный исследовательский университет «Высшая школа экономики», г. Москва

Мария Александровна Щепелева, кандидат экономических наук, доцент Департамента теоретической экономики Национального исследовательского университета «Высшая школа экономики», г. Москва

Information about the authors

Alexandr Patalaha, HSE University, Moscow

Maria A. Shchepelava, Candidate of Economic Sciences, Associate Professor, HSE University, Moscow

Статья поступила в редакцию 20.09.2023
Одобрена после рецензирования 02.11.2023
Принята к публикации 05.12.2023

Article submitted September 20, 2023
Approved after reviewing November 2, 2023
Accepted for publication December 5, 2023