

Научная статья

УДК 336.7

EDN [BEVWNH](#)

DOI 10.17150/2411-6262.2023.14(3).822-834

В.А. Казаринов¹ , Н.А. Звягинцева² ¹ АО «Технологии Доверия», г. Москва, Российская Федерация² Байкальский государственный университет, г. Иркутск, Российская ФедерацияАвтор, ответственный за переписку: Н.А. Звягинцева, legnata2010@yandex.ru

КРИТЕРИИ ЭФФЕКТИВНОСТИ МОДЕЛЕЙ ТЕНЕВЫХ РЕЙТИНГОВ ПРИ ОЦЕНКЕ КРЕДИТОСПОСОБНОСТИ НИЗКОДЕФОЛТНЫХ ЗАЕМЩИКОВ

АННОТАЦИЯ. Оценка кредитоспособности заемщиков является важнейшим процессом, влияющим на деятельность современного коммерческого банка. Процессы оценки кредитоспособности возникают как на этапе принятия решения о выдаче кредитного продукта, так и в процессе регулярной оценки кредитоспособности для целей резервирования и расчета экономического капитала. В связи с этим у банка возникает необходимость в разработке и сопровождении работы эффективных моделей оценки кредитного рейтинга, способных точно и стабильно определять кредитоспособность заемщика путем предсказания его вероятности дефолта.

В статье рассматриваются проблематика определения критериев эффективности моделей теневых рейтингов, используемых для оценки вероятности дефолта низкодефолтных сегментов банковского кредитования. Модели теневых рейтингов могут использоваться как в бизнес-целях, так и в регуляторных целях. В зависимости от установленной цели, на каждом этапе разработки модели теневых рейтингов возникает ряд специфичных для этого класса моделей проблем, которые ложатся в основу определения критериев эффективности: корректная спецификация выборки данных, гармонизированность оценок рейтинговых агентств, корректный выбор алгоритма расчета, удовлетворение критериям количественной валидации и обоснованность экспертных корректировок. Соответствие данным критериям с учетом установленной цели позволяет сделать вывод об эффективности полученной модели.

КЛЮЧЕВЫЕ СЛОВА. Кредитный риск, модели кредитного риска, модели теневых рейтингов, вероятность дефолта, модельный риск, кредитоспособность.

ИНФОРМАЦИЯ О СТАТЬЕ. Дата поступления 10 мая 2023 г.; дата принятия к печати 05 июля 2023 г.; дата онлайн-размещения 31 августа 2023 г.

Original article

V.A. Kazarinov¹ , N.A. Zvyagintseva² ¹ JSC "Technologies of Trust", Moscow, Russian Federation² Baikal State University, Irkutsk, Russian FederationCorresponding author: N.A. Zvyagintseva, legnata2010@yandex.ru

CRITERIA FOR THE EFFECTIVENESS OF SHADOW RATING MODELS IN ASSESSING THE CREDITWORTHINESS OF LOW-DEFAULT BORROWERS

ABSTRACT. Assessment of borrowers' creditworthiness is the most important process affecting the activities of a modern commercial bank. Creditworthiness assessment processes occur both at the stage of decision-making to issue a credit product and during the process of regular creditworthiness assessment for the purposes of reserving and calculating economic capital. This is the reason why the commercial bank needs to develop and maintain the effective models of credit rating estimation, which

© Казаринов В.А., Звягинцева Н.А., 2023

are able to determine the borrower's solvency accurately and steadily by predicting its probability of default.

This examines with the problem of determining the criteria for the effectiveness of shadow rating models used to estimate the probability of default of low-default segments of bank lending. Shadow rating models can be used both for business purposes and for regulatory purposes. Depending on the goal set, a number of problems specific to this class of models arise at each stage of shadow rating model development, which form the basis for the definition of performance criteria: correct specification of data samples, harmonization of rating agencies' assessments, correct choice of calculation algorithm, satisfaction of quantitative validation criteria and validity of expert corrections. Compliance with these criteria, taking into account the established objective, allows us to conclude on the effectiveness of the obtained model.

KEYWORDS. Credit risk, credit risk models, shadow rating models, probability of default, model risk, creditworthiness.

ARTICLE INFO. Received May 10, 2023; accepted July 05, 2023; available online August 31, 2023.

Введение

Банковское кредитование является одним из главных источников формирования инвестиционных потоков в любой экономике. На конец 2022 г. объем кредитного портфеля в российском банковском секторе составлял 86 трлн р., из которых почти 70 % составляло корпоративное кредитование¹. По мере роста объема кредитного портфеля, все большую значимость приобретает необходимость комплексной оценки кредитоспособности заемщиков.

Способность прогнозировать кредитоспособность заемщиков позволяет банкам формировать резервы [1], удовлетворяющие требованиям МСФО, рассчитывать экономический и регуляторный капитал, а также определить оптимальную кредитную ставку при заключении кредитного договора. В глобальном масштабе вся финансовая система страны зависит от способности банков точно прогнозировать банкротство и принимать меры предосторожности. Особенно оценки кредитоспособности актуальны для низкодефолтных сегментов, так как дефолты подобных заемщиков могут повлечь системный кризис в экономике страны. Анти-примером может служить мировой кризис 2008 г., который явился следствием системной недооценки кредитных рисков, в сфере ипотечного кредитования [2].

Крупные коммерческие банки для определения кредитоспособности используют модели кредитного рейтинга. Эти модели используются разными подразделениями банка для предсказания вероятности выхода заемщика (или отдельного кредитного требования) в дефолт. В частности, модели предсказывают, какой кредитный рейтинг может быть присвоен заемщику или кредитному требованию [3]. Для построения и тестирования таких моделей используется статистическая информация, накопленная банком за определенный внутренними правилами или требованиями регулятора период.

Также для построения модели кредитного рейтинга необходимо использовать данные об исторических дефолтах заемщиков или кредитных требованиях банка. Это позволяет прогнозировать вероятность дефолта заемщика (PD). Однако для низкодефолтных сегментов (например, финансовых организаций) данные о дефолте не могут быть использованы при моделировании в связи с низким числом дефолтных наблюдений в портфеле, поэтому в таких случаях могут применяться

¹ Банк России. Банковский сектор. 2022 год. Аналитический обзор. Март 2022. URL: https://cbr.ru/Collection/Collection/File/43816/analytical_review_bs-2022.pdf.

модели теневого рейтинга². В отличие от стандартных моделей оценки вероятности дефолта, модели теневого рейтинга используют внешние рейтинги от сертифицированных рейтинговых агентств и прогнозируют вероятность того, что заемщик имеет определенный рейтинг. В свою очередь, на основе прогноза рейтинга оценивают вероятность дефолта заемщика.

На всех этапах разработки моделей теневого рейтинга возникает ряд вопросов, которые порождают необходимость оценки эффективности модели, решающее значение при этом приобретает определение критериев эффективности. В данной статье представлен набор критериев, которые позволяют в полном объеме оценить эффективность модели теневого рейтинга и сделать вывод о возможности ее использования для выделенных целей. Основной фокус статьи сосредоточен на процессе кредитного скоринга в коммерческом банке, однако данная логика может также быть экстраполирована на процесс моделирования кредитного риска в других организациях или в академических целях.

Этапы построения моделей теневого рейтинга

Как было отмечено выше, модели теневого рейтинга — это класс моделей, которые используют данные внешнего рейтинга для прогнозирования уровня дефолта. Определение данных моделей впервые было представлено в докладе Базельского комитета³. Эти модели могут быть построены как на основе моделей машинного обучения, так и на основе статистических моделей. Основное достоинство подхода на основе теневого рейтинга (Shadow Ratings-based Approach — SRA) заключается в том, что они позволяют оценить риск дефолта заемщика на основе доступной информации от рейтинговых агентств, даже если внутренняя информация о его кредитоспособности ограничена или недоступна [4]. Это делает SRA особенно привлекательной для оценки заемщиков с высокой капитализацией: банков, крупных добывающих компаний и ИТ-гигантов.

Для определения критериев эффективности модели важно понимать последовательность этапов моделирования. Для модели теневого рейтинга процесс можно описать следующей схемой (рис.). Так как в отличие от моделирования стандартных PD-моделей, где данные о дефолтах содержатся в базах данных банка, для описываемого класса моделей источником служат также внешние данные о рейтингах заемщиков от рейтинговых агентств. Перед формированием итоговой выборки данных важно провести предобработку каждой из двух частей данных. С этапа обучения модели процесс следует стандартному процессу моделирования оценок кредитных рейтингов. В связи с этим, проблема определения критериев оценки эффективности моделей, описанные в текущей статье, затрагивают два первых этапа моделирования — обработка данных и обучение модели.

Эффективная модель не только дает возможность корректно предсказывать кредитоспособность заемщиков, но и позволяет минимизировать модельный риск банка и сократить затраты на ее последующую доработку. Для класса моделей теневого рейтинга можно выделить ряд специфических критериев, по которым можно судить об эффективности модельной спецификации. Так, эффективно специфицированной для назначенных целей моделью теневого рейтинга является модель, которая:

1. Построена на корректно сформированной выборке данных.

² Validation of low-default portfolios in the Basel II Framework / Basel Committee on Banking Supervision (BCBS) // Basel Committee Newsletter. 2005. № 6. URL: https://www.bis.org/publ/bcbs_n16.pdf.

³ Ibid.

2. Использует гармонизированные оценки рейтинговых агентств при использовании данных нескольких агентств.

3. Использует подходящий для установленных целей алгоритм.

4. Удовлетворяют установленным критериям количественной валидации:

- предсказательная сила (точность предсказаний) модели;

- устойчивость предсказаний на любом промежутке времени;

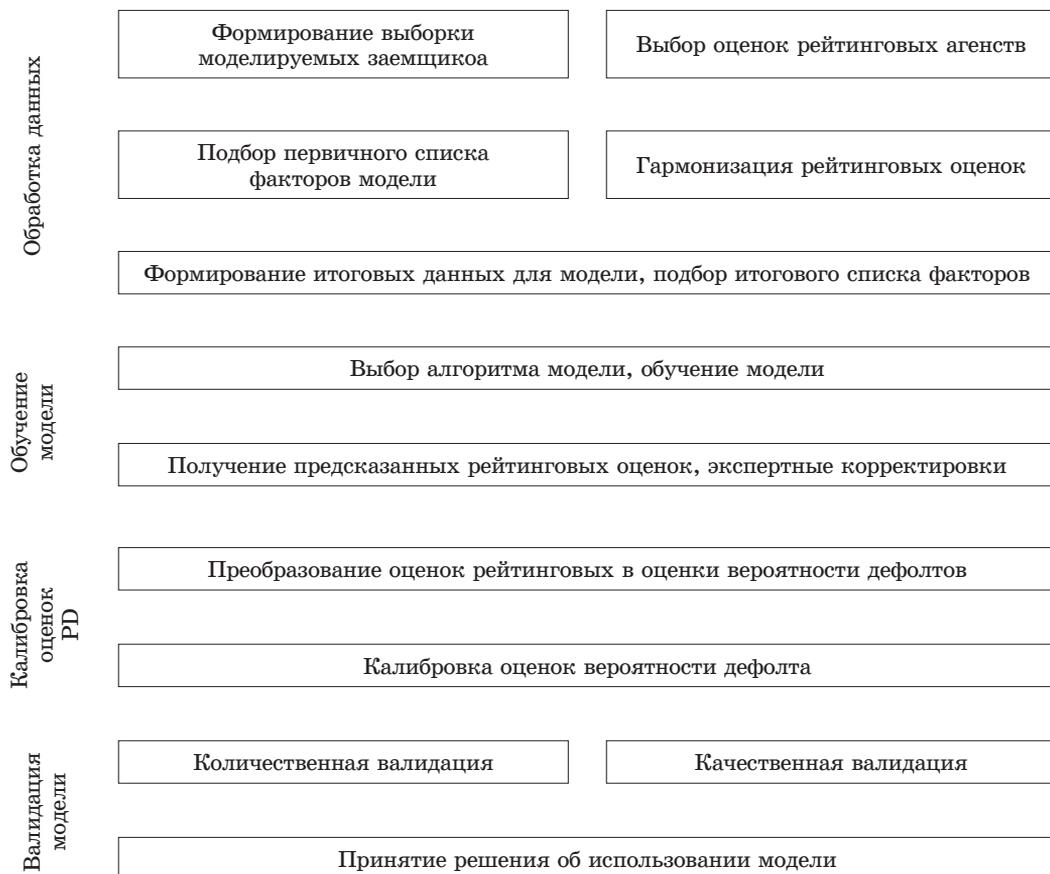
- стабильность точности предсказаний для заемщиков разного кредитного качества.

5. Содержит обоснованные экспертные корректировки, в допустимых пределах влияющие на итоговый результат кредитного скоринга.

При соблюдении указанных условий, одновременно выступающих критериями эффективности, модельные оценки кредитного рейтинга могут считаться достоверными. В следующих частях статьи детализируем каждый из выделенных критериев.

Критерий 1. Корректная спецификация выборки данных

Корректное формирование выборки данных для моделирования представляется одним из первостепенных условий, оказывающих влияние на эффективность



Этапы моделирования теневого рейтинга

модели теневого рейтингов. Выборка состоит из наблюдений, в качестве которых выступают данные о заемщиках банка в разные временные промежутки. Можно выделить ряд требований, предъявляемых к выборке данных:

1. *Все наблюдения в выборке относятся к сегменту, для которого разрабатывается модель.* В первую очередь требование о корректной спецификации относится к моделируемым сегментам. Например, важно понимать, что если модель была построена для оценки риска дефолта заемщиков — финансовых организаций, то в выборку для моделирования не должны входить заемщики из других сегментов (напр. компании добывающей отрасли).

2. *Данные содержат достаточное количество наблюдений, необходимых для построения модели.* Вторым важным условием является достаточное количество наблюдений. В процессе моделирования важно убедиться, что наблюдений в выборке достаточно, чтобы полученные результаты модели были несмещенными. Поскольку модели теневого рейтингов моделируют рейтинги крупных низкодефолтных заемщиков, проблема низкого количества наблюдений в выборке встречается регулярно. В случае, если наблюдений недостаточно, возможно использование дополнительных методов (напр. bootstrap [5]). Также допустимо использование внешних данных о компаниях, которые не содержатся в кредитном портфеле банка.

3. *Глубина данных покрывает полный экономический цикл.* Третьим условием является покрытие полного наблюдениями всего экономического цикла, включая кризисный период. Согласно требованиям Базельского комитета, минимальный период наблюдений составляет свыше 5 лет. Аналогичные требования выставляются Банком России по отношению к регуляторным моделям. Включение полного экономического цикла в выборку для наблюдений повышает стабильность прогнозов модели в периоды кризиса.

4. *Выбранные факторы модели позволяют покрыть основные сферы анализа.* Наконец, в процессе обработки данных важно комплексно подойти к процессу составления первичного списка факторов модели. Существует несколько классификаций, определяющих перечень факторов, которые необходимо учитывать при оценке кредитного рейтинга банка. Одна из наиболее ранних классификаций, известная как CAMELS [6], предлагает оценивать кредитоспособность банков на основе достаточности капитала, активов, возможностей управления, прибыли, ликвидности, чувствительности к рыночным рискам. Позже появились классификации, в которые были добавлены факторы операционной и регулятивной среды, как, например, в методологии рейтинга финансовой устойчивости банков Moody's⁴. В настоящее время методологии развились еще дальше, и теперь банки учитывают макроэкономические факторы, которые, как было доказано, влияют на окончательный рейтинг банка (см. Karminsky and Khromova [7] или Grunert et al. [8]). Например, согласно методологии Moody's⁵, банки оцениваются по следующей схеме:

1. Базовая оценка кредитоспособности:

- финансовые факторы — коэффициенты, которые могут быть получены из финансового отчета организации;
- макроэкономические факторы — глобальные факторы, влияющие на экономику в целом;

⁴ Banking Account and Ratio Definitions // Moody's Investors Service. February 2011. URL: <https://www.moodys.com/sites/products/productattachments/banking%20account%20and%20ratio%20definitions.pdf>.

⁵ Banks methodology // Moody's Investors Service. November 2019. URL: <https://ratings.moodys.com/api/rmc-documents/71997>.

– качественные корректировки — факторы, которые невозможно оценить в цифрах (например, прозрачность управления).

2. Вспомогательный и структурный анализ:

- аффилированная поддержка;
- анализ ответственности за потери при отказе;
- государственная поддержка.

Большинство национальных рейтинговых агентств также следуют этой тенденции, применяя аналогичные методологии, например, российское рейтинговое агентство АКРА⁶. Таким образом формируется первичный лист факторов модели. Далее различными методами анализа перечень факторов сужается, что позитивно влияет на устойчивость модели.

Критерий 2. Гармонизированность оценок рейтинговых агентств

Проблема сопоставимости рейтингов является одной из основных в современных исследованиях. Проблема возникает из-за того, что основные рейтинговые агентства используют различные подходы к оценке ключевых метрик: определение вероятности дефолта, метод калибровки PD и др. В результате пользователи рейтингов сталкиваются со значительными трудностями при сопоставлении шкал различных рейтинговых агентств, что ограничивает возможности проведения эмпирических исследований на больших массивах данных.

Было проведено множество исследований, направленных на решение этой проблемы. В работе Packer, Tarashev [9] методологии рейтингования трех крупнейших мировых рейтинговых агентств (S&P, Moody's, Fitch Ratings) были рассмотрены и проанализированы в исторической перспективе. Авторы утверждают, что после кризиса 2008 г. наблюдается сближение рейтингов перечисленных агентств, что связано с «эволюцией взглядов на внешнюю поддержку». Авторы также подчеркивают, что Moody's склонно давать более высокие оценки, чем Standard & Poor's и Fitch Ratings.

Аналогичный результат был получен в более позднем исследовании Karminsky and Khromova [7]. Здесь авторы приводят эмпирическое доказательство того, что в среднем Moody's имеет самый высокий показатель среди трех агентств. Также отмечается, что наилучшая предсказательная сила на данных выборки была достигнута на данных S&P. Однако их исследование также проводилось на старых данных (1996–2011 гг.), которые не отражают текущую ситуацию в плане различий в методологии.

Для того чтобы преодолеть проблему сопоставимости и расширить наблюдаемые данные, необходима специальная калибровочная модель. Одна из таких моделей была предложена Eisl et al. [10]. Этот подход «пересчета» основан на непараметрической оценке и поэтому не ограничен мерой кредитоспособности, временным горизонтом, методологией и масштабами. Таким образом, целью метода является определение сопоставимых границ шкал для каждой пары рейтинговых агентств с целью отображения всех рейтингов на уникальную шкалу. Другой подход, предложенный Карминским и Сосюрко [11], использует модель log-log регрессии для калибровки шкал. Согласно этому подходу, наилучшие показатели достигаются после использования логарифмического преобразования, поскольку на высоких рейтингах методологические различия менее очевидны, чем на низких рейтингах.

Отдельно следует отметить проблему применимости оценок международных рейтинговых агентств к российскому рынку. В настоящий момент количество рос-

⁶ Методология присвоения кредитных рейтингов банкам и банковским группам по национальной шкале для Российской Федерации // АКРА. 2022. 14 сент. URL: https://www.acra-ratings.ru/upload/iblock/a3a/2wemlf190ozvaktso02r7881s9o441tp/20220914_Banks_ru.pdf.

сийских компаний, попадающих под оценку международных рейтинговых агентств значительно сократилось, а история наблюдений российских национальных рейтинговых агентств (РА-Эксперт, АКРА, Рус Рейтингс и др.) зачастую не обладает достаточным объемом для составления достаточной для моделирования выборки. Это ставит перед моделистами задачу по использованию дополнительных методов по расширению объема выборки и проведению тестов на сопоставимость оценок.

Другой проблемой, возникающей при сопоставлении рейтинга с финансовыми данными в реальном времени, является временной разрыв между моментом представления отчета рейтингуемым контрагентом и моментом присвоения официального рейтинга агентством. Эта разница объясняется необходимостью оценить финансовый отчет, оценить качественные корректировки и выдать официальное заключение. В современной литературе лаг оценивается от 3 месяцев [12] до 6 месяцев [7].

Критерий 3. Корректный выбор алгоритма расчета

В основе оценки SRA лежат PD-модели — математические методы, которые помогают предсказать потенциальную вероятность дефолта. Это особенно актуально для компаний финансового сектора и, в частности, банков, где потенциальный риск при дефолте во много раз выше, чем в других сегментах. Если банк-кредитор неверно оценит вероятность дефолта банка-заемщика, это приведет к значительным потерям для инвесторов и даже может спровоцировать масштабный кризис, как это случилось в 2008 г. [13], поэтому повышение качества прогнозирования моделей является важной задачей. Существует список моделей, которые могут быть полезны для решения этой конкретной задачи: Altman Z-score [14], Ordered Probit [7], Random Forest [15], Gradient Boosting [16], Artificial Neural Networks [17] и др. Кроме того, существует несколько методик, которые помогают выбрать важные параметры для модели [18]. Сравнение предсказательной способности этих моделей и методов должно быть проведено для выбора наиболее точной модели для прогнозирования PD финансовых учреждений.

Все алгоритмы можно разделить на два больших класса: методы искусственного интеллекта (ИИ) и статистические методы [7]. Алгоритмы искусственного интеллекта — это сложные модели, которые могут находить нелинейные зависимости в структуре данных, и именно поэтому они оказались в центре внимания последних исследований. Эти модели представлены различными типами нейронных сетей (например, в работах Huang et al. [19] и Hajek [20]), алгоритмами градиентного бустинга [16], сложными классификаторами [18] и т.д. Методы искусственного интеллекта привлекают большое внимание академических исследователей и отделов управления рисками в банках и претендуют на то, чтобы стать будущим оценки рисков. Однако некоторые исследователи, как Lee [21] показали, что модели ИИ не обязательно обладают лучшей предсказательной способностью, чем стандартные модели, основанные на статистических методах. Более того, существует два основных недостатка, присущих этим сложным моделям.

Во-первых, методы ИИ предъявляют особые требования к объему анализируемых данных, поэтому для получения устойчивых результатов набор данных для проверки должен включать тысячи наблюдений. На практике эти методы применимы только для прогнозирования дефолтов розничных заемщиков, поскольку количество корпоративных заемщиков (и особенно банков) недостаточно велико для применения сложных моделей ИИ.

Во-вторых, результаты моделей ИИ в большинстве случаев не поддаются интерпретации. Согласно положению⁷ Центрального Банка России, коммерческим

⁷ О порядке расчета величины кредитного риска на основе внутренних рейтингов : Положение Банка России от 6 авг. 2015 г. N 483-П // СПС «КонсультантПлюс».

банкам разрешено использовать результаты моделей данного типа как в регуляторных целях для расчета обязательных нормативов достаточности капитала, так и для целей внутренних процедур оценки достаточности капитала (ВПОДК)⁸. Иными словами, алгоритм должен быть воспроизводим, а полученные коэффициенты модели являются интерпретируемыми. Практически все регуляторы в мире (за исключением Центрального Банка Испании) предъявляют данное требование к используемым методам оценки вероятности дефолта [22]. Для целей регуляторного использования данное требование отсекает большое количество моделей, основанных на алгоритмах машинного обучения. Тот факт, что результаты ИИ-моделей трудно объяснимы, определяет низкую популярность этих методов в управлении рисками, оставляя им роль внутреннего инструмента для ограниченного числа сегментов (например, индивидуальных заемщиков).

Что касается статистических методов, то они широко использовались для прогнозирования PD в течение длительного времени [23]. К этому классу относятся линейные вероятностные модели, множественный дискриминантный анализ [24] и методы множественного выбора, актуальные для SRA подхода — упорядоченные logit [25] и probit [26] регрессии. Последняя, по данным Hajek and Olej [18], показывает более высокую точность классификации по сравнению с первой. Относительная простота этих методов наряду с хорошей интерпретируемостью и меньшей требовательностью к размеру выборки данных сделали их широко используемым инструментом для прогнозирования PD в различных сегментах (как корпоративных, так и розничных заемщиков).

Большинство исследователей, изучающих российский банковский сектор, таких как А.Д. Живайкина и А.А. Пересецкий [12], Vasilyuk and Karminsky [27] или С.В. Овсейчик [28], используют статистические методы, такие как упорядоченный логит, однако лишь несколько попыток было предпринято применить алгоритмы искусственного интеллекта, например, в работах Karminsky and Khromova [7], Д.С. Челышев [29] или Karminsky and Khromova [30].

Таким образом, при выборе алгоритма, для соблюдения данного критерия эффективности важно ориентироваться не только на предсказательную способность моделей, но и учитывать ее применимость для различных целей (оценки регуляторного капитала, экономического капитала, принятия управленческих решений и т.д.).

Критерий 4. Удовлетворение критериям количественной валидации

Критерии дискриминационной точности, стабильности и устойчивости являются ключевыми характеристиками, определяющими качество любой модели оценки вероятности дефолта. Рассмотрим каждую из этих характеристик подробнее.

1. Предсказательная сила модели.

Основной характеристикой модели оценки вероятности дефолта является точность предсказаний. Модель должна быть точной в прогнозировании дефолта для каждого заемщика. Точность модели может быть оценена через отдельные показатели, такие как средняя абсолютная ошибка (MSE), коэффициент детерминации (R-squared), и средняя абсолютная процентная ошибка (MAPE). Для моделей классификации, которой является модель теневых рейтингов, точность может оцениваться методом несовпадения попаданий (hit-mismatch) доля корректно предсказанных рейтинговых категорий среди общего числа наблюдений в выборке, а также точность предсказаний в интервале ± 1 рейтинговая категория.

2. Устойчивость предсказаний на любом промежутке времени.

⁸ О требованиях к системе управления рисками и капиталом кредитной организации и банковской группы : Указание Банка России от 15 апр. 2015 г. N 3624-У // СПС «КонсультантПлюс».

Модель должна быть устойчивой в том смысле, что ее прогнозы не должны сильно меняться в зависимости от периода, для которого она используется. Другими словами, характеристики модели не должны иметь сильные отклонения в разные временные периоды. Чтобы определить стабильность модели, используют динамику точности прогнозов на временном ряду.

3. Стабильность точности предсказаний для заемщиков разного кредитного качества.

Стабильность модели оценки вероятности дефолта тесно связана с ее способностью сохранять точность и стабильность на портфелях разного качества. Более того, модели должны быть устойчивыми на различных временных периодах, т.е. модель должна иметь возможность корректно предсказывать рейтинги на разных стадиях экономического цикла. Стабильность модели может быть протестирована путем применения кросс-валидационных процедур [31].

Как правило, пороги приемлемости устанавливаются для каждого критерия с учетом экспертного мнения.

Критерий 5. Обоснованность экспертных корректировок

Последним критерием эффективности модели теневого рейтинга для оценки кредитного риска — это обоснованность экспертных корректировок полученного рейтинга. Корректировки рейтингов зачастую необходимы, чтобы учесть качественные факторы, которые не учитываются в модели, но важны для оценки кредитного риска конкретной заявки [32]. Корректировки в соответствии с положениями Центрального банка РФ в значительной степени регламентированы, что не позволяет значительно изменять присвоенную моделью оценку кредитного риска. На практике банки допускают корректировку в пределах ± 2 рейтинговой категории. Тем не менее, корректировки особенно актуальны для крупных компаний в силу невозможности учета индивидуальных факторов статистическим алгоритмом. Как правило, экспертным мнением учитывается моментальная платежеспособность заемщика по другим открытым кредитам (с опорой на информацию из БКИ), а также поддержка основного общества, материнской компании или государства. Важно, чтобы корректировки проводились экспертами, имеющими достаточный опыт и знания в области кредитного риска, чтобы исключить субъективность и ошибки при проведении процедур.

Набор перечисленных выше качественных критериев позволяет определить корректность спецификации модели теневого рейтинга на основных ключевых этапах разработки модели. Одновременное соблюдение указанных критериев позволяет определить, что данные зависимой переменной и факторы модели выбраны корректно и соотносятся между собой, алгоритм модели соответствует требуемым параметрам, модель демонстрирует точные и стабильные результаты, а экспертные корректировки не искажают результатов модельной оценки. В то же время, при анализе модели невозможно выделить более или менее приоритетные критерии, так как несоблюдение хотя бы одного из них ставит под сомнение эффективность модели и возможность его дальнейшего использования.

Заключение

В данной статье были рассмотрены ключевые критерии эффективности для моделей теневого рейтинга. Мы выявили пять основных критериев, по которым можно сделать вывод о корректности модельной спецификации. Эти критерии основываются на ключевых этапах, которые проходит модель в рамках процесса разработки и внедрения в эксплуатацию. Полученная структура оценки эффективности SRA-моделей может быть использована для моделирования как профессионалами рынка, так и для проведения исследований в академической сфере.

Список использованной литературы

1. Гаврилов Ю.Э. Оценка влияния кредитного риска на финансовые результаты банковского сектора / Ю.Э. Гаврилов, Д.В. Гуринова. — EDN [DXNBFS](#) // Global and Regional Research. — 2020. — Т. 2, № 1. — С. 361–367.
2. Фаттахова Р.Х. Принципы управления риском банковской ликвидности на основе стандартов качества банковской деятельности / Р.Х. Фаттахова. — DOI 10.17150/2072-0904.2015.6(3).11. — EDN [TVWROB](#) // Известия Иркутской государственной экономической академии (Байкальский государственный университет экономики и права. — 2015. — Т. 6, № 3. — С. 11.
3. Грошев А.П. Оценка эффективности использования капитала банка с учетом принимаемых рисков / А.П. Грошев, В.С. Павлов. — DOI 10.17150/2411-6262.2016.7(4).8. — EDN [XDESYH](#) // Baikal Research Journal. — 2016. — Т. 7, № 4. — С. 8.
4. Erlenmaier U. The Shadow Rating Approach: Experience from Banking Practice / U. Erlenmaier // The Basel II Risk Parameters: Estimation, Validation, Stress Testing-with Applications to Loan Risk Management. — Berlin, Heidelberg : Springer Berlin Heidelberg, 2011. — P. 37–74.
5. Florez-Lopez R. Modelling Credit Risk with Scarce Default Data: On the Suitability of Cooperative Bootstrapped Strategies for Small Low-Default Portfolios / R. Florez-Lopez, J.M. Ramon-Jeronimo. — DOI 10.1057/jors.2013.119 // Journal of the Operational Research Society. — 2014. — Vol. 65. — P. 416–434.
6. Lopez J.A. Using CAMELS Ratings to Monitor Bank Conditions / J.A. Lopez // FRBSF Economic Letter. — 1999. — 11 June.
7. Karminsky A.M. Modelling Banks' Credit Ratings of International Agencies / A.M. Karminsky, E. Khromova. — DOI 10.1007/s40822-016-0058-5 // Eurasian Economic Review. — 2016. — Vol. 6. — P. 341–363.
8. Grunert J. The Role of Non-Financial Factors in Internal Credit Ratings / J. Grunert, L. Norden, M. Weber // Journal of Banking & Finance. — 2005. — Vol. 29, no. 2. — P. 509–531.
9. Packer F. Rating Methodologies for Banks / F. Packer, N.A. Tarashev // BIS Quarterly Review. — 2011. — June. — P. 39–52.
10. Eisl A. Re-Mapping Credit Ratings. / A. Eisl, H. Elendner, M. Lingo // SSRN. — URL: <https://eubub.uni-muenchen.de/22799/1/492.pdf>.
11. Карминский А.М. Сопоставление банковских рейтингов различных агентств / А.М. Карминский, В.В. Сосюрко. — EDN [OKXRUF](#) // Журнал Новой экономической ассоциации. — 2011. — Т. 12. — С. 102–123.
12. Живайкина А.Д. Кредитные рейтинги российских банков и отзывы банковских лицензий 2012–2016 гг. / А.Д. Живайкина, А.А. Пересецкий. — DOI 10.31737/2221-2264-2017-36-4-3. — EDN [YKWERV](#) // Журнал Новой экономической ассоциации. — 2017. — Т. 36, № 4. — С. 49–80.
13. Benmelech E. The Credit Rating Crisis / E. Benmelech, J. Dlugosz. — DOI 10.3386/w15045 // NBER macroeconomics annual. — 2009. — Vol. 24, no. 1. — P. 161–208.
14. Elliott R.J. A Double HMM Approach to Altman Z-Scores and Credit Ratings / R.J. Elliott, T.K. Siu, E.S. Fung. — DOI 10.1016/j.eswa.2013.08.052 // Expert Systems with Applications. — 2014. — Vol. 41, no. 4. — P. 1553–1560.
15. Bou-Hamad I. Bayesian Credit Ratings: A Random Forest Alternative Approach / I. Bou-Hamad. — DOI 10.1080/03610926.2016.1148730 // Communications in Statistics-Theory and Methods. — 2017. — Vol. 46, no. 15. — P. 7289–7300.
16. Chang Y.C. Application of eXtreme Gradient Boosting Trees in the Construction of Credit Risk Assessment Models for Financial Institutions / Y.C. Chang, K.H. Chang, G.J. Wu. — DOI 10.1016/j.asoc.2018.09.029 // Applied Soft Computing. — 2018. — Vol. 73. — P. 914–920.
17. Pacelli V. An Artificial Neural Network Approach for Credit Risk Management / V. Pacelli, M. Azzolini. — DOI 10.4236/jilsa.2011.32012 // Journal of Intelligent Learning Systems and Applications. — 2011. — Vol. 3, no. 2. — P. 103–112.
18. Hájek P. Credit Rating Modelling by Kernel-Based Approaches with Supervised and Semi-Supervised Learning / P. Hájek, V. Olej. — DOI 10.1007/s00521-010-0495-0 // Neural Computing and Applications. — 2011. — Vol. 20. — P. 761–773.

19. Credit Rating Analysis with Support Vector Machines and Neural Networks: A Market Comparative Study / Zan Huang, Hsiu-chin Chen, Chia-Jing Hsu, Wun Hwa Chen. — DOI 10.1016/S0167-9236(03)00086-1 // Decision support systems. — 2004. — Vol. 37, no. 4. — P. 543–558.
20. Hájek P. Municipal Credit Rating Modelling by Neural Networks / P. Hájek. — DOI 10.1016/j.dss.2010.11.033 // Decision Support Systems. — 2011. — Vol. 51, no. 1. — P. 108–118.
21. Lee Y.C. Application of Support Vector Machines to Corporate Credit Rating Prediction / Y.C. Lee. — DOI 10.1016/j.eswa.2006.04.018 // Expert Systems with Applications. — 2007. — Vol. 33, no. 1. — P. 67–74.
22. Пеникас Г.И. Моделирование микро- и макропруденциального регулирования кредитного риска в банках : дис. д-ра экон. наук : 08.00.13. / Г.И. Пеникас. — Санкт-Петербург, 2022. — 466 с.
23. Altman E.I. Credit Risk Measurement: Developments over the Last 20 Years / E.I. Altman, A. Saunders. — DOI 10.1016/S0378-4266(97)00036-8 // Journal of Banking & Finance. — 1997. — Vol. 21, no. 11-12. — P. 1721–1742.
24. Aronson J.R. Duplicating Moody's Municipal Credit Ratings / J.R. Aronson, J.R. Marsden // Public Finance Quarterly. — 1980. — Vol. 8, no. 1. — P. 97–106.
25. Hassan O.A.G. Accounting for the Determinants of Banks' Credit Ratings / O.A.G. Hassan, R. Barrell // Economics and Finance Working Paper, Brunel University. — 2013. — Vol. 13, no. 2. — URL: <http://bura.brunel.ac.uk/handle/2438/7428>.
26. Карминский А.М. Кредитные рейтинги и их моделирование / А.М. Карминский. — Москва : Изд-во ВШЭ, 2015. — 304 с.
27. Василюк А.А. Моделирование кредитных рейтингов отечественных банков на основе российской отчетности / А.А. Василюк, А.М. Карминский. — EDN [NXTSHJ](#) // Управление финансовыми рисками. — 2011. — № 3. — С. 194–205.
28. Овсейчик С.Е. Разработка подхода на внутренних рейтингах в отношении оценки кредитного риска в российской банковской практике / С.Е. Овсейчик. — EDN [ZCIUCH](#) // Мировая экономика: проблемы безопасности. — 2017. — № 3. — С. 96–101.
29. Чельшев Д.С. Моделирование вероятности дефолта российских банков / Д.С. Чельшев. — DOI 10.25683/VOLBI.2019.47.271. — EDN [WDPLSS](#) // Бизнес. Образование. Право. — 2019. — № 2 (47). — С. 262–266.
30. Karminsky A.M. Increase of banks' credit risks forecasting power by the usage of the set of alternative models / A.M. Karminsky, E. Khromova. — EDN [XSFOHJ](#) // Russian Journal of Economics. — 2018. — Vol. 4, no. 2. — P. 155–174.
31. Ang J.S. Bond Rating Methods: Comparison and Validation / J.S. Ang, K.A. Patel // The Journal of Finance. — 1975. — Vol. 30, no. 2. — P. 631–640.
32. Estran R. Using a Genetic Algorithm to Optimize an Expert Credit Rating Model / R. Estran, A. Souchaud, D. Abitbol. — DOI 10.1016/j.eswa.2022.117506 // Expert Systems with Applications. — 2022. — Vol. 203, no. 1. — P. 117506.

References

1. Gavrillov Yu.E., Gurinova D.V. Assessment of the Impact of Credit Risk on the Financial Results of the Banking Sector. *Global and Regional Research*, 2020, vol. 2, no. 1, pp. 361–367. (In Russian). EDN: [DXNBFS](#).
2. Fattakhova R.Kh. Principles of Risk Management for Bank Liquidity Based on Standards of Banking Activity Quality Banking. *Izvestiya Irkutskoy gosudarstvennoy ekonomicheskoy akademii (Baykalskiy gosudarstvennyy universitet ekonomiki i prava) = Izvestiya of Irkutsk State Economics Academy (Baikal State University of Economics and Law)*, 2015, vol. 6, no. 3, pp. 11. (In Russian). EDN: [TVWROB](#). DOI: 10.17150/2072-0904.2015.6(3).11.
3. Groshev A.R., Pavlov V.S. Assessing Efficiency of Using Bank Equity in Terms of Accepted Risk. *Baikal Research Journal*, 2016, vol. 7, no. 4, pp. 8. (In Russian). EDN: [XDESYH](#). DOI: 10.17150/2411-6262.2016.7(4).8.
4. Erlenmaier U. The Shadow Rating Approach: Experience from Banking Practice. *The Basel II Risk Parameters: Estimation, Validation, Stress Testing-with Applications to Loan Risk Management*. Berlin, Heidelberg, Springer Berlin Heidelberg, 2011, pp. 37–74.

5. Florez-Lopez R., Ramon-Jeronimo J. M. Modelling Credit Risk with Scarce Default Data: on the Suitability of Cooperative Bootstrapped Strategies for Small low-default Portfolios. *Journal of the Operational Research Society*, 2014, vol. 65, pp. 416–434. DOI:10.1057/jors.2013.119.
6. Lopez J.A. Using CAMELS ratings to monitor bank conditions. *FRBSF Economic Letter*, 1999, June 11.
7. Karminsky A.M., Khromova E. Modelling Banks' Credit Ratings of International Agencies. *Eurasian Economic Review*, 2016, vol. 6, pp. 341–363. DOI: 10.1007/s40822-016-0058-5.
8. Grunert J., Norden L., Weber M. The Role of Non-financial Factors in Internal Credit Ratings. *Journal of Banking & Finance*, 2005, vol. 29, no. 2, pp. 509–531.
9. Packer F., Tarashev N.A. Rating Methodologies for Banks. *BIS Quarterly Review*, 2011, June, pp. 39–52.
10. Eisl A., Elendner H., Lingo M. Re-Mapping Credit Ratings. SSRN. Available at: <https://pub.ub.uni-muenchen.de/22799/1/492.pdf>.
11. Karminsky A.M., Sosyurko V.V. Comparison of Bank Credit Ratings for Various Agencies. *Zhurnal Novoi ekonomicheskoi assotsiatsii = Journal of the New Economic Association*, 2011, vol. 12, pp. 102–123. (In Russian). EDN: [OKXRUF](#).
12. Zhivaikina A.D., Peresetsky A.A. Russian Bank Credit Ratings and Bank License Withdrawals 2012–2016. *Zhurnal Novoi ekonomicheskoi assotsiatsii = Journal of the New Economic Association*, 2017, vol. 36, no. 4, pp. 49–80. (In Russian). EDN: [YKWERV](#). DOI: 10.31737/2221-2264-2017-36-4-3.
13. Benmelech E., Dlugosz J. The Credit Rating Crisis. *NBER Macroeconomics Annual*, 2009, vol. 24, no. 1, pp. 161–208. DOI: 10.3386/w15045.
14. Elliott R.J., Siu T.K., Fung E.S. A Double HMM Approach to Altman Z-scores and Credit Ratings. *Expert Systems with Applications*, 2014, vol. 41, no. 4, pp. 1553–1560. DOI:10.1016/j.eswa.2013.08.052.
15. Bou-Hamad I. Bayesian Credit Ratings: A Random Forest Alternative Approach. *Communications in Statistics-Theory and Methods*, 2017, vol. 46, № 15, pp. 7289–no.7300. DOI: 10.1080/03610926.2016.1148730
16. Chang Y.C., Chang K.H., Wu G.J. Application of eXtreme Gradient Boosting Trees in the Construction of Credit Risk Assessment Models for Financial Institutions. *Applied Soft Computing*, 2018, vol. 73, pp. 914–920. DOI:10.1016/j.asoc.2018.09.029.
17. Pacelli V., Azzollini M. An Artificial Neural Network Approach for Credit Risk Management. *Journal of Intelligent Learning Systems and Applications*, 2011, vol. 3, no. 2, pp. 103–112. DOI:10.4236/jilsa.2011.32012.
18. Hójek P., Olej V. Credit Rating Modelling by Kernel-based Approaches with Supervised and Semi-supervised Learning. *Neural Computing and Applications*, 2011, vol. 20, pp. 761–773. DOI: 10.1007/s00521-010-0495-0.
19. Zan Huang, Hsiu-chin Chen, Chia-Jing Hsu, Wun Hwa Chen. Credit Rating Analysis with Support Vector Machines and Neural Networks: a Market Comparative Study. *Decision support systems*, 2004, vol. 37, no. 4, pp. 543–558. DOI: 10.1016/S0167-9236(03)00086-1.
20. Hójek P. Municipal Credit Rating Modelling by Neural Networks. *Decision Support Systems*, 2011, vol. 51, no. 1, pp. 108–118. DOI: 10.1016/j.dss.2010.11.033.
21. Lee Y.C. Application of Support Vector Machines to Corporate Credit Rating Prediction. *Expert Systems with Applications*, 2007, vol. 33, no. 1, pp. 67–74. DOI: 10.1016/j.eswa.2006.04.018.
22. Penikas G.I. *Modeling of Micro- and Macroprudential Regulation of Credit Risk in Banks*. Doc. Diss. Sankt-Peterburg, 2022. 466 p.
23. Altman E.I., Saunders A. Credit Risk Measurement: Developments over the Last 20 Years. *Journal of banking & finance*, 1997, vol. 21, no. 11–12, pp. 1721–1742. DOI: 10.1016/S0378-4266(97)00036-8.
24. Aronson J.R., Marsden J.R. Duplicating Moody's Municipal Credit Ratings. *Public Finance Quarterly*, 1980, vol. 8, no. 1, pp. 97–106.
25. Hassan O.A.G., Barrell R. Accounting for the Determinants of Banks' Credit Ratings. *Economics and Finance Working Paper, Brunel University*, 2013, vol. 13, no. 2. Available at: <http://bura.brunel.ac.uk/handle/2438/7428>.
26. Karminsky A.M. *Credit Ratings and Their Modeling*. Moscow, Higher School of Economics Publ., 2015. 304 p.

27. Vasilyuk A.A., Karminsky A.A. Modeling Credit Ratings of Domestic Banks Based on Russian Accounting Standards. *Upravlenie finansovimi riskami (Financial risk management)*, 2011, no. 3, pp. 194–205. (In Russian). EDN: [NXTSHJ](#).

28. Ovseychik S.E. Development of Internal-ratings Based Approach Towards Estimation of Credit Risk in Russian Banking Practice. *Mirovaya ekonomika: problemy bezopasnosti = World Economy: Security Issues*, 2017, no. 3, pp. 96–101. (In Russian). EDN: [ZCIUCH](#).

29. Chelyshev D.S. Modeling of Russian Bank's Probability of Default. *Biznes. Obrazovanie. Pravo = Business. Education. Right*, 2019, no. 2, pp. 262–266. (In Russian). EDN: [WDPLSS](#). DOI: 10.25683/VOLBI.2019.47.271.

30. Karminsky A.M., Khromova E. Increase of Banks' Credit Risks Forecasting Power by the Usage of the Set of Alternative Models. *Russian Journal of Economics*, 2018, vol. 4, no. 2, pp. 155–174. EDN: [XSFOHJ](#).

31. Ang J.S., Patel K.A. Bond Rating Methods: Comparison and Validation. *The Journal of Finance*, 1975, vol. 30, no. 2, pp. 631–640.

32. Estran R., Souchaud A., Abitbol D. Using a Genetic Algorithm to Optimize an Expert Credit Rating Model. *Expert Systems with Applications*, 2022, vol. 203, no. 1, pp. 117506. DOI: 10.1016/j.eswa.2022.117506.

Информация об авторах

Казаринов Виктор Александрович — старший консультант, АО «Технологии Доверия», г. Москва, Российская Федерация, vakazarinov@outlook.com,  <https://orcid.org/0009-0002-0998-4205>, SPIN-код: 7777-0026, AuthorID РИНЦ: 1198492.

Звягинцева Наталья Александровна — доктор экономического наук, доцент, профессор кафедры финансов и финансовых институтов, Байкальский государственный университет, г. Иркутск, Российская Федерация, legnata2010@yandex.ru,  <https://orcid.org/0000-0003-0249-852X>, SPIN-код: 1123-5244, AuthorID РИНЦ: 326257.

Authors

Viktor A. Kazarinov — Senior Consultant, JSC “Technologies of Trust”, Moscow, Russian Federation, vakazarinov@outlook.com,  <https://orcid.org/0009-0002-0998-4205>, SPIN-Code: 7777-0026, AuthorID RSCI: 1198492.

Natalia A. Zvyagintseva — D.Sc. in Economics, Associate Professor, Professor of the Department of Finance and Financial Institutions, Baikal State University, Irkutsk, Russian Federation, legnata2010@yandex.ru,  <https://orcid.org/0000-0003-0249-852X>, SPIN-Code: 1123-5244, AuthorID RSCI: 326257.

Вклад авторов

Все авторы сделали эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.

Contribution of the Authors

The authors contributed equally to this article. The authors declare no conflicts of interests.

Для цитирования

Казаринов В.А. Критерии эффективности моделей теневых рейтингов при оценке кредитоспособности низкодефолтных заемщиков / В.А. Казаринов, Н.А. Звягинцева. — DOI 10.17150/2411-6262.2023.14(3).822-834. — EDN [BEVWNH](#) // Baikal Research Journal. — 2023. — Т. 14, № 3. — С. 822–834.

For Citation

Kazarinov V.A., Zvyagintseva N.A. Criteria for the Effectiveness of Shadow Rating Models in Assessing the Creditworthiness of Low-Default Borrowers. *Baikal Research Journal*, 2023, vol. 14, no. 3, pp. 822–834. (In Russian). EDN: [BEVWNH](#). DOI: 10.17150/2411-6262.2023.14(3).822-834.