

ОЦЕНКА КРЕДИТОСПОСОБНОСТИ СУБЪЕКТОВ МАЛОГО ПРЕДПРИНИМАТЕЛЬСТВА***Игорь Владимирович АРИНИЧЕВ^{а*}, Наталья Юрьевна САЙБЕЛЬ^б**

^а кандидат экономических наук, доцент кафедры теоретической экономики, Кубанский государственный университет, Краснодар, Российская Федерация
iarinichev@gmail.com

^б кандидат экономических наук, доцент кафедры теоретической экономики, Кубанский государственный университет, Краснодар, Российская Федерация
saybel-natali@yandex.ru

* Ответственный автор

История статьи:

Получена 14.07.2017

Получена в доработанном виде 28.07.2017

Одобрена 11.08.2017

Доступна онлайн 29.08.2017

УДК 336.63

JEL: C44, C51, C52, L25, L26

Ключевые слова:

кредитоспособность, малое предпринимательство, скоринг, риск, машинное обучение

Аннотация

Предмет. Проблемой оценки кредитоспособности субъектов малого предпринимательства является отсутствие единой, учитывающей их специфику, методики. Необходимо разработать комплексный подход к оценке кредитоспособности, который базировался бы на показателях, характеризующих деятельность субъектов малого предпринимательства со всех сторон.

Цели. Разработка алгоритма оценки и построение логической модели кредитоспособности субъектов малого предпринимательства, учитывающей все аспекты их деятельности и низкую степень финансовой устойчивости.

Методология. Используются методы сравнения и аналогии.

Результаты. Созданная методика оценки кредитоспособности субъектов малого предпринимательства основана на методологии машинного обучения, что делает ее полной. Суть состоит в нахождении и анализе показателей, всесторонне характеризующих деятельность субъектов малого предпринимательства. Данная методика дает возможность классифицировать субъекты бизнеса по типам риска в целях их минимизации, а также оставить самые изменчивые показатели оценки кредитоспособности. Предлагаемая систематизация позволит быстрее и эффективнее оценить кредитоспособность субъектов малого предпринимательства.

Выводы. Существующие методики оценки кредитоспособности субъектов малого предпринимательства в основном направлены на анализ их финансового положения. Для того чтобы методика оценки кредитоспособности была наиболее достоверной, необходимо не только учитывать показатели, характеризующие финансовую деятельность предприятия, но и принимать во внимание деловую репутацию малого предприятия, эффективность использования основных ресурсов, уровень конкурентоспособности и положение на рынке. Все это позволит получить полное представление о деятельности субъектов малого предпринимательства.

© Издательский дом ФИНАНСЫ и КРЕДИТ, 2017

Для цитирования: Ариничев И.В., Сайбель Н.Ю. Оценка кредитоспособности субъектов малого предпринимательства // Финансы и кредит. – 2017. – Т. 23, № 31. – С. 1878 – 1892.
<https://doi.org/10.24891/fin.23.31.1878>

Актуальность данной темы состоит в том, что в настоящее время отсутствуют методики комплексной оценки кредитоспособности субъектов малого предпринимательства. В основном существующие методики делятся

на две группы: оценка кредитоспособности крупных предприятий и физических лиц. В большинстве случаев предлагаемые методики оценки кредитоспособности субъектов малого предпринимательства основываются на анализе статистической информации, которая в силу специфики данного сектора экономики в требуемом объеме отсутствует. Предлагаемая в статье модель оценки

* Авторы выражают благодарность и глубокую признательность доктору экономических наук, профессору, заведующему кафедрой теоретической экономики Кубанского государственного университета Виктору Александровичу СИДОРОВУ за советы при работе над статьей.

кредитоспособности, использующая методологию машинного обучения, позволит анализировать не только количественные, но и качественные показатели, характеризующие деятельность субъектов малого предпринимательства. В результате станет возможным полноценный и корректный анализ их кредитоспособности.

Как известно, условно методы оценки кредитоспособности можно разделить на две группы: экспертные и скоринговые. Традиционно большинство финансовых институтов полагалось на субъективное суждение для оценки кредитного риска корпоративного заемщика. По сути, эксперты использовали информацию о различных характеристиках заемщика, таких как репутация, капитал (кредитное плечо), волатильность прибыли, условия (цель кредита) и залог – при принятии решения о том, предоставлять ли кредит данной организации. В мировой финансовой системе названная методика экспертных оценок получила название «кредит пяти си» или «FiveCsOfCredit» (character, capacity, capital, collateral and conditions). Одним из ограничений экспертных оценок является сложность принятия компромиссного решения между сильными и слабыми сторонами заемщика, когда неудовлетворительный уровень одного показателя смягчается силой какого-либо другого. У фирмы, например, может быть низкий коэффициент рентабельности, но выше среднего – коэффициент ликвидности. Кроме того, внедрение и разработка экспертных систем такого типа требует от банков существенных временных и денежных затрат. Именно поэтому финансовые институты время от времени пытаются клонировать процесс принятия решений, внедряя в свою деятельность скоринговые системы.

Основу скоринговых систем составляют строгие статистические методы и модели, позволяющие на основе многофакторного анализа разделить потенциальных заемщиков на несколько непересекающихся групп, начиная с «плохих», имеющих высокую

вероятность дефолта по финансовому обязательству, до «хороших» кредитных групп, состоящих из компаний, которые с большей вероятностью погасят задолженность в течение установленного срока. В последние десятилетия для оценки кредитоспособности компаний был разработан ряд отечественных и зарубежных скоринговых систем, использующих самые разнообразные методы. Рассмотрим некоторые классы моделей и методов, получивших широкое распространение в нашей стране и за рубежом.

Модели линейного дискриминантного/регрессионного анализа, связывающие результирующую переменную (платежеспособность клиента, число скоринговых баллов) с рядом независимых факторов (квартальная прибыль, отношение собственного капитала к заемному и др.) (E. Altman [1], W. Beaver [2], D. Chesser [3], M. Dimitriu, I. Oprea [4]). Полученные в результате оценивания параметры (веса) определяют характер линейной зависимости. Логистическая регрессия, разработанная Д. Коксом [5], одна из наиболее часто используемых при оценке кредитных рисков статистических моделей, рассматривается как частный случай линейной регрессии и имеет в отличие от нее дискретный результат (S. Bhatia et al. [6], D. Hosmer [7], E. Mortazavi, M. Ahmadzadeh [8], А.С. Сорокин [9], В.А. Яцко [10]). В моделях, базирующихся на теории нечетких множеств, в основу скоринговой системы ложится процедура нечеткого вывода, включающая в себя ряд этапов. При этом исходные факторы и результирующий признак задаются с помощью функций принадлежности и связываются между собой полной системой логических правил (A. Bazmara, S. Donighi [11], F. Hoffmann et al. [12], R. Malhotra D. Malhotra [13], H. Nosratabadi et al. [14], S. Sampath, V. Kalaichelvi [15]). Нейронные сети для скоринговых моделей представляют собой множество нейронов, сгруппированных в слои. Входящий уровень сети состоит из всех характеристик, используемых для предсказания кредитоспособности, а

исходящий уровень представляет собой ожидаемый результат (платежеспособность клиента) (К.К. Lai et al. [16], T.S. Lee [17], R. Malhotra, D. Malhotra [18], V. Pacelli M. Azzollini [19], D. West [20]). Авторский анализ скоринговых систем показал, что большинство из перечисленных исследований были проведены в глобальном масштабе и сосредоточены на крупных многонациональных компаниях, акции которых котируются на фондовых рынках, что не учитывает специфику малого бизнеса.

В настоящем исследовании предлагается архитектура оценки кредитоспособности малого предприятия, использующая методологию машинного обучения, относящуюся к системам интеллектуального анализа данных. На основе применения исторических данных о финансовых и деловых показателях деятельности малых предприятий, а также данных балансов в работе строится логический классификатор в виде дерева решений, относящий каждую компанию к одной из трех групп риска. Общая схема процесса машинного обучения, а также формализация постановки задачи описана далее.

Объектом x из множества всех объектов X в данной задаче будем считать юридическое лицо (малое предприятие), подавшее заявку на кредит. Чтобы задать объект, введем его признаковое описание $f_i: x_i \rightarrow D_j$, где $f_i(x_i)$ – значение j -го частного критерия для i -го предприятия x , $i = \overline{1, m}$, $j = \overline{1, n}$. Например, в качестве группы признаков могут быть выбраны показатели, характеризующие бизнес-риски предприятия (срок функционирования бизнеса, зависимость от поставщиков и потребителей, наличие судебных разбирательств, конкурентная позиция заемщика на рынке и др.); другая группа содержит факторы, характеризующие финансовые риски (денежное покрытие, ликвидность, обеспеченность собственным капиталом и др.); третья группа признаков может отвечать за анализ рисков кредитной истории и т.д. Тогда вектор $(f_1(x_i), f_2(x_i), \dots, f_n(x_i))$

задает полное признаковое описание объекта. Для удобства восприятия может быть записана матрица «объекты-признаки»:

$$\begin{pmatrix} f_1(x_1) & \dots & f_1(x_m) \\ \dots & \dots & \dots \\ f_n(x_1) & \dots & f_n(x_m) \end{pmatrix}.$$

Ее столбцы содержат признаковое описание j -го объекта (малого предприятия). В зависимости от того, в какой шкале измеряется тот или иной признак (интервальная, порядковая, номинальная), множество D_j может быть конечным или бесконечным, с отношением порядка или нет. К примеру, если f_j – среднесписочная численность сотрудников в организации, то соответствующее множество является конечным и упорядоченным $D_j = \{1, 2, 3, \dots, 100\}$. Для показателя, характеризующего долю рынка, логично в качестве D_j рассмотреть отрезок $[0; 100]$.

Для определения зависимой переменной разделим заемщиков на три класса, которые условно назовем: «плохие», «удовлетворительные» и «хорошие». Присвоив каждому классу метку, получим множество всевозможных ответов для каждого предприятия соответственно $Y = \{-1; 0; 1\}$. Для банкротов и безнадежных кредитов критерий определения «плохого» заемщика однозначен. В отношении остальных заемщиков банка критерием определения «плохого предприятия» является, как правило, количество дней просрочки платежа по кредитам. К группе «неопределенных» клиентов могут относиться клиенты с недостаточной кредитной историей, имеющие небольшую допустимую просрочку платежа и др.

Предложенная номинальная шкала для зависимой переменной не освобождена от критики и выбрана нами для конкретизации проводимого исследования. В общем случае она может быть определена произвольно. Например, задавая Y как множество натуральных чисел, мы фактически получаем скоринговую карту общего вида.

Чтобы успешно обучить и реализовать алгоритм оценки кредитоспособности произвольно выбранного малого предприятия, рассматриваются два этапа [21].

Первый этап обучения, на котором по обучающей выборке X^l (выборка признаков объектов для которых заранее известны ответы Y^l) на основе некоторого метода μ строится алгоритм классификации $a = \mu(X^l \cdot Y^l)$.

На втором этапе тестирования построенный на первом этапе алгоритм a классифицирует объекты, не вошедшие в обучающую выборку.

Если при этом алгоритм a демонстрирует допустимую ошибку (менее 15%), то он может использоваться в дальнейшем для диагностики кредитоспособности произвольного малого предприятия. В противном случае производится переобучение алгоритма путем подбора для него новых параметров. Чтобы измерить точность ответа алгоритма на одном отдельном объекте, рассматривается функция потерь:

$$L(a, x) = \begin{cases} 1, & a(x) \neq y(x), \\ 0, & a(x) = y(x) \end{cases}$$

Она равна 0, если алгоритм верно проклассифицировал объект, и 1 – в противном случае. Тогда величина ошибки в задаче классификации определяется при помощи функционала качества:

$$Q(a, X^{test}) = \frac{1}{|X^{test}|} \sum_i L(a, x_i),$$

где X^{test} – тестовая выборка.

С учетом специфики задачи и качественного характера некоторых признаков (деловые факторы) был выбран логический алгоритм классификации кредитоспособности малых предприятий, который представляет собой бинарное дерево (ациклический граф), каждой внутренней вершине $v \in V_{\text{внутр}}$ которого приписан предикат $\beta_v: X \rightarrow \{0, 1\}$, а каждой листовой (терминальной) вершине $v \in V_{\text{лист}}$ – метка класса $c_v \in Y$. В настоящей работе

были использованы одномерные предикаты вида $\beta_v(X) = \{x_j \leq \theta_j\}$, где θ_j – некоторое пороговое значение j -го признака объекта.

Бинарный решающий алгоритм стартует из корневой вершины v_0 и вычисляет значение предиката β_{v_0} . Если оно равно нулю, то алгоритм переходит в левую дочернюю вершину, иначе – в правую, вычисляет значение предиката в новой вершине и делает переход или влево, или вправо. Процесс продолжается, пока не будет достигнута листовая вершина; алгоритм возвращает тот класс, который приписан этой вершине («плохие», «удовлетворительные» и «хорошие»).

В настоящей работе при построении решающего дерева была использована рекурсивная процедура Induction of Decision 3 (LearnID3), псевдокод которой представлен на рис. 1.

Наиболее важным шагом рассмотренного алгоритма является поиск предиката с максимальной информативностью. При определении предиката, который максимально хорошо отделял бы какую-то группу классов от всех остальных в зависимости от выбора критерия ветвления, возникает большое разнообразие методов построения решающих деревьев.

В данной работе был использован наиболее распространенный и часто используемый критерий Джини, показывающий, сколько пар объектов, лежащих в одном и том же классе, одновременно попадут либо в левую, либо в правую дочернюю вершину дерева (значения предиката на них совпадают):

$$I(\beta, X^l) = \# \{(x_i, x_j) : y_i \neq y_j, \beta(x_i) = \beta(x_j)\}.$$

После того как дерево построено, в целях упрощения его структуры и понижения сложности восприятия результатов моделирования можно провести его «стрижку». Существует ряд исследований, показывающих, что «стрижка» позволяет достичь лучшего качества по сравнению с ранним останом построения дерева на

основе различных критериев. Тем не менее на данный момент методы «стрижки» редко используются и не реализованы в большинстве библиотек для анализа данных [21]. Другим подходом к оптимизации дерева является сокращение размерности исходной задачи.

Чтобы понизить размерность задачи и сохранить при этом максимум информации в меньшем количестве переменных, может быть использован метод главных компонент, широко применяющийся в анализе данных [22]. Суть анализа главных компонент заключается в том, что все признаки-колонки преобразуются в компоненты, причем наибольшую информацию о разнообразии объектов несет первая компонента, вторая несет меньше информации, третья – еще меньше и т.д. Данный метод позволяет уменьшить количество признаков, выбрать самые изменчивые.

По своей математической сути данный метод представляет собой линейную замену переменных или переход из n -мерного пространства признаков $(f_1(x_i), f_2(x_i), \dots, f_n(x_i))$ в k -мерное пространство главных компонент $(g_1(x_i), g_2(x_i), \dots, g_k(x_i))$, где $k \leq n$:

$$\begin{aligned} g_1(x) &= v_{11} f_1(x) + v_{21} f_2(x) + \dots + v_{n1} f_n(x), \\ g_2(x) &= v_{12} f_1(x) + v_{22} f_2(x) + \dots + v_{n2} f_n(x), \\ &\dots \\ g_k(x) &= v_{1k} f_1(x) + v_{2k} f_2(x) + \dots + v_{nk} f_n(x). \end{aligned}$$

Веса v_{ij} подбираются так, чтобы выборочная дисперсия новой главной компоненты на каждом шаге была максимально возможной и выборочные корреляции $r(g_i(x), g_j(x)) = 0, i \neq j$. Известно, что если значения исходных признаков центрированы, то $g_j(x) = X^T \cdot v_j, |v_j|^2 = \lambda_j$, где v_j – собственные векторы, соответствующие собственным значениям λ_j матрицы $(X^T)^T X^T$, упорядоченным по убыванию $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \geq 0$.

Если данные, лежащие в матрице X^T , действительно укладываются в пространстве меньшей размерности, то для определения

эффективной размерности выборки используют следующее правило: оптимальное значение новой выборки – это наименьшее целое k , при котором

$$\frac{\lambda_{k+1} + \lambda_{k+2} + \dots + \lambda_n}{\lambda_1 + \lambda_2 + \dots + \lambda_n} > 0,5.$$

Указанное соотношение позволяет принять решение о том, какое количество последних главных компонент должно быть исключено из выборки без последствий, тем самым редуцируется размерность анализируемого пространства.

С учетом сказанного последовательность оценки кредитоспособности малых предприятий укладывается в схему, представленную на *рис. 2*.

Для реализации рассмотренной методики оценки кредитоспособности (*рис. 2*) было рассмотрено более 100 кредитных заявок от малых предприятий, по каждому из которых зафиксированы значения по 24 признакам (*табл. 1*).

С учетом того что разные признаки имеют разные единицы измерения, все они должны быть предварительно стандартизованы, например, по формуле:

$$f_j^*(x_i) = \frac{f_j(x_i) - \overline{f_j(x_i)}}{sd(f_j(x_i))},$$

где $sd(f_j(x_i))$ – стандартное отклонение j -го признака $j = \overline{1, n}, i = \overline{1, m}$.

Применение процедуры стандартизации переменных необходимо перед использованием метода главных компонент, так как в противном случае будут выбраны не наиболее информативные признаки и их комбинации, а признаки с максимальными размахами, которые в свою очередь определяются, в том числе, единицами измерения. Так, незначительное колебание прибыли, выраженной в рублях, перекроет существенный разброс доли рынка, выраженный в процентах.

Для автоматизации процесса редукции метод главных компонент был реализован с

помощью встроенной функции `prcomp` (principal component) в среде статистических вычислений *R*. В выводах данного метода содержатся как сами значения главных компонент PC_j , так и веса v_{ij} , через которые новые, синтетические переменные выражаются через исходные признаки $f_j(x)$. В *табл. 2* приведены результаты (первые шесть компонент) применения метода в среде *R*, откуда видно, что первая главная компонента PC_1 объясняет 54% дисперсии совокупного исходного набора данных (Cumulative Proportion), первая и вторая главные компоненты PC_1 , PC_2 улавливают 73% дисперсии в вариации рассматриваемой выборки. Первые четыре главные компоненты «ловят» 93% разброса исходных данных. Таким образом, в нескольких первых главных компонентах содержится практически вся информация, что и в 24 исходных признаках.

С учетом результатов применения метода главных компонент (*табл. 2*) и правила определения эффективного размера выборки (2), новая размерность признакового пространства составила $k = 4$. После применения к новому набору данных рекурсивной процедуры *ID3* было получено бинарное решающее дерево (*рис. 3*). Если двигаться из его начальной вершины в зависимости от значений главных компонент, любой объект (предприятие) можно отнести к одному из трех классов кредитоспособности.

Значение функционала качества, полученное с помощью (1) для построенного алгоритма по тестовой выборке, показало допустимые значения ошибки (<15%), что дает основание

использовать его в качестве инструмента поддержки и принятия решений при предоставлении кредита либо при отказе субъектам малого предпринимательства.

Предложенная в настоящей работе методология моделирования кредитного риска малых предприятий включает в себя комплексную оценку характеристик заемщика и объекта, к которому он стремится получить доступ; дифференциацию уровней риска; сокращение размерности пространства признаков объектов с помощью метода главных компонент; разработку логического алгоритма классификации малых предприятий по уровням кредитоспособности. При этом логический алгоритм обеспечивает разумную точность и согласованность во времени количественных оценок кредитного риска, что подтверждается достаточно низким значением функции потерь на тестовых выборках.

Таким образом, способность методов машинного обучения, в частности логических алгоритмов, позволяет значительно улучшить аналитические возможности в области оценки и управления кредитоспособностью субъектов малого предпринимательства, предлагает высокую степень детализации и глубину интеллектуального анализа. В то же время использование методов машинного обучения в секторе финансовых услуг значительно зависит от доступности и качества исходных данных, так как прогнозная сила некоторых методов сильно зависит от объема и размерности исходной выборки. Частично проблема решается путем сокращения редукции задачи методом главных компонент.

Таблица 1

Факторы кредитоспособности малых предприятий

Table 1

Factors of small businesses' creditworthiness

Группа факторов	Порядковый номер	Наименование	Комментарий
Деловые риски	1	Business_period	Срок функционирования бизнеса – период в годах от начала регистрации компании до 2017 г.
	2	Legalization	Позиция на рынке, кредитная история, качество работы, степень легализации бизнеса
	3	Management quality	Компетентность, уровень образования, сплоченность руководства и его эффективность
	4	Credit security	Залог, гарантии, поручительства, страхование, условия погашения кредита
	5	Market share	Доля рынка – доля компании на рынке
	6	Supplier_dependence	Зависимость от поставщиков – наличие крупнейшего поставщика (>30%)
	7	Customer_dependence	Зависимость от покупателей – наличие крупнейшего покупателя (>30%)
Финансовые риски	8	Net_assets	ВБ – долгосрочные и краткосрочные заемные средства + доходы будущих периодов
	9	Current_liquidity	Оборотные активы / Краткосрочные пассивы
	10	Financial_autonomy	Собственный капитал / Суммарный пассив (ВБ)
	11	Equity_to_debt_relation	Собственный капитал / Суммарные обязательства
	12	Sales_profitability	Прибыль от реализации / Выручка от реализации
	13	Activity_profitability	Чистая прибыль за последний отчетный квартал / Выручка от продажи товаров, продукции, работ, услуг за последний отчетный квартал
	14	Cash_cover	Размер кредитных обязательств на текущую дату / Среднемесячная выручка
	15	Interest_cover	Квартальная прибыль от продаж за последний отчетный квартал / Сумма процентов по кредитам и займам, уплаченная за последний отчетный квартал
Активы баланса	16	Fixed_assets	Внеоборотные активы – труднореализуемые активы (А4)
	17	Stock	Запасы – медленно реализуемые активы (А3)
	18	Receivables	Дебиторская задолженность – быстро реализуемые активы (А2)
	19	Short-term_investments	Краткосрочные финансовые вложения – наиболее ликвидные активы (А1)
	20	Cash	Денежные средства – наиболее ликвидные активы (А1)
Пассивы баланса	21	Equity	Собственный капитал – постоянные пассивы (П4)
	22	Long-term_borrowings	Долгосрочные кредиты и займы – долгосрочные пассивы (П3)
	23	Short-term_borrowings	Краткосрочные кредиты и займы – краткосрочные пассивы (П2)
	24	Payables	Кредиторская задолженность – наиболее срочные обязательства (П1)

Источник: составлено авторами

Source: Authoring

Таблица 2

Выводы метода главных компонент в среде статистических вычислений R

Table 2

Conclusions from output of a principal component analysis in Environment for Statistical Computing R

Показатель	PC1	PC2	PC3	PC4	PC5	PC6
Стандартное отклонение	5,432	4,622	2,074	1,521	0,725	0,612
Доля дисперсии	0,5421	0,1896	0,1217	0,0808	0,0442	0,0077
Накопленная доля дисперсии	0,5421	0,7317	0,8534	0,9342	0,9784	0,9861

Примечание. PC – главная компонента.

Источник: составлено авторами

Note. PC – principal component.

Source: Authoring

Рисунок 1

Рекурсивная процедура построения бинарного решающего дерева

Figure 1

Recursive procedure for constructing a binary decision tree

1.	ПРОЦЕДУРА $LearnID3(S \subseteq X^I)$	
2.	ЕСЛИ $\forall s \in S \Rightarrow y_s = c \in Y$	Если все объекты подвыборки лежат в одном классе
3.	ВЕРНУТЬ $v, c_v = c$	Вернуть новую листовую вершину и присвоить ей метку класса
4.	$\beta = \arg \max_{\beta} I(\beta, S)$	Найти предикат с максимальной информативностью
5.	$S_0 = \{x \in S : \beta(x) = 0\}$ $S_1 = \{x \in S : \beta(x) = 1\}$	Разбить выборку на две подвыборки $S = S_0 \cup S_1$ по предикату максимальной информативности β
6.	ЕСЛИ $S_0 = \emptyset$ ИЛИ $S_1 = \emptyset$	Если разбиения не произошло
7.	ВЕРНУТЬ $v, c_v = c$	Вернуть новую листовую вершину, присвоить метку того класса, объектов которого больше в подвыборке
8.	$v: \beta_v = \beta$ $L_v = LearnID3(S_0)$ $R_v = LearnID3(S_1)$	Создать новую внутреннюю вершину и поместить в нее предикат Построить левое поддерево Построить правое поддерево
9.	ВЕРНУТЬ $v;$	Вернуть решающее дерево

Источник: Воронцов К.В. Математические методы обучения машин по прецедентам (теория обучения машин). URL: <http://www.machinelearning.ru/wiki/images/6/6d/Voron-ML-1.pdf>

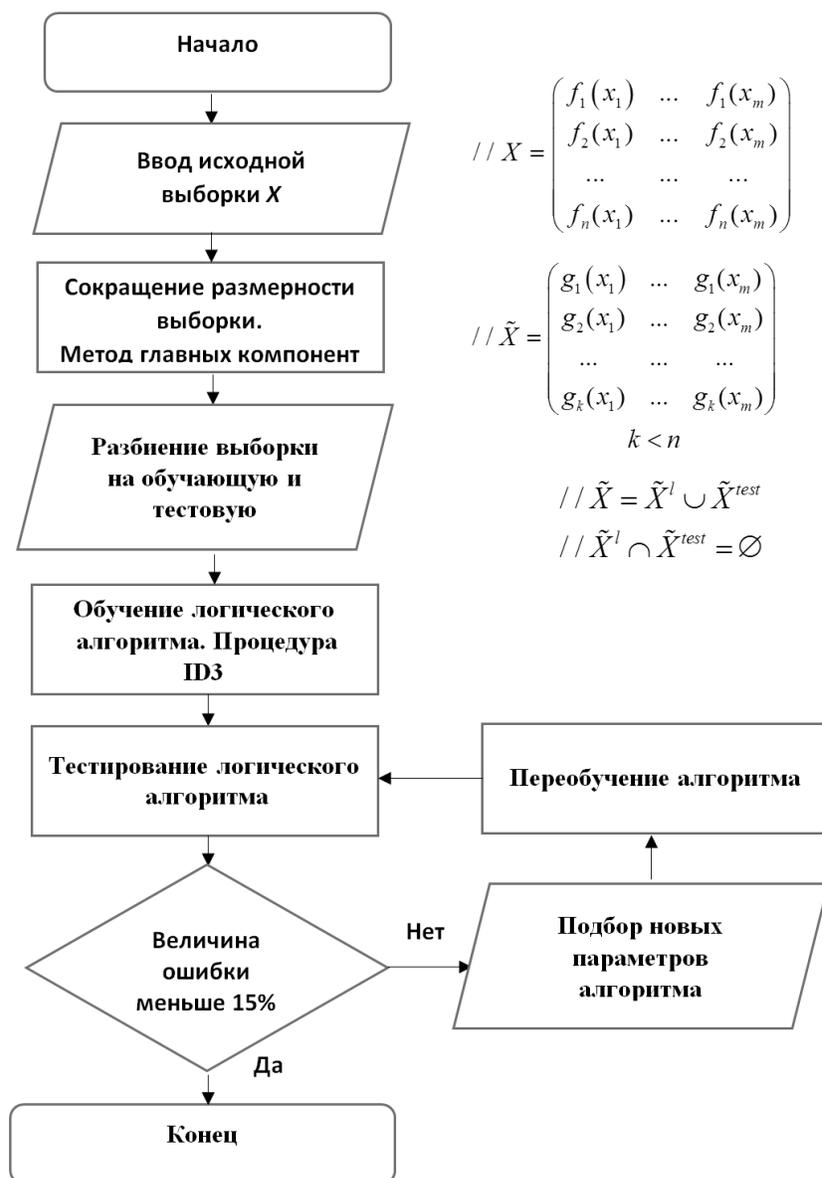
Source: Vorontsov K.V. *Matematicheskie metody obucheniya mashin po pretsedentam (teoriya obucheniya mashin)* [Mathematical methods of case-based machine learning (machine learning theory)]. URL: <http://www.machinelearning.ru/wiki/images/6/6d/Voron-ML-1.pdf> (In Russ.)

Рисунок 2

Методика разработки алгоритма оценки кредитоспособности малых предприятий

Figure 2

A methodology for developing an algorithm to evaluate the creditworthiness of small businesses



Источник: составлено авторами

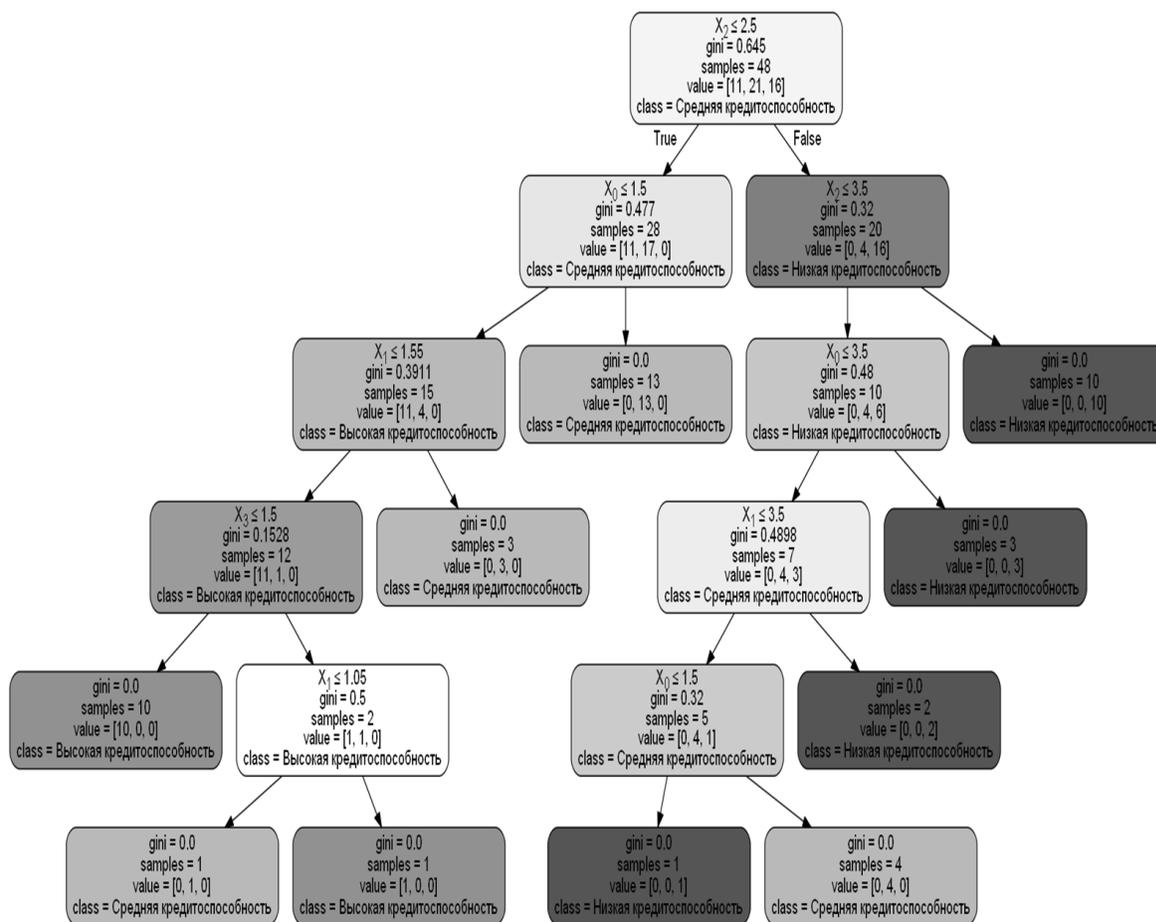
Source: Authoring

Рисунок 3

Логический алгоритм классификации малых предприятий по уровням риска кредитоспособности

Figure 3

Logical algorithm to classify small businesses by solvency risk level



Источник: составлено авторами (результаты моделирования в среде Питон)

Source: Authoring (modeling results in Python)

Список литературы

1. *Altman E.* Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *Journal of Finance*, 1968, vol. 23, no. 4, pp. 589–609.
2. *Beaver W.H.* Financial ratios as predictors of failure. *Journal of Accounting Research*, 1966, vol. 4, pp. 71–111.
3. *Chesser D.* Predicting loan noncompliance. *The Journal of Commercial Bank Lending*, 1974, pp. 28–38.
4. *Dimitriu M., Oprea I.A.* Modeling Credit Scoring. *Metalurgia International*, 2010, no. 5, Special Issue, pp. 62–67.
5. *Cox D.R., Snell E.J.* Analysis of Binary Data. London, Chapman and Hall, 1989, 240 p.
6. *Bhatia S., Sharma P., Burman R., Hazari S. et al.* Credit Scoring Using Machine Learning Techniques. *International Journal of Computer Applications*, 2017, vol. 161, no. 11, pp. 1–4.
7. *Hosmer D., Lemeshow S.* Applied Logistic Regression. John Wiley & Sons, Inc., 2000. doi: 10.1002/0471722146
8. *Mortazavi E., Ahmadzadeh M.* A Hybrid Approach for Automatic Credit Approval. *International Journal of Scientific & Engineering Research*, 2014, vol. 5, iss. 8, pp. 614–619.
9. *Сорокин А.С.* Построение скоринговых карт с использованием модели логистической регрессии // Науковедение. 2014. № 2. URL: <http://naukovedenie.ru/PDF/180EVN214.pdf>
10. *Яцко В.А.* Разработка модели кредитного скоринга с использованием мягких вычислений // Бизнес. Образование. Право. Бюллетень Волгоградского института бизнеса. 2015. № 2. С. 251–255.
11. *Bazmara A., Donighi S.S.* Bank Customer Credit Scoring by Using Fuzzy Expert System. *I.J. Intelligent Systems and Applications*, 2014, vol. 11, pp. 29–35. doi: 10.5815/ijisa.2014.11.04
12. *Hoffmann F., Baesens B., Martens J., et al.* Comparing a genetic fuzzy and a neurofuzzy classifier for credit scoring. *International Journal of Intelligent Systems*, 2002, vol. 17, iss. 11, pp. 1067–1083. doi: 10.1002/int.10052
13. *Malhotra R., Malhotra D.K.* Differentiating between good credits and bad credits using neuro-fuzzy systems. *European Journal of Operational Research*, 2002, vol. 136, iss. 1, pp. 190–211. URL: [https://doi.org/10.1016/S0377-2217\(01\)00052-2](https://doi.org/10.1016/S0377-2217(01)00052-2)
14. *Nosratabadi H.E., Nadali A., Pourdarab S.* Credit Assessment of Bank Customers by a Fuzzy Expert System Based on Rules Extracted from Association Rules. *International Journal of Machine Learning and Computing*, 2012, vol. 2, no. 5, pp. 662–666.
15. *Sampath S., Kalaichelvi V.* Assessment of Mortgage Applications Using Fuzzy Logic. *International Journal of Social, Behavioral, Educational, Economic, Business and Industrial Engineering*, 2014, vol. 8, no. 11, pp. 3487–3491.
16. *Lai K.K., Yu L., Zhou L.G., Wang S.Y.* Neural Network Metalearning for Credit Scoring. URL: https://link.springer.com/chapter/10.1007/11816157_47
17. *Lee T.-S., Chen I.-F.* A two-stage hybrid credit scoring model using artificial neural networks and multivariate adaptive regression splines. *Expert Systems with Applications*, 2005, vol. 28, iss. 4, pp. 743–752. URL: <https://doi.org/10.1016/j.eswa.2004.12.031>

18. *Malhotra R., Malhotra D.K.* Evaluating consumer loans using neural networks. *Omega*, 2003, vol. 31, iss. 2, pp. 83–96. URL: [https://doi.org/10.1016/S0305-0483\(03\)00016-1](https://doi.org/10.1016/S0305-0483(03)00016-1)
19. *Pacelli V., Azzollini M.* An Artificial Neural Network Approach for Credit Risk Management. *Journal of Intelligent Learning Systems and Applications*, 2011, vol. 3, pp. 103–112. doi: 10.4236/jilsa.2011.32012
20. *West D.* Neural network credit scoring models. *Computers & Operations Research*, 2000, no. 27, pp. 1131–1152.
21. *Воронцов К.В.* Математические методы обучения машин по прецедентам (теория обучения машин). URL: <http://www.machinelearning.ru/wiki/images/6/6d/Voron-ML-1.pdf>
22. *Jarrow R.A., Turnbull S.* Pricing derivatives on financial securities subject to credit risk. *Journal of Finance*, 1995, vol. 50, iss. 1, pp. 53–85. doi: 10.1111/j.1540-6261.1995.tb05167.x

Информация о конфликте интересов

Мы, авторы данной статьи, со всей ответственностью заявляем о частичном и полном отсутствии фактического или потенциального конфликта интересов с какой бы то ни было третьей стороной, который может возникнуть вследствие публикации данной статьи. Настоящее заявление относится к проведению научной работы, сбору и обработке данных, написанию и подготовке статьи, принятию решения о публикации рукописи.

EVALUATION OF SMALL BUSINESS CREDITWORTHINESS

Igor' V. ARINICHEV^{a,*}, Natal'ya Yu. SAIBEL^b^a Kuban State University, Krasnodar, Russian Federation
iarinichev@gmail.com^b Kuban State University, Krasnodar, Russian Federation
saybel-natali@yandex.ru

* Corresponding author

Article history:Received 14 July 2017
Received in revised form
28 July 2017
Accepted 11 August 2017
Available online
29 August 2017**JEL classification:** C44, C51,
C52, L25, L26**Keywords:** creditworthiness,
small business, scoring, risk,
machine learning**Abstract****Importance** The article addresses the need to develop an integrated approach to creditworthiness assessment based on performance indicators of small businesses that characterize all aspects of their operations.**Objectives** The purpose of the study is to develop an algorithm to evaluate the borrowing power and to build a logical model of creditworthiness of small businesses that would consider every facet of their operations and a low degree of financial stability.**Methods** Using the methods of comparison and analogy, we review existing approaches to evaluation of small business creditworthiness.**Results** The developed methodology rests on machine learning techniques, which make it sufficiently complete and detailed. The techniques imply finding, revealing and analyzing indicators that comprehensively describe the operations of small business entities. We propose a systematization of factors of creditworthiness, which will enable a straightforward and efficient assessment.**Conclusions** The existing methods to assess small business creditworthiness mainly focus on business analysis. However, to provide an adequate assessment, the methodology should take into account not only financial performance, but also business reputation, efficiency of basic resource utilization, level of competitiveness, and market position.

© Publishing house FINANCE and CREDIT, 2017

Please cite this article as: Arinichev I.V., Saibel' N.Yu. Evaluation of Small Business Creditworthiness. *Finance and Credit*, 2017, vol. 23, iss. 31, pp. 1878–1892.
<https://doi.org/10.24891/fc.23.31.1878>**Acknowledgments**

We extend our appreciation and profound gratitude to Viktor A. SIDOROV, Doctor of Economics, Professor, Head of Theoretical Economics Department of the Kuban State University, for his advice during our work on the article, and to all those involved in detailed review of the manuscript for valuable comments.

References

1. Altman E. Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *Journal of Finance*, 1968, vol. 23, no. 4, pp. 589–609.
2. Beaver W.H. Financial ratios as predictors of failure. *Journal of Accounting Research*, 1966, vol. 4, pp. 71–111.
3. Chesser D. Predicting loan noncompliance. *The Journal of Commercial Bank Lending*, 1974, no. 56(12), pp. 28–38.
4. Dimitriu M., Oprea I.A. Modeling Credit Scoring. *Metalurgia International*, 2010, no. 5, Special Issue, pp. 62–67.

5. Cox D.R., Snell E.J. *Analysis of Binary Data*. London, Chapman and Hall, 1989, 240 p.
6. Bhatia S., Sharma P., Burman R., Hazari S. et al. Credit Scoring Using Machine Learning Techniques. *International Journal of Computer Applications*, 2017, vol. 161, no. 11, pp. 1–4.
7. Hosmer D., Lemeshow S. *Applied Logistic Regression*. John Wiley & Sons, Inc., 2000. doi: 10.1002/0471722146
8. Mortazavi E., Ahmadzadeh M. A Hybrid Approach for Automatic Credit Approval. *International Journal of Scientific & Engineering Research*, 2014, vol. 5, iss. 8, pp. 614–619.
9. Sorokin A.S. [Building a scorecard using a logistic regression model]. *Naukovedenie*, 2014, no. 2. (In Russ.) URL: <http://naukovedenie.ru/PDF/180EVN214.pdf>
10. Yatsko V.A. [Development of credit scoring model using soft computations]. *Biznes. Obrazovanie. Pravo. Byulleten' Volgogradskogo instituta biznesa = Business. Education. Law. Bulletin of Volgograd Business Institute*, 2015, no. 2, pp. 251–255. (In Russ.)
11. Bazmara A., Donighi S.S. Bank Customer Credit Scoring by Using Fuzzy Expert System. *International Journal of Intelligent Systems and Applications*, 2014, vol. 11, pp. 29–35. doi: 10.5815/ijisa.2014.11.04
12. Hoffmann F., Baesens B., Martens J. et al. Comparing a genetic fuzzy and a neurofuzzy classifier for credit scoring. *International Journal of Intelligent Systems*, 2002, vol. 17, iss. 11, pp. 1067–1083. doi: 10.1002/int.10052
13. Malhotra R., Malhotra D.K. Differentiating between good credits and bad credits using neuro-fuzzy systems. *European Journal of Operational Research*, 2002, vol. 136, iss. 1, pp. 190–211. URL: [https://doi.org/10.1016/S0377-2217\(01\)00052-2](https://doi.org/10.1016/S0377-2217(01)00052-2)
14. Nosratabadi H.E., Nadali A., Pourdarab S. Credit Assessment of Bank Customers by a Fuzzy Expert System Based on Rules Extracted from Association Rules. *International Journal of Machine Learning and Computing*, 2012, vol. 2, no. 5, pp. 662–666.
15. Sampath S., Kalaichelvi V. Assessment of Mortgage Applications Using Fuzzy Logic. *International Journal of Social, Behavioral, Educational, Economic, Business and Industrial Engineering*, 2014, vol. 8, no. 11, pp. 3487–3491.
16. Lai K.K., Yu L., Zhou L.G., Wang S.Y. Neural Network Metalearning for Credit Scoring. URL: https://link.springer.com/chapter/10.1007/11816157_47
17. Lee T.-S., Chen I.-F. A two-stage hybrid credit scoring model using artificial neural networks and multivariate adaptive regression splines. *Expert Systems with Applications*, 2005, vol. 28, iss. 4, pp. 743–752. URL: <https://doi.org/10.1016/j.eswa.2004.12.031>
18. Malhotra R., Malhotra D.K. Evaluating consumer loans using neural networks. *Omega*, 2003, vol. 31, iss. 2, pp. 83–96. URL: [https://doi.org/10.1016/S0305-0483\(03\)00016-1](https://doi.org/10.1016/S0305-0483(03)00016-1)
19. Pacelli V., Azzollini M. An Artificial Neural Network Approach for Credit Risk Management. *Journal of Intelligent Learning Systems and Applications*, 2011, vol. 3, pp. 103–112. doi: 10.4236/jilsa.2011.32012
20. West D. Neural network credit scoring models. *Computers & Operations Research*, 2000, no. 27, pp. 1131–1152.

21. Vorontsov K.V. *Matematicheskie metody obucheniya mashin po pretsedentam (teoriya obucheniya mashin)* [Mathematical methods of case-based machine learning (machine learning theory)]. URL: <http://www.machinelearning.ru/wiki/images/6/6d/Voron-ML-1.pdf> (In Russ.)
22. Jarrow R.A., Turnbull S. Pricing derivatives on financial securities subject to credit risk. *The Journal of Finance*, 1995, vol. 50, iss. 1, pp. 53–85. doi: 10.1111/j.1540-6261.1995.tb05167.x

Conflict-of-interest notification

We, the authors of this article, bindingly and explicitly declare of the partial and total lack of actual or potential conflict of interest with any other third party whatsoever, which may arise as a result of the publication of this article. This statement relates to the study, data collection and interpretation, writing and preparation of the article, and the decision to submit the manuscript for publication.