




Известия Саратовского университета. Новая серия. Серия: Экономика. Управление. Право. 2024. Т. 24, вып. 3. С. 294–311
Izvestiya of Saratov University. Economics. Management. Law, 2024, vol. 24, iss. 3, pp. 294–311
<https://eup.sgu.ru> <https://doi.org/10.18500/1994-2540-2024-24-3-294-311>, EDN: OWEQBG

Научная статья
УДК 336.77

Методы диагностики и прогнозирования кредитоспособности субъектов МСП с применением искусственного интеллекта



В. В. Заболоцкая

¹ Российский университет дружбы народов имени Патриса Лумумбы, Россия, 117198, г. Москва, ул. Миклухо-Маклая, д. 6
² Кубанский государственный университет, Россия, 350040, г. Краснодар, ул. Ставропольская, д. 149

Заболоцкая Виктория Викторовна, кандидат экономических наук, доцент, ¹научный сотрудник кафедры менеджмента; ²доцент кафедры мировой экономики и менеджмента, zvicky90@gmail.com, <https://orcid.org/0000-0002-9808-127X>

Аннотация. Введение. Воздействие макроэкономических и региональных факторов экономической бизнес-среды в условиях неопределенности и повышенных рисков обуславливает значительные сложности диагностики, оценки и прогнозирования кредитоспособности получателей финансово-кредитной поддержки и заемщиков – субъектов малого и среднего предпринимательства (МСП). **Теоретический анализ.** Осуществлена систематизация основных математических методов и моделей оценки и прогнозирования уровня кредитоспособности предприятий микро-, малого и среднего бизнеса в зарубежной и российской практике, применяющих современные системы и технологии искусственного интеллекта и методы машинного обучения. **Эмпирический анализ.** Предложены результаты апробации методологического подхода экспресс-диагностики финансово-экономического состояния и прогнозирования кредитоспособности субъектов МСП Краснодарского края за 2014–2017 гг., основанного на применении методов экспертной оценки, экономического анализа и нечетких продукционных систем и позволяющий производить расчет кредитного рейтинга субъектов МСП с учетом их отраслевой принадлежности. **Результаты.** Детерминированы преимущества и недостатки методов и моделей диагностики кредитоспособности и кредитного скоринга с позиции их применения для различных категорий субъектов МСП. Показано, что наиболее перспективными и математически достоверными моделями для осуществления кредитного скоринга и оценки риска финансовой поддержки и кредитования различных предприятий сектора МСП на различных стадиях их жизненного цикла как в России, так и за рубежом являются компьютеризированные модели и экспертные системы, применяющие такие методы и технологии искусственного интеллекта, как нечеткие множественные и нечеткие продукционные системы, искусственные нейронные сети, метод опорных векторов, ансамблевые методы (метод «случайного леса»), а также интеллектуальные информационные системы, гибридные модели и гибридные системы. В работе показано, что их комбинация друг с другом позволит достичь синергетического эффекта и эмерджентности при взаимодействии кредиторов с заемщиками – субъектами МСП и своевременно избежать их банкротства.

Ключевые слова: кредитоспособность, малое и среднее предпринимательство, методы и модели диагностики и прогнозирования, искусственный интеллект, машинное обучение, управленческие решения

Для цитирования: Заболоцкая В. В. Методы диагностики и прогнозирования кредитоспособности субъектов МСП с применением искусственного интеллекта // Известия Саратовского университета. Новая серия. Серия: Экономика. Управление. Право. 2024. Т. 24, вып. 3. С. 294–311. <https://doi.org/10.18500/1994-2540-2024-24-3-294-311>, EDN: OWEQBG

Статья опубликована на условиях лицензии Creative Commons Attribution 4.0 International (CC-BY 4.0)

Article

Methods for diagnostics and forecasting SMEs creditworthiness using artificial intelligence

V. V. Zabolotskaya

Peoples' Friendship University of Russia named after Patrice Lumumba, 6 Miklukho-Maklaya St., Moscow 117198, Russia
Kuban State University, 149 Stavropolskaya St., Krasnodar 350040, Russia

Victoria V. Zabolotskaya, zvicky90@gmail.com, <https://orcid.org/0000-0002-9808-127X>

Abstract. Introduction. The impact of multidirectional external macroeconomic and regional factors of the economic environment in conditions of uncertainty and increased risks causes significant difficulties in diagnosing, assessing and forecasting the creditworthiness of financial and credit support recipients and borrowers (micro, small and medium-sized enterprises) in the Russian Federation. **Theoretical analysis.** The author systematized the basic mathematical methods and models for assessing and forecasting the level of creditworthiness of micro, small and medium-sized businesses in foreign and Russian practice, using modern systems and technologies of artificial intelligence and machine learning methods. **Empirical analysis.** The author proposed the results of approbation of methodological approach for express diagnostics of the financial



and economic condition and forecasting the creditworthiness of SMEs in the Krasnodar krai for the period of 2014–2017, based on expert assessment methods, economic analysis and fuzzy logic systems, which form the credit rating of SMEs considering their industry affiliation. **Results.** In this study, the author has determined the advantages and disadvantages of methods and models for diagnosing creditworthiness and credit scoring from the perspective of their application for various categories of SMEs. As it is shown that the most promising and mathematically reliable models for credit scoring and risk assessment of financial support and lending to various enterprises in the SME sector at different stages of their life cycle both in Russia and abroad are computerized models and expert systems, based on such methods and technologies of Artificial Intelligence, as fuzzy logic systems, artificial neural networks, support vector machines, ensemble methods (random forest method), as well as intelligent information systems, hybrid models and hybrid systems. The study reveals that their combination with each other will allow to achieve synergistic and system effects in the interaction between lenders and borrowers (SMEs) and timely avoid their bankruptcy.

Keywords: creditworthiness, SMEs, diagnostic and forecasting methods and models, artificial intelligence, machine learning, management decisions

For citation: Zabolotskaya V. V. Methods for diagnostics and forecasting SMEs creditworthiness using artificial intelligence. *Izvestiya of Saratov University. Economics. Management. Law*, 2024, vol. 24, iss. 3, pp. 294–311 (in Russian). <https://doi.org/10.18500/1994-2540-2024-24-3-294-311>, EDN: OWEQBG

This is an open access article distributed under the terms of Creative Commons Attribution 4.0 International License (CC-BY 4.0)

Введение

Одними из ключевых проблем диагностики кредитоспособности заемщиков сектора малого и среднего предпринимательства (МСП) являются информационная непрозрачность их деятельности и низкая финансовая грамотность предпринимателей, что приводит к появлению множества ошибок в их финансовой и управленческой отчетности. Заемщики из сектора МСП до сих пор являются высокорисковым сегментом для потенциальных инвесторов и кредиторов.

Наиболее известный и простой способ информирования инвесторов и кредиторов – кредитные рейтинги оценки надежности заемщика. Однако рейтингов для МСП, присваиваемых международными агентствами, крайне мало, и зачастую они не только не совпадают, но и противоречат друг другу, к тому же эти рейтинги, как правило, не учитывают региональную специфику.

Применение методов и технологий искусственного интеллекта (ИИ) и инструментария машинного обучения для диагностики и прогнозирования кредитоспособности субъектов МСП в России в приоритетных и доминирующих отраслях с использованием не только количественных, финансовых, социально-экономических, но и качественных показателей функционирования предприятий, и макроэкономических показателей страны и регионов является актуальной задачей, резко возросшей в современных условиях повышенных рисков и неопределенности в бизнес-среде, возникших из-за ужесточения экономических санкций со стороны стран коллективного Запада и преодоления последствий пандемии COVID-19, а также разрыва деловых связей отечественных предприятий после начала специальной военной операции РФ на Украине.

Теоретический анализ

Математические методы и модели оценки социально-экономических процессов, в том числе для диагностики и прогнозирования кредитоспособности можно дифференцировать на параметрические и непараметрические.

Параметрические модели включают: линейную вероятностную модель, логит- или пробит-модели, модель на основе дискриминантного анализа [1] и нейронные сети. Непараметрические модели включают в себя математическое программирование, классификационные деревья, модель ближайшего соседа, процесс аналитической иерархии и экспертные системы [1].

Среди перечисленных моделей для оценки кредитоспособности МСП наиболее часто используются модели, основанные на классических методах статистического анализа (например, модель линейной вероятности, логит- и пробит-модели, дискриминантный анализ) и альтернативные методы – нейронные сети [2].

Разработке моделей и методов ИИ для решения узкоспециализированных задач в экономике были посвящены работы А. С. Арутюняна с соавт. [3], Дж. Бакли с соавт. [4], Т. П. Барановской с соавт. [5], Дж. и М. Бояджиевых [6], С. Зопундисиса и М. Доумпоса [7], М. В. Иванищева [8], Е. В. Луценко с соавт. [9] и А. О. Недосекина [10].

Для использования методов и технологий ИИ необходимо учитывать особенности функционирования субъектов МСП в экономической среде. Решение этой задачи требует существенной модификации данных методов и разработки нового инструментария, адаптированного к особенностям предприятий этого сектора экономики. Отсутствие полноценного и комплексного исследования проблем финансово-экономиче-



ского анализа, оценки кредитоспособности и банкротства МСП с учетом их отраслевой и региональной специфики на основе современного математического аппарата ИИ обосновывает имеющийся пробел в исследуемой области.

Проблема прогнозирования и анализа кредитоспособности предприятий сферы МСП относится к задаче моделирования сложных слабоструктурированных систем, которую невозможно решать без применения методов и технологий ИИ и машинного обучения.

Для оценки и прогнозирования кредитоспособности и рисков кредитования МСП используются различные математические методы: искусственные нейронные сети, генетические алгоритмы, метод опорных векторов, ансамблевые методы или «случайный лес», метод дерева решений (классификационных

деревьев) [11]. Эти методы позволяют получить достоверные прогнозные оценки кредитоспособности заемщиков (субъектов МСП).

Искусственные нейронные сети (Artificial Neural Networks, ANN) явились предметом фундаментальных исследований в 60–70-е гг. XX в. В тот период впервые были предприняты попытки воссоздать работу биологических нейронных сетей, моделирующих функционирование мозга. Нейрон биологического организма – это базовая (элементарная) структурно-функциональная единица мозга. Несмотря на обилие форм, все нейроны действуют по одному принципу: электрический сигнал, поступающий на дендриты, передается по нейрону до терминалей через аксон. Далее этот импульс переходит к другому нейрону, который соединяется с предыдущим, используя синаптические связи (рис. 1).



Рис. 1. Строение нейрона
Fig. 1. Structure of a neuron

Сегодня имеется уже достаточно знаний в этой области, чтобы предлагать различные способы решения задач в экономике при помощи математического моделирования нейронных сетей. Нейронная сеть представляет собой модель обработки информации, напоминающую структуру связей в синапсах, которая состоит из большого количества узлов, называемых нейронами, соединенными связями.

Впервые модель искусственного нейрона была представлена учеными У. Маккаллоком и У. Питтсом [12]. Основу каждой ANN составляют простые элементы, которые соединены между собой синаптическими связями и способны имитировать работу нейронов головного мозга. Строение модели искусственного нейрона показано на рис. 2.

Вход представляет собой вектор вещественных чисел $x = (x_1, \dots, x_n)$, а каждый синапс ха-




Рис. 2. Строение модели искусственного нейрона
Fig. 2. Structure of an Artificial Neuron Model

рактеризуется величиной w_i , называемой весом. Это действительный коэффициент, находящийся в промежутке от 0 до 1.



В качестве текущего состояния нейрона понимают взвешенную сумму его входов. Входными данными нейрона считается значение $Y = f(S)$:

$$S = \sum_{i=1}^n x_i w_i, \quad (1)$$

где S – сумма входов, которая вычисляется по формуле (1); f – функция активации, принимающая значения из интервала (0; 1).

Для активации нейронных сетей наиболее часто применяют следующие функции:

логистический сигмоид –

$$\sigma(x) = \frac{1}{1 + e^{-x}}; \quad (2)$$

гиперболический тангенс –

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}; \quad (3)$$

ступенчатая функция Хевисайда –

$$\text{step}(x) = \begin{cases} 0, & x < 0 \\ 1, & x > 0 \end{cases}; \quad (4)$$

кусочно-линейная функция –

$$\text{ReLU}(x) = f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}. \quad (5)$$

Единых правил выбора наиболее эффективной функции не существует. Для каждой задачи ее следует подбирать индивидуально, отталкиваясь от результатов процесса обучения. Однако среди перечисленных функций чаще всего применяют логистический сигмоид (см. (2)) и ступенчатую функцию Хевисайда (см. (4)).

ANN представляет собой направленный граф со связями между узлами, где каждый узел является искусственным нейроном.

Отличие ANN друг от друга состоит в характере соединения отдельных компонентов сети.

По архитектуре связей можно выделить три типа нейронных сетей [2] (рис. 3):

– однослойные сети прямого распространения (рис. 3, а);

– многослойные сети прямого распространения (рис. 3, б);

– рекуррентные сети (рис. 3, в, г).

Нейросеть организована слоями. Однослойные сети прямого распространения (рис. 3, а) – это простейшая форма такой сети, имеет один слой и строго прямой тип подачи входных данных. Входные данные проецируются в выходные зна-

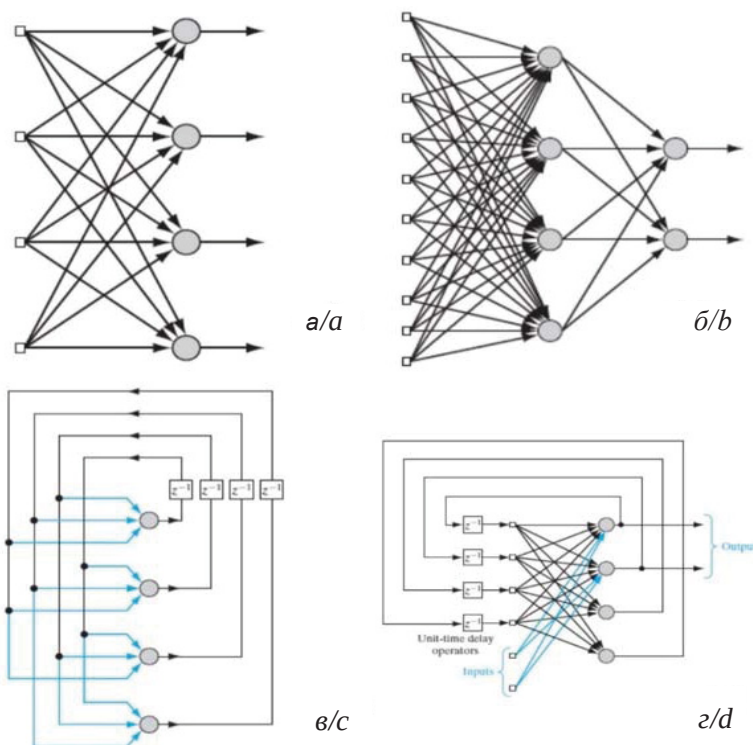


Рис. 3. Типы искусственных нейронных сетей: а – однослойные сети прямого распространения; б – многослойные сети прямого распространения; в, г – рекуррентные сети

Fig. 3. Types of Artificial Neural Networks: а – single-layer neural networks; б – multilayer neural networks; в, г – recurrent neural networks



чения и не считаются за слои, поскольку на этой стадии не выполняются вычисления. Второй класс прямой нейронной сети (З, б) отличается кроме входного и выходного нейронов наличием некоторого количества скрытых слоев. Такие сети обладают большими возможностями, чем предыдущие и в большей степени приближены к имитации работы человеческого головного мозга. В рекуррентных сетях (З, в, г) нейронные связи к верхнему слою могут идти не только от нижнего слоя, но и от предыдущих значений нейронов того же слоя. Рекуррентные сети продемонстрировали значительный успех при решении многих задач, связанных с генерацией текстов, машинным переводом, а также распознаванием речи и созданием описаний изображений:

Нейросети использовались для проведения кредитного скоринга [13]. В исследовании Ф. Чампи, Н. Гордини [14] отмечалось, что их использование способно повысить точность управленческого решения о кредитовании малого бизнеса по сравнению с традиционными методологиями. В работах В. Джаннопулоса, Е. Аггелопулоса [15], М. Оливейра с соавт. [16] показано, что нейросети эффективны для присвоения баллов в кредитном скоринге.

Метод опорных векторов (Support Vector Machines, SVM) – это относительно новый метод машинного обучения, основанный на использовании ИИ. В основе метода лежит построение гиперплоскости, разделяющей данные на классы по полученным на входе данным многомерного пространства. Этот метод основан на правилах минимизации структурного риска (structural risk minimization rule), которые теоретически обеспечивают хорошую устойчивость, и способен решать как линейные, так и нелинейные задачи, классификации и регрессии. Алгоритмы SVM функционируют по принципу «черного ящика», что значительно усложняет интерпретацию результатов.

Х. С. Ким и С. Й. Сон [17] предложили модель SVM для прогнозирования риска дефолта финансируемых МСП.

Генетические алгоритмы (Genetic Algorithm, GA) имитируют процесс естественного отбора теории эволюции Дарвина с целью поиска оптимального решения. GA – стохастические, эвристические оптимизационные методы, применяемые для подбора коэффициентов регрессионной зависимости с помощью процесса, подобного процессу естественного отбора. Этот метод является самоадаптирующимся, обладает высокой надежностью. GA способен обрабатывать любые

формы целевой функции, независимо от того, являются ли данные функции линейными или нелинейными, непрерывными или дискретными.

Х. А. Абду [18], К. С. Онг с соавт. [19] применили генетическое программирование для кредитной оценки заемщиков.

Ансамблевые методы (Ensemble Techniques, ET) (метод «случайного леса», Random Forests). Ансамблевое обучение – это новый метод машинного обучения, используемый для проведения кредитного скоринга заемщиков. Одной из наиболее важных его характеристик является возможность получения общего решения без индивидуального решения нескольких подзадач [13].

Классификационные и регрессионные деревья решений (Classification and Regression Trees, CART). Метод прогнозирования вероятности риска невыплаты по кредиту, широко используемый в статистике, интеллектуальном анализе данных и машинном обучении, использует дерево решений как прогностическую модель.

Метод CART, впервые предложенный Л. Брейманом с соавт. [20], является одним наиболее распространенных методов оценки кредитоспособности заемщиков. Он основан на рекурсивном процессе деления данных при переходе с более высокого уровня дерева к более низкому.

Важными алгоритмами построения этого регрессионного дерева являются алгоритм рекурсивного деления и энтропийный алгоритм [21].

Алгоритм CART можно определить с помощью индекса Джини (Gini):

$$\text{Gini } T = 1 - \sum_{i=1}^n p_i^2, \quad (6)$$

где Gini – индекс Джини; T – показатели оценки кредитоспособности субъекта МСП; p_i – вероятность (относительная частота) класса в T .

Для узла бинарного дерева (с двумя ветвями-потомками) показатель «успешности» разбиения множества рассчитывается как

$$G_{\text{split}} = \frac{1}{L} \sum_{i=1}^n l_i^2 + \frac{1}{R} \sum_{i=1}^n r_i^2, \quad (7)$$

где L , R – количество примеров соответственно в левом и правом потомке дерева решений; l , r – количество экземпляров i -го и j -го класса в левом и правом потомке дерева решений.

Оптимальным считается такое разбиение, для которого величина G_{split} имеет максимальное значение. Пример дерева решений для оценки кредитоспособности заемщика представлен на рис. 4.

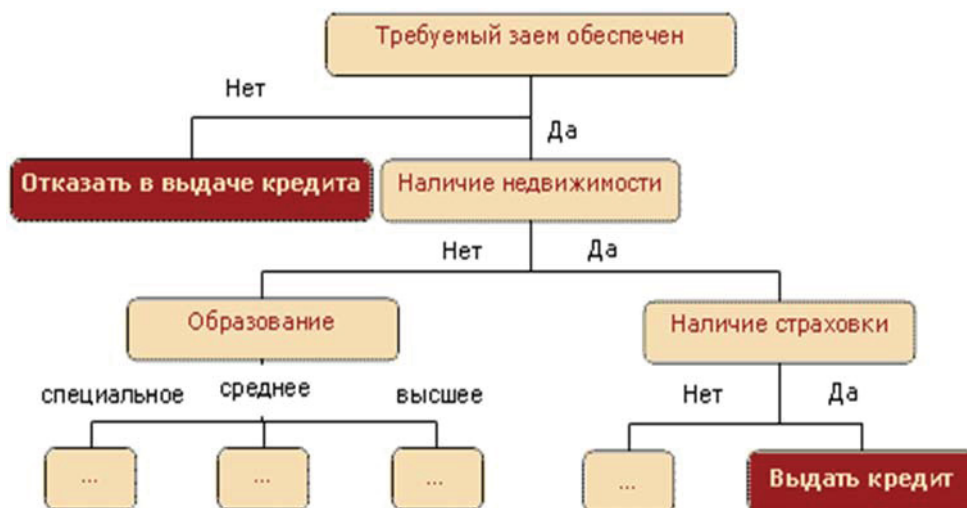


Рис. 4. Пример построения дерева решений для диагностики кредитоспособности заемщика
 Fig. 4. An example of constructing a decision tree for the diagnostics of the borrower's creditworthiness

Для субъектов МСП метод CART получил широкое применение, в том числе при комбинировании его с другими методами оценки кредитоспособности заемщика. В работе Е. А. Федоровой с соавт. [22] с помощью метода CART, а также его модификации (Bagging CRT, Boosting CRT) были уточнены нормативные значения для финансовых коэффициентов для предприятий МСП на этапе их банкротства.

В работе А. Брезигар-Мастена, И. Мастена [23] метод CART был скombинирован с логит-моделями для диагностики банкротства МСП. В исследовании З. Ли для построения моделей прогнозирования МСП в Южной Корее были использованы метод CART, его модификация (LightGBM) и логистическая регрессия. Построенная модель была основана на использовании только внешних кредитных данных, достигнутый уровень прогностической способности составил 87% [21].

К перспективным методам диагностики и прогнозирования уровня кредитоспособности субъектов МСП относят: нечеткие продукционные системы, интеллектуальные информационные системы, а также гибридные модели (системы).

Нечеткие продукционные системы (НПС) (Fuzzy logic systems, FLS) представляют собой современный компьютеризированный метод оценки и прогнозирования различных объектов и процессов, базирующийся на теории нечеткой логики (Fuzzy logic) и нечетких множеств (Fuzzy sets theory). Нечетко-множественные модели по-

зволяют выявить функциональные связи между нечеткими лингвистическими переменными и специальными функциями, характеризующими степень принадлежности значений уровня кредитоспособности МСП нечетким описаниям. FLS – это экспертные системы, ориентированные на построение адекватных и эффективных решений в условиях неполноты и неточности исходных данных при наличии неопределенности. Данные системы позволяют описывать естественным образом процесс мышления человека и ход его рассуждений, лингвистическую неопределенность, а также нечетко формализуемые экономические системы и процессы.

Впервые теория нечетких множеств была создана Л. Заде в 1965 г. [24]. Нечеткое множество – совокупность элементов, относительно которых нельзя однозначно идентифицировать степень принадлежности любого элемента, входящего в множество [2].

Нечеткая система (Fuzzy system) характеризуется неопределенностью границ системы, отдельных ее состояний, входных и выходных воздействий [2]. Структура модели FLS может быть изображена в виде фигуры с расплывчатыми границами (рис. 5).

Представление нечеткого множества имеет следующий вид [2]:

$$\mu A(x) : X \rightarrow [0, 1], \quad (8)$$

где A – нечеткое множество, включающее множество пар (кортежей) вида: $\langle x, \mu A(x) \rangle$; x – элемент, принадлежащий некоторому универсальному множеству (универсум (X));




Рис. 5. Визуализация нечеткой системы [2]
 Fig. 5. Visualization of a fuzzy logic system [2]

$\mu A(x)$ – функция, которая ставит в соответствие любому элементу x из множества X действительное число, лежащее в интервале $[0; 1]$.

Если для некоторого $x \in X$ значение $\mu A(x) = 1$, то в этом случае можно понимать, что $x \in A$. Аналогично, когда $\mu A(x) = 0$, соответственно $x \notin A$.

Любое конечное нечеткое множество имеет следующий вид:

$$A = \{ \langle x_1, \mu A(x_1) \rangle, \langle x_2, \mu A(x_2) \rangle, \dots, \langle x_n, \mu A(x_n) \rangle \}. \quad (9)$$

Множество A – такое множество A_s , которое включает в себя только элементы универсума (X) с отличными от нуля значениями функции принадлежности. Носитель нечеткого множества

$$A_s = \{ x \in X \mid \mu A(x) > 0 \} \quad \forall x \in X. \quad (10)$$

Ядро нечеткого множества включает в себя следующие элементы:

$$A_1 = \{ x \in X \mid \mu A(x) = 1 \}. \quad (11)$$

Элементы универсума (X) с отличными от 0 и 1 значениями функции принадлежности считаются границами нечеткого множества $A = \{ \langle x, \mu A(x) \rangle \}$ и включают только те элементы универсума $x \in X$, для которых будет выполняться условие: $0 < \mu A(x) < 1$. Элементы некоего нечеткого множества $u \in A$, удовлетворяющие условию $\mu A(u) = 0,5$, считаются точками перехода нечеткого множества A .

В практике моделирования FLS применяют следующие алгоритмы нечеткого вывода: алгоритмы Мамдани, Цукамото, Ларсена и Сугено. Среди перечисленных алгоритмов для решения экономических проблем наиболее популярным

является алгоритм Мамдани [2, 25]. Для построения моделей с использованием нечеткой логики используют специальный пакет программы MATLAB – Fuzzy Logic Toolbox.

В работе А. К. Язди с соавт. [25] был предложен метод оценки кредитоспособности заемщиков на основе нечетких множеств для Фонда гарантирования экспорта Ирана. В российской практике труды таких ученых, как В. В. Заболоцкая [26], И. В. Шевченко с соавт. [27], были посвящены исследованию возможностей нечетких множеств и нечетких продукционных систем для оценки кредитоспособности МСП.

В результате развития ИИ теория нечетких множеств Л. Заде получила вторую жизнь. Появилось новое направление моделирования, в том числе в сфере прогнозирования финансовых процессов, получившее название «мягкие вычисления» (soft computing). Теория нечетких множеств и ИИ дополняют друг друга и используются в различных комбинациях для создания гибридных интеллектуальных информационных систем.

Интеллектуальные информационные системы (Intellectual informational systems, IIS) – новейший оценочный метод, который может успешно применяться в области диагностики кредитоспособности заемщиков, в том числе из сферы МСП. IIS – это компьютеризированные информационно-аналитические системы со встроенными интеллектуальными компонентами, основанными на различных математических методах и применении ИИ.

Гибридные модели и гибридные системы (Hybrid models и Hybrid systems) представляют собой многослойную нейросеть специальной



структуры. При этом значения входов, выходов и весов гибридной нейросети представляют собой нечеткие лингвистические переменные [2]. Данные модели и системы объединяют в себе достоинства нейросетей и FIS.

Несмотря на то, что они синтезируют в себе преимущества различных математических методов, четкого решения о том, как классифицировать гибридные модели, до сих пор нет. Это позволяет применять различные комбинации существующих методов диагностики и прогнозирования кредитоспособности, а также

кредитного скоринга для достижения высокой точности результатов. Ключевое отличие гибридных методов от ансамблевых алгоритмов заключается в том, что первые используют только один классификатор для выборочного обучения и разные способы выбора признаков и этапов классификации [13].

Систематизация преимуществ и недостатков математических методов, применяемых к диагностике и прогнозированию кредитоспособности МСП с использованием ИИ, представлена в табл. 1.

Таблица 1 / Table 1

Преимущества и недостатки основных математических методов диагностики и прогнозирования кредитоспособности с позиции субъектов МСП с применением ИИ
Advantages and Disadvantages of the Basic Mathematical Methods for Diagnosing and Forecasting Creditworthiness for SMEs Using AI

Метод	Преимущества	Недостатки
Нейронные сети	<ul style="list-style-type: none"> Высокие прогностические возможности; – возможность нелинейного моделирования и обучения на примерах; – возможность выстраивания четкого алгоритма работы, основанного на теоремах Колмагорова и Хехт – Нильсена, заключающихся в возможности разложения сложной функции в ряд линейных функций; – способность преобразования качественных (лингвистических) данных в номинальные, а затем обратно в числовую форму; – возможность решения трудно формализуемых и неформализуемых задач 	<ul style="list-style-type: none"> Интуитивный (экспертный) выбор входящих переменных; – закрытость (нейросети – это «черный ящик», имеющий вход и выход с неизвестным алгоритмом работы); – представление знаний об исследуемой области в специальном виде [2]; – необходимость наличия репрезентативной выборки для моделирования и прогнозирования
Метод опорных векторов	<ul style="list-style-type: none"> Способность анализа линейно и нелинейно разделяемых данных (ядерный метод); – высокая эффективность анализа многомерных и небольших наборов данных 	<ul style="list-style-type: none"> Снижение эффективности при анализе рядов с «белым шумом», которые имеют перекрывающиеся классы
Метод CART	<ul style="list-style-type: none"> Высокая скорость работы алгоритма и достоверность вычислений (около 90%) [28]; – отсутствие жестких требований к статистическим данным; – возможность использования качественных показателей; – способность обработки «шумных» и неполных данных [29] 	<ul style="list-style-type: none"> Отсутствие возможности определения наиболее весомых переменных [29]; – высокая трудоемкость построения регрессионных деревьев, что приводит к удорожанию операционных расходов банков при кредитовании субъектов МСП
Генетические и ансамблевые алгоритмы	<ul style="list-style-type: none"> Высокая эффективность при решении крупномасштабных проблем оптимизации; – возможности поиска решений для широкого класса задач; – простота, прозрачность в реализации; – возможность использования в задачах с изменяющейся средой 	<ul style="list-style-type: none"> Мало применимы в случае, когда необходимо найти локальный экстремум; – время исполнения оценки с помощью генетического алгоритма велико; – не применимы в случае, если необходимо найти все варианты решения задачи; – высокая сложность конфигурации алгоритма (осуществляется кодирование решения); – поиск оптимального решения для сложных задач является затратным; – низкая масштабируемость



Окончание табл. 1 / Continuation of the Table 1

Метод	Преимущества	Недостатки
Нечеткие множественные и нечеткие продукционные системы	Возможность использования количественно-качественных данных; – отсутствие ограничений числа исследуемых объектов (параметров); – высокая достоверность принимаемых управленческих решений	Недостаточность квалификации эксперта при формировании лингвистических функций и правил вывода; – экспертный подход при формировании правил нечеткого вывода часто не позволяет получить полную и непротиворечивую базу правил нечеткого вывода; – ориентированность на решение классификационных задач
Интеллектуальные информационные системы	Обеспечение высокой точности диагностики, анализа и прогнозирования кредитоспособности заемщика; – обеспечение высокого качества принимаемых управленческих решений при предоставлении кредитных ресурсов и формировании кредитной политики кредитора	Необходимость высокой квалификации специалистов, создающих ИИС
Гибридные системы и гибридные модели	Возможность использования обучающей выборки так же, как у нейросетей, и для определения параметров функций принадлежности, как у нечетких множественных или продукционных систем [2]	Нерациональность использования в случае недостаточной репрезентативной (обучающей) выборки; – ориентированность на решение прогнозных задач

Сост. по: [2, 26, 28, 29] / Compiled according to: [2, 26, 28, 29].

Эмпирический анализ

Исходя из проведенного теоретического исследования основных математических методов диагностики и прогнозирования кредитоспособности с позиции субъектов МСП с применением ИИ, автором *впервые* был разработан комплексный подход экспресс-диагностики финансово-экономического состояния (ФЭС) и прогнозирования кредитоспособности микро-, малых и средних предприятий, базирующийся на комбинировании искусственного интеллекта (нечетких множеств и нечетких продукционных систем) и классических методов экспертной оценки (балльно-рейтинговой и интегральной оценки) с учетом региональной специфики, включающий пять этапов.

1. Подготовка базы данных и обоснование выбора показателей для экспресс-диагностики ФЭС и уровня кредитоспособности субъектов МСП.

2. Формирование архитектуры и модульной структуры автоматизированной кредитной экспертизы экспресс-диагностики ФЭС и кредитоспособности заемщиков (предприятий сферы МСП).

3. Построение нечетких продукционных систем для расчета интегральных показателей

($y_1 - y_9$) и общего интегрального ФЭС и кредитоспособности заемщиков (хозяйствующих субъектов МСП).

4. Разработка интерфейса и краткое описание работы программного приложения.

5. Расчет рейтинга, отражающего уровень ФЭС и кредитоспособности МСП в программе ЭВМ, и вывод данных (при необходимости выгрузка в Excel).

На этапе 1 с использованием методов корреляционного анализа и главных компонент были отобраны 35 линейно-независимых показателей (рис. 6). Данные показатели были проранжированы с применением метода экспертных оценок и аппарата теории нечетких множеств в диапазоне от 0 до 1 по правилу пента-шкалы, им были присвоены баллы оценки ФЭС и уровня кредитоспособности (0 – *L* – очень низкий, 0,25 – *LM* – низкий, 0,5 – *M* – средний, 0,75 – *HM* – высокий, 1 – *H* – очень высокий). Интегральные рейтинги «очень низкий» и «низкий» свидетельствуют о том, что предприятие-заемщик некредитоспособно.

Сформирована репрезентативная выборка, содержащая 125 предприятий сферы МСП Краснодарского края и данных в Excel. С применением фильтров для распределения предприятий по отраслям и основному виду деятельности



Рис. 6. Показатели комплексной оценки ФЭС и кредитоспособности МСП

Fig. 6. Indicators for a comprehensive assessment of the financial and economic condition and creditworthiness of borrowers (SMEs)



(согласно классификации ОКВЭД) были учтены дополнительные данные об их деятельности (ИНН, размер предприятия и критерии отнесения к субъекту МСП, присутствие в Реестре МСП, дата регистрации и ликвидации).

С применением макросов Excel были созданы алгоритмы для расчетов финансовых показателей субъектов МСП и автоматического присвоения им баллов (рейтингов) от L до H . Конечная репрезентативная выборка содержала результаты 35 расчетных показателей ФЭС и кредитоспособности предприятий сферы МСП и присвоенные им рейтинги по пяти отраслям: обрабатывающее производство, сельское хозяйство, строительство, сфера торговли и сфера услуг.

Методом экспертных оценок показатели были дифференцированы на 9 групп (кластеров). Построены автоматизированные алгоритмы анализа количественных оценочных и интегральных показателей по выделенным группам (кластерам).

Кратко приведем методику применения главных компонент для экспресс-диагностики ФЭС и прогнозирования уровня кредитоспособности МСП.

Каждое из наблюдений группы показателей 1–9 заменено векторами $F_i = (f_i^{(1)}, f_i^{(2)}, \dots, f_i^{(p)})$ с существенно меньшим, чем p , числом компонент p' для того, чтобы система новых показателей сохранила в себе существенную часть информации, содержащейся в исходном массиве данных. Была найдена матрица собственных векторов корреляционной матрицы предикторов L , а также матрица собственных чисел λ .

С учетом свойств главных компонент был определен критерий информативности, послуживший базисом для принятия решения о снижении количества показателей в исследуемом пространстве:

$$J_F^{(p')} = \frac{\lambda_1 + \lambda_2 + \dots + \lambda_{p'}}{\lambda_1 + \lambda_2 + \dots + \lambda_p} > 50\%.$$

Матрица нагрузок главных компонент A определяется по формуле

$$A = L^T \lambda^{1/2}, \quad (12)$$

где L – матрица собственных векторов корреляционной матрицы предикторов; λ – матрица собственных чисел.

Коэффициенты матрицы нагрузок определяют степень тесноты парной линейной связи между главными компонентами и удельный вес

влияния главных компонент на исследуемый признак. Для определения меры связи главных компонент и исследуемого признака были выбраны элементы матрицы нагрузок $|a_{ij}| > 0,6$.

Результаты применения метода главных компонент для групп 1–9 показали, что полученная система 35 линейно-независимых показателей наиболее соответствует процессу дальнейшего моделирования.

На этапах 2–5 была сформирована архитектура программы искусственного интеллекта, включающая 10 нечетких продукционных систем (НПС) для проведения экспресс-диагностики ФЭС и прогнозирования кредитоспособности заемщиков (предприятий сферы МСП). НПС (1REG – 9FIN) представляют собой функциональные зависимости влияющих факторов от независимых переменных системы:

$$X = (x_1, x_2, \dots, x_{35}) \rightarrow (y_1, y_2, \dots, y_9) \rightarrow Y, \quad (13)$$

где x_1, \dots, x_{35} – входные переменные модели; y_1, \dots, y_9 – интегральные рейтинги по группам 1–9, рассчитываемые на основе созданных НПС 1REG – 9FIN; Y – итоговый интегральный рейтинг ФЭС и кредитоспособности МСП региона (НПС 10REZULT).

Результатом работы 9 НПС являются рейтинги и их лингвистические значения для 9 интегральных показателей.

На основе последних в НПС 10REZULT рассчитываются общая интегральная оценка ФЭС и уровень кредитоспособности заемщика из сферы МСП. Качественным и количественным значениям 35 показателей программа присваивает рейтинги от 0 до 1. Для расчета интегрального показателя действует следующий принцип: если значение интегрального показателя близко к 1, то ФЭС предприятия и уровень кредитоспособности МСП оценивается как отличные, с уменьшением общего интегрального рейтинга уровень ФЭС и кредитоспособности снижается. При получении рейтинга общего интегрального показателя, равного 0,06, предприятие-заемщик идентифицируется как с высоким риском банкротства.

С применением разработанных НПС была получена адекватная система интегральной оценки комплексных показателей ФЭС и уровня кредитоспособности и для производственных, строительных и сельскохозяйственных предприятий, а также предприятий сферы торговли и сферы услуг сектора МСП. Процесс нечеткого моделирования ФЭС и уровня кредитоспособности МСП был реализован в среде MATLAB



с помощью пакета Fuzzy Logic Toolbox. Для построения НПС в программе ЭВМ AIFin Expert применялся алгоритм Мамдани.

Для автоматизации расчетов была разработана программа ЭВМ «Система интеллек-

туального анализа финансово-экономического состояния МСП на основе искусственного интеллекта AIFin Expert» (свидетельство гос. регистрации для программы ЭВМ № 2020612570 от 26.02.2020) (рис. 7).

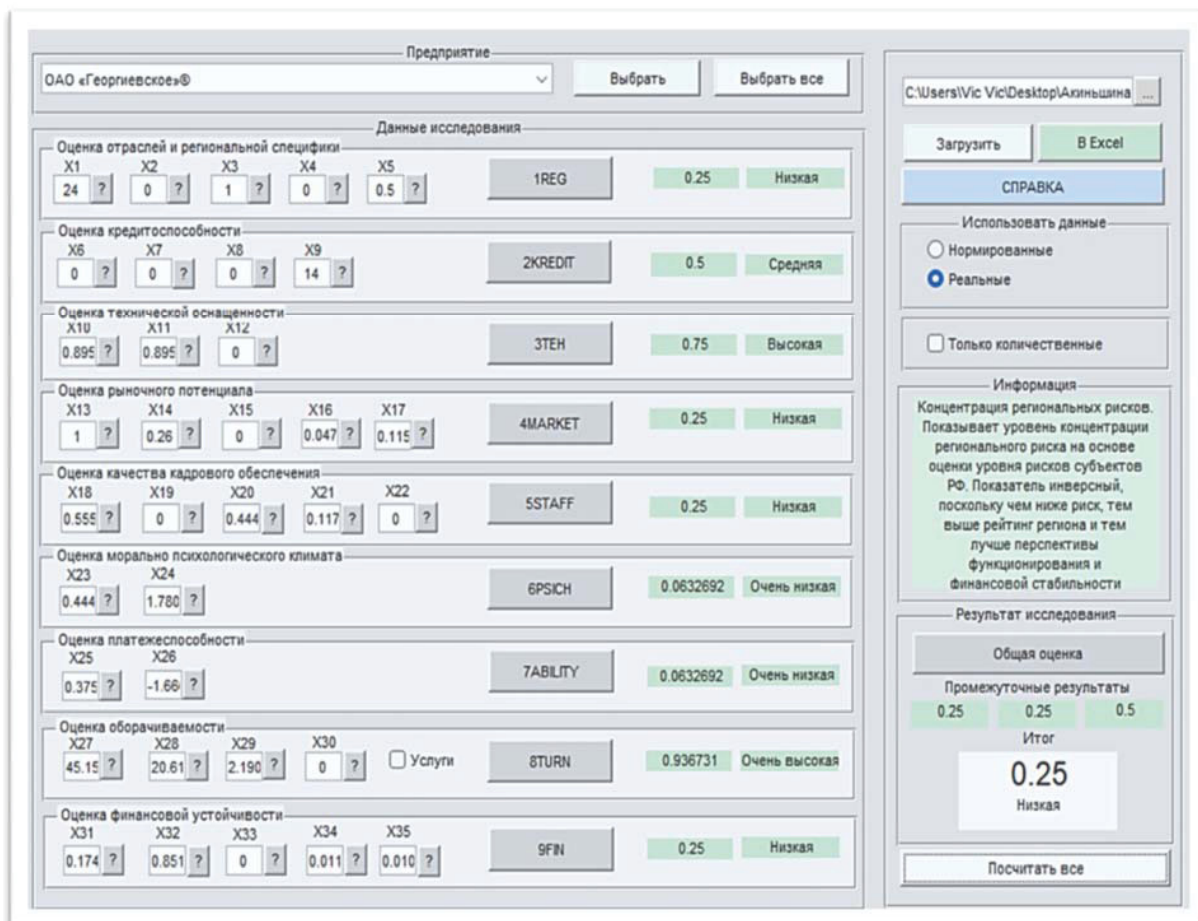


Рис. 7. Интерфейс программы ЭВМ AIFin Expert
Fig. 7. Interface of the computer program AIFin Expert

На основе 35 показателей программа ЭВМ позволяет:

- осуществлять интеллектуальный анализ ФЭС субъектов МСП, учитывающий их отраслевую специфику;
- производить автоматизированный расчет интегральных показателей и проверку достоверности результатов и их экспертной (балльно-рейтинговой) оценки;
- автоматически рассчитывать общий интегральный результат ФЭС предприятия и определять класс его кредитоспособности («очень высокая», «высокая», «средняя», «низкая», «очень низкая»);

– отображать промежуточные и итоговые оценки и осуществлять экспорт результатов анализа данных в Excel-файл.

Программа ЭВМ ориентирована на микро-, малые и средние предприятия и финансовых посредников (коммерческие банки и микрофинансовые организации).

Предложенный методологический подход и программа ЭВМ были апробированы на предприятиях, входящих в созданную базу данных «Межотраслевая база данных малых и средних предприятий Краснодарского края» (среда разработки Microsoft Access 2019) (свидетельство гос. регистрации базы данных № 2021623214 от 27.12.2021.).



Практические результаты экспресс-диагностики ФЭС и прогнозирования уровня кредитоспособности 22 сельскохозяйственных микро-, малых и средних предприятий Краснодарского края представлены на рис. 8. Как видно из представленного ниже рис. 8, а, за период с 2014 по 2017 гг. из 22 проанализированных предприятий учет качественно-количественных показателей привел к росту доли сельскохозяйственных предприятий сферы МСП с высоким кредитным рейтингом ФЭС и кредитоспособности на 10,4%, к снижению со

средним рейтингом – на 10,9%. Доля некредитоспособных субъектов МСП с низким кредитным рейтингом практически не изменилась. Свыше 4% предприятий обанкротились. Доля кредитоспособных предприятий в сельском хозяйстве в 2014 г. – 45,5%, 2015 г. – 41,0%, 2016 г. – 42,9%, 2017 г. – 45,0%. Учет факторов региональной и отраслевой специфики (группа 1) и качества кредитной истории (группа 2) повлиял на снижение кредитного рейтинга в 2014 г. у 27,4% МСП, в 2015 г. – у 0,1%, в 2016 г. – у 4,2%, в 2017 г. – у 5,0%.




Рис. 8. Динамика изменения кредитного рейтинга сельскохозяйственных МСП (заемщиков или получателей государственной финансовой поддержки) за 2014–2017 гг.: а – с учетом качественных и количественных показателей; б – с учетом только количественных показателей, % (рассчитано в программе ЭВМ AIFin Expert) (цвет онлайн)
Fig. 8. Dynamics of changes in agricultural credit ratings SMEs (borrowers or recipients of state financial support) for 2014–2017: а – considering qualitative and quantitative indicators; б – considering only quantitative indicators, % (calculated in a computer program AIFin Expert) (color online)



Программа ЭВМ смогла корректно диагностировать уровень ФЭС для 21 сельскохозяйственного МСП (табл. 2). При этом программой ЭВМ было корректно определено банкротство ОАО «Агроинвестсоюз» и идентифицирован высокий риск банкротства для

ООО «Витязевская птицефабрика». В 2015 г. ошибочно было идентифицировано лишь предприятие – ООО «Альтернатива», программа ЭВМ не смогла выявить некредитоспособность предприятия и факт его фактического банкротства.

Таблица 2 / Table 2

Результаты диагностики кредитоспособности сельскохозяйственных МСП Краснодарского края с использованием AIFin Expert за период 2014–2017 гг. (с учетом качественно-количественных показателей (ККП) и без учета качественных показателей (КП))
Diagnostics results concerning the agricultural Krasnodar krai SMEs' creditworthiness using AIFin Expert for the period 2014–2017 (considering qualitative and quantitative indicators and without taking qualitative indicators into account)

Предприятие	2014		2015		2016		2017		Год наступления риска / Дата банкротства
	С учетом ККП	Без учета КП	С учетом ККП	Без учета КП	С учетом ККП	Без учета КП	С учетом ККП	Без учета КП	
АО АК «Михайловский перевал»	0,5	0,5	0,25	0,25	0,25	0,25	0,5	0,5	
ОАО «Георгиевское»	0,25	0,25	0,25*	0,5*	0,25	0,25	0,25	0,25	
ОАО Имени Карла Маркса	0,5*	0,75*	0,5	0,5	0,25	0,25	0,25	0,25	
ООО «Лотос»	0,5*	0,75*	0,5*	0,75*	0,5*	0,75*	0,75	0,75	
ООО «Кавказ»	0,5*	0,75*	0,5*	0,75*	0,5*	0,75*	0,5*	0,75*	
ООО «СП ИНДУСТРИАЛ-ФЕРМЕР»	0,5*	0,75*	0,75	0,75	0,75	0,75	0,75	0,75	
ООО «Выселковский рыбхоз»	0,5	0,5	0,5	0,5	0,5	0,5	0,25	0,25	
ОАО «Витязево»	0,25**	0,06**	0,25	0,25	0,25	0,25	0,25	0,25	Риск банкротства – 2014
ОАО «Агроинвестсоюз»	0,25*	0,5	0,25*	0,5*	0,06	0,06	–	–	21.11.2016
АО «Агро-ресурсы»	0,25	0,25	0,25	0,25	0,25	0,25	0,25	0,25	
АО «Россия»	0,25	0,25	0,25*	0,5*	0,25*	0,5*	0,25*	0,5*	
ООО «Родина»	0,5*	0,75*	0,75	0,75	0,5	0,5	0,75	0,75	
ООО «Золотая осень Кубани»	0,25	0,25	0,25	0,25	0,25	0,25	0,25	0,25	
ООО «Витязевская птицефабрика»	0,25	0,25	0,25	0,25	0,25**	0,06**	0,25**	0,06**	Риск банкротства 2016–2017
АО «Агро-центр «Пшадра»»	0,25	0,25	0,25	0,25	0,25	0,25	0,25	0,25	
ОАО «Воронцовское»	0,5	0,5	0,5	0,5	0,75	0,75	0,5	0,5	
АО «Знамя Октября»	0,25	0,25	0,25	0,25	0,5	0,5	0,5	0,5	
АО «Колхоз «Прогресс»»	0,5*	0,75*	0,75	0,75	0,75	0,75	0,5	0,5	
АО «Нива»	0,75	0,75	0,75	0,75	0,5	0,5	0,5	0,5	
ООО «Альтернатива»	0,25	0,25	0,25***	0,25***	–	–	–	–	13.08.2015
ООО «Аргус»	0,25	0,25	0,25	0,25	0,25	0,25	0,25	0,25	
ООО «ДЦК»	0,25	0,25	0,25	0,25	0,25	0,25	0,25	0,25	

Примечание. * – выделены предприятия, на кредитный рейтинг которых оказали влияние качественные показатели; ** – предприятия, у которых корректно спрогнозирован риск банкротства; *** – выделено предприятие, для которого искусственный интеллект не смог корректно определить риск банкротства. Рассчитано в программе ЭВМ AIFin Expert.

Note. * – enterprises whose creditworthiness was influenced by qualitative indicators; ** – enterprises whose bankruptcy risk was correctly forecasted; *** – enterprise for which AI could not forecast bankruptcy risk correctly. Calculated in the computer program AIFin Expert.



Предложенный комплексный подход экспресс-диагностики ФЭС и прогнозирования уровня кредитоспособности был применен для субъектов МСП в сфере торговли, услуг, обрабатывающем производстве, сельском хозяйстве и строительстве Краснодарского края и может быть без изменений применен для МСП в других субъектах Российской Федерации. По результатам проведенного исследования для 125 МСП Краснодарского края за 2014–2017 гг. было определено, что наибольшее влияние качественных показателей на интегральный кредитный рейтинг заемщика (субъекта МСП) было свойственно предприятиям отрасли сельского хозяйства и сферы торговли Краснодарского края.

В целом результаты апробации показали, что предложенный методологический подход с достоверностью 96% позволил определить реальное финансово-экономическое состояние и построить интегральный рейтинг класса кредитоспособности субъектов МСП.

Результаты

По результатам проведения теоретического анализа и систематизации основных математических методов и моделей диагностики и прогнозирования кредитоспособности показано, что наиболее распространенными (классическими) методами, применяемыми к оценке кредитоспособности заемщиков из сферы МСП, являются модели, основанные на методах статистического анализа. Среди современных (альтернативных) методов машинного обучения широкое применение в этой области нашли искусственные нейронные сети. При этом, в отличие от классических подходов, нейросети показывают более высокую точность оценки и прогнозирования данных, что способствует повышению качества принятия управленческих решений при кредитовании МСП и кредитном скоринге заемщиков.

К новейшим методам, обладающим высокой прогностической способностью для диагностики и долгосрочного прогнозирования кредитоспособности субъектов МСП с учетом их отраслевой принадлежности и региональной специфики, можно смело отнести интеллектуальные и гибридные информационные системы, метод опорных векторов, нечеткие множественные и нечеткие продукционные системы, а также метод

«случайного леса». Их комбинация с другим позволит достичь синергетического эффекта при взаимодействии кредиторов с заемщиками из сферы МСП.

Заключение

В современных конкурентных условиях деятельность предприятий сектора МСП РФ связана с повышенными рисками, обусловленными усложнением геополитической обстановки и другими макроэкономическими факторами, что требует разработки новых системных и комплексных подходов к оценке, диагностике и прогнозированию кредитоспособности МСП, базирующихся на применении комбинирования экономического анализа и различных методов искусственного интеллекта. Проведение такой оценки невозможно без учета отраслевой и региональной специфики этих предприятий и их изменяющихся кредитных потребностей.

Список литературы

1. *Abdou H. A., Pointon J.* Credit scoring, statistical techniques, and evaluation criteria: A review of the literature // *Intelligent Systems in Accounting, Finance & Management*. 2011. № 18. P. 59–88. <https://doi.org/10.1002/isaf.325>
2. *Леоненков А. В.* Нечеткое моделирование в среде MATLAB и fuzzyTECH. СПб. : БХВ Петербург, 2005. 736 с.
3. *Арутюнян А. С., Коваленко А. В., Уртенев М. Х.* Нейросетевые технологии финансово-экономического анализа : учеб. пособие. Ч. 3. Нейросетевые технологии. Краснодар : КубГТУ, 2015. 156 с. EDN: TNMJDX
4. *Buckley J., Feuring T., Eslami E.* Fuzzy Mathematics in Economics and Engineering. Physica-Varlag. Heidelberg Physica, 2002. 272 p. <https://doi.org/10.1007/978-3-7908-1795-9>
5. *Барановская Т. П., Кармазин В. Н., Уртенев М. Х., Коваленко А. В.* Современные математические методы анализа финансово-экономического состояния предприятия. Краснодар : КубГАУ, 2009. 235 с. EDN: TXJWKL
6. *Bojadziev G., Bojadziev M.* Fuzzy Logic for Business, Finance and Management. Singapore ; River Edge, NJ : World Scientific, 1997. 232 p. (Advances in Fuzzy Systems. Vol. 12). <https://doi.org/10.1142/3312>
7. *Zopoundisis C., Doumpou M.* Multi-group discrimination using multi-criteria analysis: Illustrations from the field of finance // *European Journal of Operational Research*. 2002. Vol. 139, iss. 2. P. 371–389. [https://doi.org/10.1016/s0377-2217\(01\)00360-5](https://doi.org/10.1016/s0377-2217(01)00360-5)



8. *Иванищев М. В.* Разработка нечетко-численного метода прогнозирования и обеспечения устойчивости предприятия в условиях неопределенности: дис. ... канд. экон. наук. М., 2002. 138 с.
9. *Луценко Е. В., Коваленко А. В., Печурина Е. К., Уртенев М. А. Х.* Открытая персональная интеллектуальная технология разработки и применения адаптивных методик оценки инвестиционной привлекательности и кредитоспособности предприятий // Вестник Пермского университета. Сер. «Экономика» = Perm University Herald. Economy. 2019. Т. 14, № 1. С. 20–50. <https://doi.org/10.17072/1994-9960-2019-1-20-50>, EDN: NUHJG
10. *Недосекин А. О.* Методологические основы моделирования финансовой деятельности с использованием нечетко-множественных описаний : дис. ... д-ра экон. наук. СПб., 2003. 302 с.
11. *Thomas L. C.* A survey of credit and behavioral scoring: Forecasting financial risk of lending to consumers // *International Journal of Forecasting*. 2000. Vol. 16, iss. 2. P. 149–172. [https://doi.org/10.1016/S0169-2070\(00\)00034-0](https://doi.org/10.1016/S0169-2070(00)00034-0)
12. *Маккаллоу У., Питтс В.* Логические исчисления идей, относящихся к нервной деятельности // *Автоматы* : сб. ст. / под ред. К. Э. Шеннона, Дж. Маккарти ; пер. с англ. под ред. А. А. Ляпунова М. : Иностранная литература, 1956. С. 363–384.
13. *Xiao-Lin L., Zhong Yu.* An Overview of Personal Credit Scoring: Techniques and Future Work // *International Journal of Intelligence Science*. 2012. Vol. 2. P. 181–189. <https://doi.org/10.4236/ijis.2012.224024>
14. *Ciampi F., Gordini N.* Small enterprise default prediction modeling through artificial neural networks: An empirical analysis of Italian small enterprises // *Journal of Small Business Management*. 2013. Vol. 51, iss. 1. P. 23–45. <https://doi.org/10.1111/j.1540-627X.2012.00376.x>
15. *Giannopoulos V., Aggelopoulos E.* Predicting SME loan delinquencies during recession using accounting data and SME characteristics: The case of Greece // *Intelligent Systems in Accounting, Finance and Management*. 2019. Vol. 26, iss. 2. P. 71–82. <https://doi.org/10.1002/isaf.1456>
16. *Oliveira M. D. N. T., Ferreira F. A. F., Pérez-Bustamante Ilander G. O., Jalali M. S.* Integrating cognitive mapping and MCDA for bankruptcy prediction in small-and medium-sized enterprises // *Journal of the Operational Research Society*. 2017. Vol. 68, iss. 9. P. 985–997. <https://doi.org/10.1057/s41274-016-0166-3>
17. *Kim H. S., Sohn S. Y.* Support vector machines for default prediction of SMEs based on technology credit // *European Journal of Operational Research*. 2010. Vol. 201, iss. 3. P. 838–846. <https://doi.org/10.1016/j.ejor.2009.03.036>
18. *Abdou H. A.* Genetic programming for credit scoring: The case of Egyptian public sector banks // *Expert Systems with Applications*. 2009. Vol. 36, iss. 9. P. 11402–11417. <https://doi.org/10.1016/j.eswa.2009.01.076>
19. *Ong C. S., Huang J. J., Tzengb G. H.* Building Credit Scoring Models Using Genetic Programming // *Expert Systems with Applications*. 2005. Vol. 29, no. 1, pp. 41–47. <https://doi.org/10.1016/j.eswa.2005.01.003>
20. *Breiman L., Friedman J., Olshen R. A., Stone C. J.* Classification and regression trees. Monterey, CA : Wadsworth & Brooks/Cole Advanced Books & Software, 1984. 358 p. <https://doi.org/10.1201/9781315139470>
21. *Lee S., Choi K., Yoo D.* Predicting the Insolvency of SMEs Using Technological Feasibility Assessment Information and Data Mining Techniques // *Sustainability*. 2020. Vol. 12, iss. 23. Art. 9790. <https://doi.org/10.3390/su12239790>
22. *Федорова Е. А., Мусиенко С. О., Федоров Ф. Ю.* Прогнозирование банкротства субъектов малого и среднего предпринимательства в России // *Финансы и кредит*. 2018. Т. 24, вып. 11 (779). С. 2537–2552. <https://doi.org/10.24891/fc.24.11.2537>, EDN: YOVLZZ
23. *Brezigar-Masten A., Masten I.* CART-based selection of bankruptcy predictors for the logit model // *Expert Systems with Applications*. 2012. Vol. 39, iss. 11. P. 10153–10159. <https://doi.org/10.1016/j.eswa.2012.02.125>
24. *Zadeh L. A.* Fuzzy Sets // *Information and Control*. 1965. Vol. 8. P. 338–353. [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X)
25. *Yazdi A. K., Hanne T., Wang Y. J., Wee H.* A Credit Rating Model in a Fuzzy Inference System Environment // *Algorithms*. 2019. Vol. 12, iss. 7. P. 1–15. <https://doi.org/10.3390/a12070139>
26. *Заболоцкая В. В.* Финансово-кредитное обеспечение деятельности субъектов малого предпринимательства в России и за рубежом. Краснодар : КубГУ, 2013. 207 с. EDN: UYUEZB
27. *Шевченко И. В., Кармазин А. В., Коваленко А. В.* Комплексная оценка кредитоспособности предприятия малого и среднего бизнеса с помощью нечеткой продукционной системы // *Финансовая аналитика. Проблемы и решения*. 2008. № 2 (2). С. 81–86. EDN: ICKFDB
28. *Ендророва В. Н., Хасянова С. Ю.* Модели анализа кредитоспособности заемщиков // *Финансы и кредит*. 2002. № 6 (96). С. 9–15.
29. *Balcaen S., Ooghe H.* Alternative methodologies in studies on business failure: Do they produce better results than the classical statistical methods? // *Vlerick Leuven Gent Management School Working Paper Series (16)*. Vlerick Leuven Gent Management School, 2004, pp. 1–44.

References

1. *Abdou H. A., Pointon J.* Credit scoring, statistical techniques, and evaluation criteria: A review of the literature. *Intelligent Systems in Accounting, Finance & Management*, 2011, no. 18, pp. 59–88. <https://doi.org/10.1002/isaf.325>



2. Leonenkov A. V. *Nechetkoe modelirovanie v srede MATLAB i fuzzyTECH* [Fuzzy modeling in MATLAB and fuzzyTECH]. St. Petersburg, BHV Peterburg, 2005. 736 p. (in Russian).
3. Arutyunyan A. S., Kovalenko A. V., Urtenov M. Kh. *Neyrosetevye tekhnologii finansovo-ekonomicheskogo analiza. Ch. 3. Neyrosetevye tekhnologii* [Neural network technologies for financial and economic analysis. Part 3. Neural network technologies]. Krasnodar, Kuban State Technological University Publ., 2015. 156 p. (in Russian).
4. Buckley J., Feuring T., Eslami E. *Fuzzy Mathematics in Economics and Engineering*. Physica-Verlag, Heidelberg Physica, 2002. 272 p. <https://doi.org/10.1007/978-3-7908-1795-9>
5. Baranovskaya T. P., Karmazin V. N., Utrenov M. Kh., Kovalenko A. V. *Sovremennye matematicheskie metody analiza finansovo-ekonomicheskogo sostoyaniya predpriyatiya* [Modern mathematical methods for analyzing the financial and economic state of an enterprise]. Krasnodar, KubSAU Publ., 2009. 235 p. (in Russian). EDN: TXJWKL
6. Bojadziev G., Bojadziev M. *Fuzzy Logic for Business, Finance and Management*. Advances in fuzzy systems. Vol. 12. Singapore, River Edge, NJ, World Scientific, 1997. 232 p. <https://doi.org/10.1142/3312>
7. Zopoundisis C., Doumpos M. Multi-group discrimination using multi-criteria analysis: Illustrations from the field of finance. *European Journal of Operational Research*, 2002, vol. 139, iss. 2, pp. 371–389. [https://doi.org/10.1016/S0377-2217\(01\)00360-5](https://doi.org/10.1016/S0377-2217(01)00360-5)
8. Ivanishchev M. V. *Development of a fuzzy-numerical method for forecasting and ensuring enterprise sustainability under conditions of uncertainty*. Diss. Cand. Sci. (Econ.). Moscow, 2002. 138 p. (in Russian).
9. Lutsenko E. V., Kovalenko A. V., Pechurina E. K., Urtenov M. A. H. Open personal intellectual technology for development and application of adaptive methods of assessment of investment attractiveness and creditworthiness of enterprises. *Vestnik Permskogo universiteta. Seria Ekonomika* [Perm University Herald. Economy], 2019, vol. 14, no. 1, pp. 20–50 (in Russian). <https://doi.org/10.17072/1994-9960-2019-1-20-50>, EDN: NUHIJG
10. Nedosekin A. O. *Methodological basis for modeling financial activities using fuzzy set descriptions*. Diss. Dr. Sci. (Econ.). St. Petersburg, 2003. 302 p. (in Russian).
11. Thomas L. C. A survey of credit and behavioral scoring: Forecasting Financial risk of lending to consumers. *International Journal of Forecasting*, 2000, vol. 16, iss. 2, pp. 149–172. [https://doi.org/10.1016/S0169-2070\(00\)00034-0](https://doi.org/10.1016/S0169-2070(00)00034-0)
12. McCulloch W. S., Pitts W. A logical calculus of the ideas immanent in nervous activity. In: Shannon C. E., McCarthy J. (eds.) *Automata studies*. Princeton, NJ, Princeton University Press, 1956. (Russ. ed.: Moscow, Ill, 1956, pp. 363–384).
13. Xiao-Lin L., Zhong Yu. An overview of personal credit scoring: Techniques and future work. *International Journal of Intelligence Science*, 2012, vol. 2, pp. 181–189. <https://doi.org/10.4236/ijis.2012.224024>
14. Ciampi F., Gordini N. Small enterprise default prediction modeling through artificial neural networks: An empirical analysis of Italian small enterprises. *Journal of Small Business Management*, 2013, vol. 51, iss. 1, pp. 23–45. <https://doi.org/10.1111/j.1540-627X.2012.00376.x>
15. Giannopoulos V., Aggelopoulos E. Predicting SME loan delinquencies during recession using accounting data and SME characteristics: The case of Greece. *Intelligent Systems in Accounting, Finance and Management*, 2019, vol. 26, iss. 2, pp. 71–82. <https://doi.org/10.1002/isaf.1456>
16. Oliveira M. D. N. T., Ferreira F. A. F., Pérez-Bustamante Ilander G. O., Jalali M. S. Integrating cognitive mapping and MCDA for bankruptcy prediction in small-and medium-sized enterprises. *Journal of the Operational Research Society*, 2017, vol. 68, iss. 9, pp. 985–997. <https://doi.org/10.1057/s41274-016-0166-3>
17. Kim H. S., Sohn S. Y. Support vector machines for default prediction of SMEs based on technology credit. *European Journal of Operational Research*, 2010, vol. 201, iss. 3, pp. 838–846. <https://doi.org/10.1016/j.ejor.2009.03.036>
18. Abdou H. A. Genetic programming for credit scoring: The case of Egyptian public sector banks. *Expert Systems with Applications*, 2009, vol. 36, iss. 9, pp. 11402–11417. <https://doi.org/10.1016/j.eswa.2009.01.076>
19. Ong C. S. Huang J. J., Tzeng G. H. Building Credit Scoring Models Using Genetic Programming. *Expert Systems with Applications*, 2005, vol. 29, iss. 1, pp. 41–47. <https://doi.org/10.1016/j.eswa.2005.01.003>
20. Breiman L., Friedman J., Olshen R. A., Stone C. J. *Classification and regression trees*. Monterey, CA, Wadsworth & Brooks / Cole Advanced Books & Software, 1984. 358 p. <https://doi.org/10.1201/9781315139470>
21. Lee S., Choi K., Yoo D. Predicting the Insolvency of SMEs Using Technological Feasibility Assessment Information and Data Mining Techniques. *Sustainability*, 2020, vol. 12, iss. 23, art. 9790. <https://doi.org/10.3390/su12239790>
22. Fedorova E. A., Musienko S. O., Fedorov F. Yu. Prediction of bankruptcy of small and medium-sized business entities in Russia. *Finance & Credit*, 2018, vol. 24, iss. 11 (779), pp. 2537–2552 (in Russian). <https://doi.org/10.24891/fc.24.11.2537>, EDN: YOVLZZ
23. Brezigar-Masten A., Masten I. CART-based selection of bankruptcy predictors for the logit model. *Expert Systems with Applications*, 2012, vol. 39, iss. 11, pp. 10153–10159. <https://doi.org/10.1016/j.eswa.2012.02.125>
24. Zadeh L. A. Fuzzy Sets. *Information and Control*, 1965, vol. 8, pp. 338–353. [http://dx.doi.org/10.1016/S0019-9958\(65\)90241-X](http://dx.doi.org/10.1016/S0019-9958(65)90241-X)



25. Yazdi A. K., Hanne T., Wang Y. J., Wee H. A Credit Rating Model in a Fuzzy Inference System Environment. *Algorithms*, 2019, vol. 12, iss. 7, pp. 1–15. <https://doi.org/10.3390/a12070139>
26. Zabolotskaya V. V. *Finansovo-kreditnoe obespechenie deyatel'nosti sub'ektov malogo predprinimatel'stva v Rossii i za rubezhom* [Financial and credit support for the activities of small businesses in Russia and abroad]. Krasnodar, Kuban State Technological University Publ., 2013. 207 p. (in Russian). EDN: UYUEZB
27. Shevchenko I. V., Karmazin A. V., Kovalenko A. V. Assessing the creditworthiness of a small and medium-sized business using a fuzzy production system. *Financial Analytics. Problems and Solutions*, 2008, no. 2 (2), pp. 81–86. EDN: ICKFDB
28. Endronova V. N., Khasyanova. S. Yu. Models for analyzing the creditworthiness of borrowers. *Finance & Credit*, 2002, no. 6 (96), pp. 9–15 (in Russian).
29. Balcaen S., Ooghe H. Alternative methodologies in studies on business failure: Do they produce better results than the classic statistical methods? *Vlerick Leuven Gent Management School Working Paper Series* (16). Vlerick Leuven Gent Management School, 2004, pp. 1–44.

Поступила в редакцию 07.05.2024; одобрена после рецензирования 08.06.2024;
принята к публикации 10.06.2024; опубликована 30.08.2024

The article was submitted 07.05.2024; approved after reviewing 08.06.2024;
accepted for publication 10.06.2024; published 30.08.2024