

Федеральное государственное автономное образовательное

учреждение высшего образования

«Национальный исследовательский университет

«Высшая школа экономики»

*На правах рукописи*

Афанасьев Владислав Викторович

**ИСПОЛЬЗОВАНИЕ НЕФИНАНСОВОЙ ИНФОРМАЦИИ ДЛЯ  
ПРЕДСКАЗАНИЯ НЕПЛАТЕЖЕСПОСОБНОСТИ ПРЕДПРИЯТИЙ  
СФЕРЫ УСЛУГ**

**РЕЗЮМЕ**

диссертации на соискание ученой степени  
кандидата экономических наук

Научный руководитель:  
к.э.н., доцент  
Ичкитидзе Юрий Роландович

JEL: G21, G32, G33, C10, C50

Москва – 2024

## Постановка проблемы и актуальность исследования

Сфера услуг является одним из основных секторов экономики Российской Федерации. По данным World Bank,<sup>1</sup> в 2022 году на услуги приходилось 54% ВВП России. На сегодняшний день нет единого определения сектора услуг. В данном исследовании к сектору услуг отнесены фирмы следующих отраслей:

- Туризм, размещение и услуги пассажирского транспорта;
- Общественное питание;
- Образование;
- Медицинские и социальные услуги;
- Услуги культуры, спорта и развлечений;
- Жилищно-коммунальные услуги;
- Финансовые услуги;
- Прочие услуги (персональные услуги, ветеринарные услуги, услуги по ремонту и т. д.).

Необходимость точного прогнозирования неплатежеспособности особенно актуальна для сектора услуг. Фирмы сферы услуг формируют значительную долю дел о банкротстве (около 10% по данным статистики Федресурса за 2022 год) и, имея в среднем меньше активов, подлежащих реализации в случае банкротства, являются более рискованными для кредиторов. Доля долгов, которая выплачивается кредиторам во время процедур банкротства в секторе услуг, очень низкая, например, в 2019 году она составляла всего 3,4%. Таким образом, прогнозирование неплатежеспособности для фирм сферы услуг может представлять интерес для кредитных организаций и участников рынка услуг.

---

<sup>1</sup> World Bank data. Services, value added (% of GDP). URL: <https://data.worldbank.org/indicator/NV.SRV.TOTL.ZS> Accessed 10.08.2023

Одним из способов устранения неопределенности в отношении кредитного риска компаний является использование моделей вероятностного прогнозирования неплатежеспособности (дефолта, банкротства). Традиционно, такие модели основываются на финансовых данных. Начиная с 1960-х годов прошлого века исследователи предлагали различные вероятностные модели, основанные на анализе финансовых коэффициентов компаний. Большинство из них использовали статистические методы, такие как MDA (множественный дискриминантный анализ) (Altman, 1968), логистическая регрессия (Gruszczyński, 2004; Hunter and Isachenkova, 2001; Ohlson, 1980; Sirirattanaphonkun and Pattarathammas, 2012), или машинное обучение (Altman *et al.*, 1994; Cao *et al.*, 2020; Coats and Fant, 1993; Odom and Sharda, 1990; Ravi Kumar and Ravi, 2007; Zhang *et al.*, 1999). Такие модели по-прежнему широко используются для оценки кредитного риска.

В большинстве предыдущих исследований прогнозная точность составляет 80% и выше (модели верно классифицируют 80 и более процентов компаний) (Altman, 1968; Sirirattanaphonkun and Pattarathammas, 2012). Однако существуют предпосылки, позволяющие утверждать, что существующие инструменты оценки кредитного риска могут оказаться неподходящими для фирм сферы услуг в России.

Согласно оценке, представленной агентством World Economics<sup>2</sup>, около 38% российского ВВП формируется теневой экономикой. Это означает, что финансовые коэффициенты для некоторых фирм могут быть необъективными, если такие фирмы комбинируют «белую» и «серую» деятельность. Кроме того, многие предприятия в секторе услуг могут быть представлены в виде групп компаний, в том числе индивидуальных предпринимателей (не предоставляющих финансовую отчетность),

---

<sup>2</sup> World Economics data. URL: <https://www.worldeconomics.com/Informal-Economy/>

компаний с ограниченной ответственностью (на различных налоговых режимах) и т. д. Наконец, только в отношении очень небольшого числа фирм проводится аудит отчетности, что потенциально может приводить к ошибкам в отчетности. Таким образом, финансовые данные, полученные по отдельно взятым юридическим лицам, могут не отражать реального состояния бизнеса, поэтому традиционный подход к прогнозированию неплатежеспособности может дать неудовлетворительные результаты.

Одним из способов повышения качества прогнозирования неплатежеспособности является разработка отраслевых моделей, подобных тем, которые были предложены в нескольких исследованиях (Costa *et al.*, 2022; Kanarickienė *et al.*, 2023; Psillaki *et al.*, 2010; Situm, 2023; Давыдова and Беликов, 1999) для устранения влияния отраслевых особенностей. Данное исследование фокусируется на секторе услуг.

Однако, что более важно, есть способ минимизировать влияние необъективности финансовых данных на качество моделей прогнозирования неплатежеспособности, включая нефинансовые переменные в модели.

В последние годы был проведен ряд исследований в этой области (см. например Altman *et al.*, 2010, 2016; Blanco-Oliver *et al.*, 2016) и было обнаружено, что использование нефинансовых переменных, таких как, например, сумма исков в арбитражный суд или информация из аудиторских отчетов, позволяет более точно прогнозировать неплатежеспособность. Таким образом, использование нефинансовой информации представляется ценной доработкой существующих моделей, полезной с точки зрения точности прогнозов.

Подводя итог, можно сказать, что использование традиционного подхода к прогнозированию неплатежеспособности (с использованием исключительно финансовых данных) может привести к низкой точности для российских фирм, поэтому для получения более точных моделей имеет

смысл использовать нефинансовые данные. Таким образом, в исследовании поднимаются следующие исследовательские вопросы:

RQ1: "Насколько значительным может быть улучшение качества прогнозирования неплатежеспособности фирм сферы услуг, если в моделях использовать нефинансовые данные?"

RQ2: "Какие нефинансовые факторы наиболее существенно повышают качество прогнозирования неплатежеспособности в сфере услуг?"

### **Объект и предмет исследования**

*Объектом* исследования являются модели прогнозирования неплатежеспособности для частных фирм, работающих в отраслях сферы услуг в России.

Объект изучается на *предмет* возможности увеличения точности прогнозирования неплатежеспособности путем использования нефинансовых данных наряду с финансовыми коэффициентами в качестве объясняющих факторов.

### **Цель и задачи исследования**

Цель этого исследования заключается в повышении точности моделей прогнозирования неплатежеспособности для российских частных фирм сферы услуг путем использования нефинансовых данных совместно с финансовыми коэффициентами для обеспечения принятия обоснованных инвестиционных решений контрагентами таких фирм и кредитными организациями.

Задачи исследования заключаются в следующем:

- исследовать существующие подходы к прогнозированию неплатежеспособности в российских и зарубежных исследованиях, включая традиционный подход (использование финансовых

коэффициентов для прогнозирования неплатежеспособности) и новый подход - использование нефинансовых данных для этой цели;

- подтвердить низкую способность финансовых коэффициентов предсказывать будущую неплатежеспособность российских частных фирм сферы услуг в сравнении с фирмами из развитых западных рынков или опровергнуть это заявление;
- разработать модели прогнозирования неплатежеспособности для избранных отраслей сферы услуг и подтвердить гипотезу о повышении качества прогнозов в случае использования нефинансовых данных наряду с финансовыми коэффициентами или опровергнуть ее;
- определить нефинансовые переменные, оказывающие наибольший эффект на точность прогнозирования неплатежеспособности;
- формализовать подход к сбору данных, применимый для исследований по прогнозированию неплатежеспособности, с точки зрения определения теоретической даты прогнозирования (даты, на которую должны рассчитываться значения независимых переменных);
- предложить подход к оценке качества моделей на основе анализа прогнозируемых вероятностей неплатежеспособности для каждого наблюдения (фирмы).

## **Краткий обзор литературы**

Истоки моделирования прогнозирования неплатежеспособности восходят к наиболее известным исследованиям 1960-х годов: (Beaver, 1966) и (Altman, 1968). Бивер впервые применил подход к оценке кредитного риска, основанный на использовании нормативных значений финансовых коэффициентов для оценки вероятности банкротства, в то время как Альтман разработал модель с использованием дискриминантного анализа

для прогнозирования банкротства публичных компаний. Несмотря на инновационность метода Бивера (особенно для середины прошлого века), в данном подходе не выводится единый показатель вероятности неплатежеспособности, что порождает проблемы интерпретации результатов. Модель Альтмана в свою очередь делит фирмы на три группы риска неплатежеспособности на основе пяти финансовых коэффициентов. Презентованная в исследовании точность этой модели - 95%. Однако критики модели Альтмана говорят о потенциальном смещении коэффициентов, обусловленном коррелированными независимыми переменными (Евстропов, 2008) и неприменимостью оригинальной модели к малым и средним фирмам из-за использования рыночной капитализации в составе одного из коэффициентов.

Джеймс Олсон (Ohlson, 1980) впервые использовал логистическую регрессию для прогнозирования неплатежеспособности, выявив шесть финансовых коэффициентов в качестве детерминантов неплатежеспособности для американских МСП. Другие ранние исследования - (Springate, 1978), (Zmijewski, 1984), (Blum, 1974), и (Deakin, 1972), в которых в том числе рассматриваются ошибки в формировании выборок для подобных исследований и выявляются ранние признаки неплатежеспособности.

В рамках традиционного подхода, в том числе в современных исследованиях (D'Amato and Mastrolia, 2022; Jandaghi et al., 2021; Zhao and Lin, 2023) к прогнозированию неплатежеспособности в качестве объясняющих переменных используются главным образом финансовые коэффициенты. Исследователи используют показатели, охватывающие 4 группы финансовых коэффициентов: рентабельность, ликвидность, структура капитала и оборачиваемость (Jaki and Ćwięk, 2021). (du Jardin, 2008) показал, что 93% исследований в данной области использовали

только финансовые показатели, и в изученных исследованиях представлена высокая точность таких моделей (достигает 98%).

Однако, традиционный подход может не подходить для российских фирм сферы услуг из-за таких проблем, как дробление бизнеса, теневые операции, мошенничество и ошибки в отчетности. Одним из возможных решений является включение нефинансовых данных в модели. В современных научных исследованиях включение нефинансовых данных в модели прогнозирования стало перспективной тенденцией. Например, Альтман (Altman *et al.*, 2010), один из родоначальников исследований в этой сфере, отмечает существенное улучшение качества моделей в сравнении с традиционным подходом.

Широкий спектр нефинансовых переменных может быть использован в моделях прогнозирования неплатежеспособности, выбор переменных ограничен только общей логикой и здравым смыслом. Например, (Blanco-Oliver *et al.*, 2016; Karminsky and Burekhin, 2019; Lugovskaya, 2010) используют возраст и размер фирм в качестве предиктора неплатежеспособности. Логика, лежащая в основе использования этих данных, заключается в том, что, согласно гипотезе, более мелкие фирмы имеют более высокий кредитный риск из-за меньшего объема активов, а более молодые фирмы, помимо этого обладают меньшим опытом присутствия на рынке. Возраст и размер - наиболее часто используемые нефинансовые факторы в такого рода исследованиях. (Bhimani *et al.*, 2013) сообщают о значительном увеличении площади под ROC-кривой при использовании макроэкономических переменных, информации о менеджменте и акционерах, финансовой поддержке наряду с финансовыми коэффициентами, предполагая, что финансовая поддержка, высокое качество управления и благоприятные макроэкономические условия должны снижать кредитный риск. (Altman *et al.*, 2010; Kanapickienė *et al.*, 2023), используют информацию о просрочках представления отчетности,



исходя из предположения о том, что фирма, просрочившая представление финансовой отчетности, испытывает трудности и является более рискованной. (Blanco-Oliver et al., 2016) используют данные об исках в арбитражный суд в качестве предиктора, предполагая, что фирма, которая сталкивается с большим количеством исков, имеет больше просроченных долгов. Некоторые исследователи (например, Makeeva and Sinilshchikova, 2020; Stevenson et al., 2021) используют анализ текстовых данных для прогнозирования неплатежеспособности, включая, например, тон заявления на выдачу кредита (Filomeni et al., 2024). Другой пример – использование метрик качества финансовой отчетности, как реализовано, например, в (Costa et al., 2022).

Использование нефинансовых данных в прогнозировании неплатежеспособности пока еще не получило широкого распространения, однако обнадеживающие результаты свидетельствуют о значительном повышении точности прогнозов. Например, (Altman et al., 2010) заявляют о 8% прироста в площади под ROC-кривой при использовании нефинансовых факторов, (Lugovskaya, 2010) заявляет о 16% прироста в общей точности модели, (Bhimani et al., 2013) заявляют о 21% прироста в площади под ROC-кривой и т. д. Это подчеркивает потенциал нефинансовых данных для дополнения финансовых показателей в моделях прогнозирования неплатежеспособности с целью повышения точности таких моделей.

## **Методология исследования**

*Эмпирическое исследование* состоит из следующих шагов, необходимых для ответа на исследовательские вопросы:

1. Проверка гипотезы о неприменимости традиционного подхода к прогнозированию неплатежеспособности (с использованием исключительно финансовых коэффициентов в качестве переменных) для российского сектора услуг путем сравнения точности моделей,

разработанных для российских фирм и фирм из развитых европейских рынков.

2. Тестирование использования нефинансовых данных с целью прогнозирования неплатежеспособности для отдельных отраслей сферы услуг: авторемонтных фирм, частных клиник, управляющих компаний ЖКХ, микрофинансовых организаций для оценки эффекта включения нефинансовых данных на точность моделей и выявления наиболее ценных переменных.

### *Эконометрические инструменты, используемые в исследовании*

Для построения моделей прогнозирования неплатежеспособности в исследовании используются три эконометрических инструмента - логистическая регрессия, метод ближайших соседей и случайный лес. Логистическая регрессия, часто используемый в подобных исследованиях метод линейной классификации, позволяет интерпретировать результаты, оценивая вклад каждой независимой переменной. Предсказанные результаты находятся в интервале от 0 до 1, таким образом, оцениваются "вероятности" наступления неплатежеспособности. В отличие от обычной линейной регрессии, ключевым допущением логистической регрессии является линейная зависимость между независимыми переменными и логарифмическими шансами ( $\log \text{odds}$ ) зависимой переменной.

Чаще всего наблюдения классифицируются на неплатежеспособные и здоровые, исходя из значения предсказанной вероятности, при этом порог отсечения вероятности обычно составляет 50%.

Для оценки коэффициентов регрессии используется метод максимального правдоподобия. Также, используется регуляризация типа L1 для контроля числа переменных.

Метод ближайших соседей, простой алгоритм классификации, классифицирует наблюдения на основе «сходства» с соседними точками

данных. Число соседей имеет решающее значение для точности и в рамках данного исследования устанавливается равным квадратному корню из количества наблюдений. «Сходство» определяется с помощью Евклидова расстояния. Процесс классификации включает в себя определение наиболее похожих фирм из тренировочного набора данных и определение наблюдения к той или иной группе на основе классов большинства из этих «соседей».

Случайный лес, выбранный за его высокую предсказательную точность и возможность оценки важности переменных, является ансамблем классификационных деревьев. Каждое дерево классифицирует наблюдения, и наиболее частый класс среди всех деревьев используется, как вывод модели. Деревья обучаются на случайно выбранных подмножествах (с повторениями) из тренировочного набора данных. Основная цель классификационного дерева заключается в разделении тренировочных данных таким образом, чтобы каждый лист дерева содержал только один класс наблюдений или доминирующую долю одного класса.

Таким образом, логистическая регрессия предлагает интерпретируемость, метод ближайших соседей обеспечивает простоту использования, а случайный лес обеспечивает высокую предсказательную точность и оценку важности переменных.

Оценка качества модели бинарной классификации производится с помощью стандартных метрик, выведенных из классификационной матрицы. Матрица обеспечивает оценку точности модели через три ключевых показателя: общая точность, чувствительность и специфичность. Общая точность отражает пропорцию правильных прогнозов относительно общего числа наблюдений. Чувствительность измеряет пропорцию истинно положительных (неплатежеспособные фирмы) прогнозов в общем числе фактических положительных, в то время

как специфичность измеряет пропорцию истинно отрицательных (здоровые фирмы) прогнозов в общем числе фактических отрицательных.

В данном исследовании алгоритмы оценивают вероятности неплатежеспособности, которые затем преобразуются в бинарные результаты, используя выбранный порог отсечения (cutoff). Выбор порога отсечения существенно влияет на метрики точности модели. Для визуализации этой зависимости используется кривая ROC (receiver operator curve), которая показывает по одной оси чувствительность, а по другой 1-специфичность при различных значениях порога отсечения.

Идеальная модель должна показывать значения чувствительности и специфичности, равные 1 для значений порога отсечения ниже и выше 50% соответственно. Классификатор с нулевой предсказательной способностью дает диагональную прямую ROC. Поэтому, площадь под кривой ROC (AUC) служит в качестве метрики качества, причем значение 1 указывает на идеальный классификатор, а 0,5 обозначает случайный классификатор.

Вышеописанные подходы обеспечивают прозрачное моделирование и позволяют точно прогнозировать неплатежеспособность, что критически важно для эффективного управления рисками в финансовом анализе.

### *Данные, использованные в исследовании*

Исследование предполагает создание классификационных моделей для фирм, таким образом, единицей наблюдения является фирма, зависимой переменной является бинарная переменная (1, если фирма стала неплатежеспособной, 0 в противном случае), независимыми переменными являются финансовые и нефинансовые характеристики фирм, рассчитанные на теоретическую дату прогноза.

Используемые финансовые показатели различаются в зависимости от анализируемой отрасли, но всегда включают 4 типа финансовых

коэффициентов: коэффициенты ликвидности, рентабельности, оборачиваемости и финансовой устойчивости.

Нефинансовые факторы также различаются в зависимости от анализируемой отрасли и включают информацию, касающуюся судебных исков к фирме, проверок, тендеров, ключевых изменений в фирме (местоположение, генеральный директор, акционеры), возраста фирмы и т.д.

Данные, использованные в диссертационном исследовании, были собраны автором из трех основных источников информации: базы данных Amadeus для частных фирм в ЕС, базы данных SPARK-Interfax для российских частных фирм (финансовые данные, данные, связанные с возрастом фирм и судебными исками к фирмам), веб-сайта проекта «Всероссийский Бизнес Центр» (нефинансовая информация).

## **Ключевые результаты исследования и положения, выносимые на защиту**

- 1. Установлено, что точность прогнозирования неплатежеспособности для российских фирм сферы услуг при использовании только финансовых данных ниже по сравнению с фирмами сферы услуг из развитых европейских рынков, и эта разница имеет статистическую значимость.*

Во-первых, точность прогнозирования неплатежеспособности моделей, построенных на алгоритмах логистической регрессии, метода ближайших соседей и случайного леса при обучении на наборе данных российских фирм сферы услуг, была сравнена с точностью моделей, которые обучались на наборе данных фирм из развитых европейских рынков. Гипотеза заключалась в том, что точность прогнозирования будет ниже для российских фирм сферы услуг из-за потенциальной

необъективности финансовой отчетности, вызываемой такими факторами, как теневые операции, дробление бизнеса, мошенничество, ошибки в отчетности, по сравнению с фирмами из развитых европейских рынков.

В советское время в условиях отсутствия законодательной базы, поддерживающей частный бизнес, предоставление услуг населению было монополизировано государственными структурами. Однако существовал дефицит повседневных услуг, что привело к появлению неформального сектора. В современном ландшафте сохраняются следы этого исторического влияния, что подтверждается в том числе и опросами предпринимателей (Williams *et al.*, 2013). По данным исследования Форума по изучению Восточной Европы и развивающихся экономик (Putniņš and Sauka, 2020), размер теневой экономики в России оценивается почти в 45% ВВП. Если фирмы комбинируют «белую» и «серую» деятельность, отчетность таких фирм может не отражать действительного положения вещей в этих фирмах. В ситуации дробления бизнеса, которая чаще всего возникает вследствие попытки налоговой оптимизации (Качалин, 2011; Трошкова and Ильясов, 2023), возникает необходимость в консолидации финансовых отчетов для точной оценки общего состояния компании. Однако зачастую эта задача оказывается невыполнимой из-за отсутствия групповой отчетности. Более того, некоторые части корпоративной структуры могут быть представлены ИП или компаниями, использующими упрощенные режимы налогообложения, что освобождает их от предоставления подробной финансовой отчетности. Таким образом, аналитикам приходится опираться на данные по одному юридическому лицу для оценки компании, что влечет за собой потенциальную необъективность. Мошенничество и ошибки в отчетности (по данным Министерства финансов только около 2% юр. лиц в России аудируются) также могут приводить к искажению финансовых показателей.

Набор данных включал информацию о фирмах из различных

отраслей услуг, включая туризм, пассажирские перевозки, HoReCa, образование, медицинские и социальные услуги, культура, спорт и развлечения, а также другие услуги (личные услуги, ветеринарные услуги, ремонтные услуги). Для российских фирм использовалась классификация ОКВЭД-2, для европейских – соответствующий классификатор NACE.

Было подготовлено два набора данных: один для российских фирм сферы услуг, показавших неплатежеспособность в период с 2017 по 2020 год, и один для фирм сферы услуг из развитых экономик Европейского союза. Каждая фирма, показавшая неплатежеспособность, была сопоставлена со «здоровой» фирмой-аналогом, сопоставление проводилось по размеру активов. Зависимая переменная представляет собой дамми-переменную, указывающую на неплатежеспособность (1) или ее отсутствие (0), в то время как независимые переменные — это финансовые показатели, рассчитанные на основе доступной отчетности на дату неплатежеспособности.


Контрольный набор данных включает информацию о фирмах, показавших неплатежеспособность, и «здоровых» фирмах из развитых стран Европейского союза. Выбор этой контрольной группы основан на данных, подтверждающих то, что такие проблемы, как теневые операции и дробление бизнеса, менее распространены в этих странах по сравнению с Россией.

Затем наборы данных были разделены на тренировочные и тестовые наборы 100 раз, при этом классификационные алгоритмы обучались на 100 тренировочных выборках и применялись к 100 тестовым выборкам. Затем сравнивались средние точности прогнозирования. Основная гипотеза проверялась с использованием теста Манна-Уитни для сравнения средней точности по тестовым наборам для российских и европейских фирм сферы услуг.

Результаты построения классификационных моделей с

использованием алгоритмов логистической регрессии, метода ближайших соседей и случайного леса показали значительные различия в точности прогнозирования между российскими и европейскими фирмами сферы услуг. Результаты свидетельствуют о том, что точность прогнозирования всех трех классификационных алгоритмов существенно ниже для российских сервисных фирм по сравнению с европейскими.

*Рисунок 1. Результаты классификации*



*Источник: подготовлено автором*



2. Разработаны модели прогнозирования неплатежеспособности для четырех отраслей сферы услуг, для которых ранее не проводились подобные исследования на российских данных. Установлено, что полученные модели обладают высокой точностью.

Во-вторых, были построены модели прогнозирования неплатежеспособности для нескольких отраслей сектора услуг. Оценка на тестовых наборах данных, проведенная для этих моделей, указывает на перспективность их использования при оценке кредитного риска фирм, действующих внутри своих отраслей. Для каждой из отраслей, изученных в исследовании, была получена приемлемая точность. Основные метрики классификации для тестовых данных представлены в Таблице 1.

По утверждению (Казаков and Колышкин, 2018), большинство моделей предсказания неплатежеспособности в России не показывают точность выше 70%, таким образом, точность разработанных в ходе данного исследования моделей можно оценить, как высокую.

Таблица 1. Результаты классификации (показаны результаты лучших<sup>3</sup> моделей для каждой отрасли)

	Авторемонтные фирмы	Частные клиники	Управляющие компаниями ЖКХ	Микрофинансовые услуги
# наблюдений	2240	138	1134	135
% неплатежеспособных	9% (1:10)	33% (1:2)	33% (1:2)	20% (1:4)
Общая точность	70,7%	95,5%	84,8%	78,0%
Чувствительность	68,0%	77,8%	83,3%	62,5%
Специфичность	73,6%	100%	85,6%	81,8%
AUC	0,82	0,98	0,91	0,80

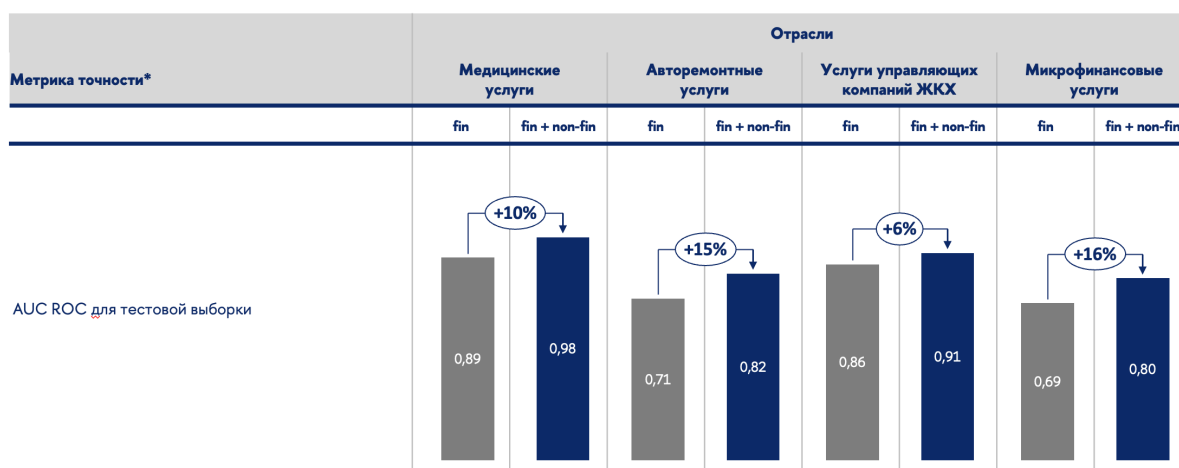
Источник: подготовлено автором

<sup>3</sup> В таблице показаны результаты моделей с наивысшим показателем AUC среди моделей, оцененных и протестированных на выборке компаний из соответствующих отраслей.

3. Установлено положительное влияние включения нефинансовых данных на точность моделей. Включение этих переменных приводит к увеличению показателя ROC AUC в среднем на 9 процентных пунктов.

Во всех рассматриваемых отраслях включение нефинансовых данных приводит к повышению прогностической способности моделей. Ниже приведен график, показывающий площадь под кривой ROC для каждой из рассматриваемых отраслей: сначала для модели, основанной только на финансовых данных, затем для модели, основанной на финансовых и нефинансовых данных.

Рисунок 2. Эффект от включения нефинансовых данных в модели



\* В таблице представлены результаты моделей, показавших лучшую точность с точки зрения AUC ROC для тестовой выборки

Источник: подготовлено автором

В исследовании было использовано несколько нефинансовых переменных. Некоторые из них были использованы ранее несколькими исследователями. Одним из примеров являются данные, связанные с исками в арбитражный суд против фирм, которые ранее использовались (Blanco-Oliver *et al.*, 2016). Эти данные, выраженные в количестве исков и сумме этих исков (разделенных на активы фирмы), оказались ценными с точки зрения точности прогнозирования в рамках данного исследования.

4. *Найдены новые нефинансовые переменные, не рассматриваемые в других исследованиях (данные о проверках бизнеса, участии в тендерах, ключевые изменения в компании), включение которых положительно влияет на точность моделей.*

Вывод о ценности нефинансовых данных для точности моделей также можно сделать относительно дополнительных нефинансовых данных, которые использовались в данном исследовании впервые. Например, информация, связанная с проверками, с которыми сталкивались фирмы, оказалась хорошим предиктором неплатежеспособности для фирм по управлению жилищным фондом и коммунальным хозяйством, количество выигранных тендеров оказалось хорошим предиктором неплатежеспособности для фирм по ремонту автомобилей, количество смен руководителя оказалось хорошим предиктором неплатежеспособности для микрофинансовых фирм. Это подчеркивает важность рассмотрения более широкого спектра источников данных для более точной оценки кредитного риска.

Полный перечень использованных нефинансовых данных и информация об их значимости в моделях для различных отраслей приведены в Таблице 2. В таблице приведены только те переменные, которые не были отфильтрованы на этапе теста на значимость разницы средних для неплатежеспособных и здоровых компаний и вошли в модель хотя бы для одной отрасли. Прочерк в таблице означает, что данная переменная не была включена в модель по причине незначимой разницы в средних для неплатежеспособных и здоровых компаний, либо не использовалась для данной отрасли. Под условным обозначением “LR” в таблице указана значимость данных переменных в моделях на базе логистической регрессии в формате «значима/незначима (уровень значимости)». В случае, если переменная включалась в несколько моделей

в рамках одной отрасли, указан лучший показатель среди этих моделей. Жирным выделены результаты для тех переменных, которые оказались значимыми на уровне 10% и ниже. Под условным обозначением “RF” в таблице указана важность (importance) данных переменных в моделях на базе случайного леса в формате «место переменной в рейтинге по важности из кол-во переменных в модели». В случае, если переменная включалась в несколько моделей в рамках одной отрасли, указан лучший показатель среди этих моделей. Жирным выделены результаты для тех переменных, которые вошли в топ-50% по важности.

Таблица 2. *Использованные нефинансовые данные и их значимость*

Переменные	Авторемонтные фирмы	Частные клиники	Управляющие компании ЖКХ	Микрофинансовые услуги
Количество проверок бизнеса	LR: незначима RF: 13 из 13 по важности	-	-	-
Количество выявленных нарушений в ходе проверок	-	LR: незначима RF: 9 из 9 по важности	LR: незначима	-
Доля проверок с выявленными нарушениями	-	-	<b>LR: значима (0,1%)</b>	-
Количество выигранных тендеров	<b>LR: значима (5%)</b> RF: 12 из 13 по важности	-	-	-
Количество изменений в составе акционеров или CEO	LR: незначима RF: 11 из 13 по важности	-	-	<b>LR: значима (10%)</b> RF: 7 из 8 по важности
Количество изменений адреса	-	-	-	<b>LR: значима (10%)</b> RF: 7 из 8 по важности
Количество уведомлений об отсутствии по месту регистрации	-	-	-	LR: незначима <b>RF: 1 из 8 по важности</b>
Количество судебных исков против фирмы в арбитражный суд	<b>LR: значима (0,1%)</b> <b>RF: 3 из 13 по важности</b>	<b>LR: значима (0,1%)</b> <b>RF: 3 из 9 по важности</b>	<b>LR: значима (0,1%)</b>	<b>LR: значима (10%)</b> <b>RF: 4 из 8 по важности</b>
Сумма судебных исков против фирмы в арбитражный суд на 1 рубль активов	LR: незначима <b>RF: 1 из 13 по важности</b>	LR: незначима <b>RF: 1 из 9 по важности</b>	<b>LR: значима (0,1%)</b>	LR: незначима RF: 5 из 8 по важности

*Источник: подготовлено автором*

5. Установлено, что модели, включающие финансовые и нефинансовые переменные, оцененные с помощью нелинейного алгоритма машинного обучения (случайный лес), позволяют более точно прогнозировать неплатежеспособность. Однако, в то же время линейный алгоритм (логистическая регрессия) в некоторых случаях обеспечивает достаточную точность и может быть использован как минимум для оценки вклада и направления влияния каждого из объясняющих факторов.

В каждом из случаев, когда в рамках исследования на одних и тех же данных были построены и модели на базе логистической регрессии, и на базе алгоритма случайного леса, модели, оцененные на основе алгоритма случайного леса, показали относительно более высокую точность на тестовой выборке. Прирост точности относительно моделей на базе логистической регрессии составляет в среднем 16 процентных пунктов в терминах ROC AUC (см. Таблицу 3).

*Таблица 3. Сравнение точности для моделей, оцененных с помощью логистической регрессии и алгоритма случайный лес.*

Метрика точности	Авторемонтные услуги		Медицинские услуги		Микрофинансовые услуги	
	Логит регрессия	Случайный лес	Логит регрессия	Случайный лес	Логит регрессия	Случайный лес
Точность	73,8%	70,7%	75,0%	95,5%	61,0%	78,0%
Чувствительность	62,7%	68,0%	78,9%	77,8%	75,0%	62,5%
Специфичность	75,0%	73,6%	66,7%	100%	57,6%	81,8%
AUC	0,69	0,82	0,81	0,98	0,62	0,80

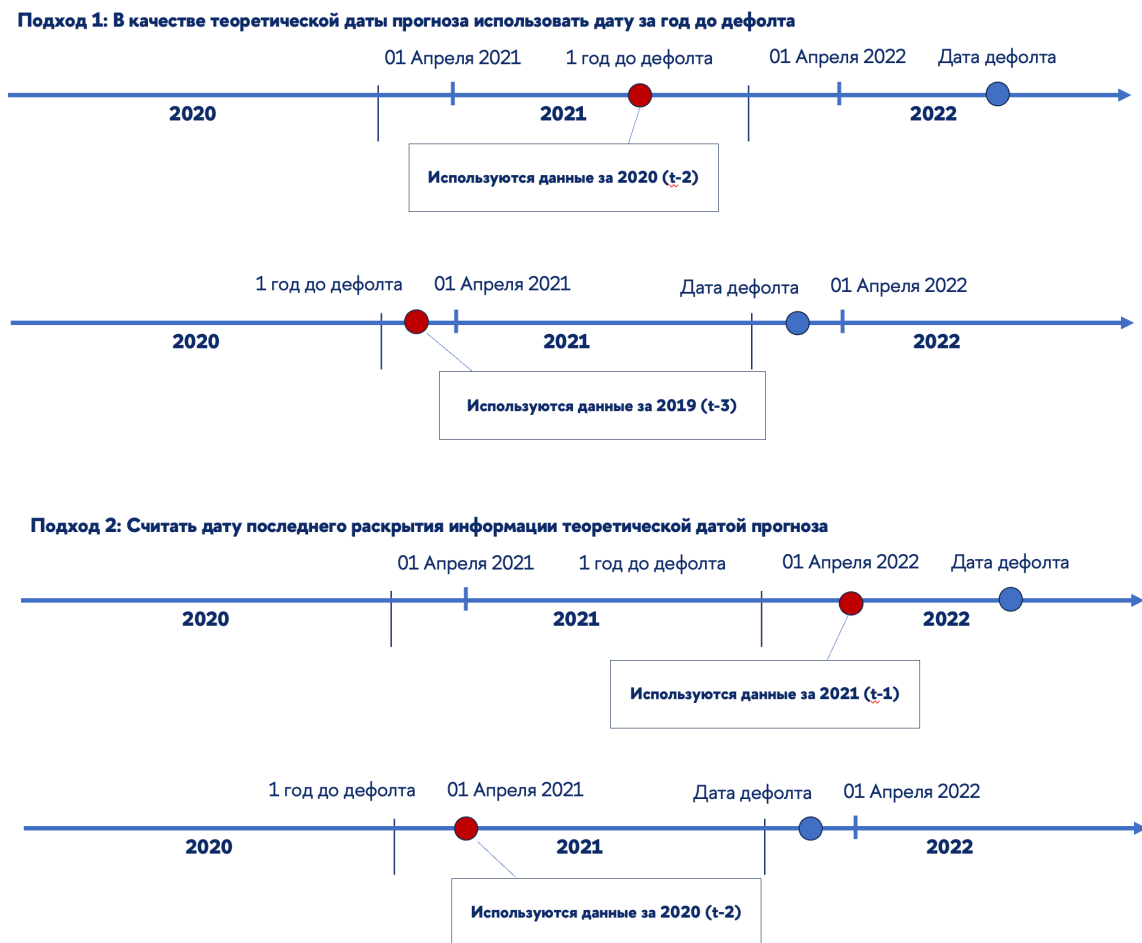
*Источник: подготовлено автором*

При этом, можно утверждать, что по крайней мере в некоторых случаях модели, оцененные с помощью алгоритма логистической регрессии, показывают относительно высокую точность (например, для отрасли авторемонтных услуг или для частных клиник). Таким образом, учитывая, что логистическая регрессия позволяет оценивать и вклад каждой переменной, и, что также важно, направление эффекта (положительный или отрицательный), рекомендуется использовать данный алгоритм при построении классификационных моделей, в том числе, если параллельно используются нелинейные алгоритмы машинного обучения.

*б. В данном исследовании разработан и применен уточненный подход к определению теоретической даты прогноза (даты, на которую должны быть рассчитаны значения независимых переменных), который позволяет контролировать доступность данных на момент предполагаемого прогнозирования.*

Исследование предлагает два подхода для определения временного периода, используемого для расчета независимых переменных в моделях прогнозирования неплатежеспособности. Первый подход, названный "Год назад", предполагает моделирование прогноза неплатежеспособности за один год до фактической даты неплатежеспособности. Теоретическая дата прогноза устанавливается ровно за год до неплатежеспособности. Второй подход, названный "Доступная отчетность", предполагает использование самой свежей отчетности, доступной на дату неплатежеспособности, для расчета независимых переменных. Многие исследования, связанные с прогнозированием неплатежеспособности, не указывают дату, на которую рассчитываются значения предикторов и/или не уделяют внимания проверке доступности данных на теоретическую дату прогноза. Данное исследование предоставляет готовую к использованию методологию для

корректного сбора данных. Описание подходов приведено на Рисунке 3.  
*Рисунок 3. Два подхода к определению теоретической даты прогноза*




*Источник: подготовлено автором*

7. В исследовании предложен подход к оценке качества и сравнения моделей, основанный на анализе прогнозируемых вероятностей неплатежеспособности для каждого наблюдения, имеющий преимущество в простоте использования практиками без профильной подготовки.

Предлагаемый метод оценки качества моделей предполагает анализ прогнозируемых вероятностей неплатежеспособности. На Рисунке 4 приведен пример построения графика прогнозируемых вероятностей для тестового набора данных, который позволяет сравнить качество базовой модели с качеством альтернативной модели. На горизонтальной оси отображаются идентификаторы (номера) фирм, а на вертикальной оси - прогнозируемые вероятности. График разделен на две области: левая область содержит точки данных для здоровых компаний, правая область содержит точки данных для неплатежеспособных компаний. Фирмы сортируются на основе вероятностей, предсказанных базовой моделью.

Рисунок 4. Пример визуализации предсказанных вероятностей



Источник: подготовлено автором



Точность модели, а также оптимальный порог отсечения могут быть оценены визуально любым заинтересованным лицом без профильной подготовки.

Затем, с использованием теста на равенство средних могут быть проверены четыре гипотезы для оценки качества моделей и их сравнения:

H1. Средние вероятности, предсказанные базовой моделью для неплатежеспособных фирм, статистически не отличаются от средних вероятностей, предсказанных базовой моделью для “здоровых” фирм (базовая модель не выполняет свою задачу должным образом).

H2. Средние вероятности, предсказанные базовой моделью для неплатежеспособных фирм, статистически не отличаются от средних вероятностей, предсказанных альтернативной моделью для неплатежеспособных фирм (обе модели предоставляют схожие результаты для неплатежеспособных фирм).

H3. Средние вероятности, предсказанные базовой моделью “здоровых” фирм, статистически не отличаются от средних вероятностей, предсказанных альтернативной моделью для “здоровых” фирм (обе модели дают схожие результаты для “здоровых” фирм).

H4. Средние вероятности, предсказанные альтернативной моделью для неплатежеспособных фирм, статистически не отличаются от средних вероятностей, предсказанных альтернативной моделью для “здоровых” фирм (альтернативная модель не выполняет свою задачу должным образом).

С использованием, например, теста Манна-Уитни можно проверить эти гипотезы и сделать выводы о качестве классификаторов.

## **Теоретическая значимость**

В рамках данного исследования разработаны и протестированы модели предсказания неплатежеспособности с использованием финансовых и нефинансовых данных в качестве объясняющих переменных, проанализировано влияние включения нефинансовых переменных и сделан вывод о положительном влиянии нефинансовых переменных на точность прогнозирования, выявлены нефинансовые переменные, представляющие ценность с точки зрения точности моделей прогнозирования неплатежеспособности.

## **Практическая значимость**

Кредитные организации могут быть заинтересованы во включении нефинансовых данных, проанализированных в данном исследовании, в собственные модели оценки кредитного риска. Также данное исследование предлагает предприятиям сферы услуг, их контрагентам и сотрудникам перечень нефинансовых показателей, которые могут быть индикаторами будущей несостоятельности предприятий сферы услуг, для мониторинга.

## **Вклад в развитие методов**

В рамках данного исследования формализован подход к оценке теоретической даты прогноза, приведен алгоритм действий по сбору данных – данный подход может использоваться в будущих исследованиях по данной тематике.

Также, в исследовании предложен подход к оценке качества моделей, позволяющий в том числе визуально оценивать качество моделей и сравнивать модели между собой. Преимущество данного подхода заключается в простоте использования на практике и доступности для любого пользователя без профильной подготовки и продвинутых знаний в

области машинного обучения и классификационных моделей.

Также, по итогам сравнения инструментов моделирования было обнаружено, что модели на основе нелинейного алгоритма машинного обучения (случайный лес) лучше описывают данные, чем модели на основе линейного алгоритма (логистическая регрессия).

## **Научная новизна**

1. Данная диссертация является первым исследованием, в котором проводится сравнение точности прогнозирования неплатежеспособности для российских фирм сферы услуг и фирм сферы услуг из развитых стран ЕС. Предыдущие исследования, во-первых, сосредоточены главным образом на зарубежных странах - существует мало исследований на российских данных. Во-вторых, существующие исследования не охватывают конкретно сектор услуг в России. Наконец, предыдущие исследования в основном фокусируются на предсказании неплатежеспособности для фирм из одной страны, и в рамках этих исследований не проводится сравнение точности для различных стран.
2. Данная диссертация является первым исследованием, в котором освещается тема прогнозирования неплатежеспособности для компаний по управлению жилищно-коммунальным хозяйством и авторемонту. Эти отрасли ранее не изучались в литературе по прогнозированию неплатежеспособности, однако они являются отраслями с высокими объемами рынка, большим количеством малых игроков и, следовательно, высокой потребностью в точной оценке кредитного риска.
3. В рамках данной работы влияние нефинансовых данных на точность прогнозирования неплатежеспособности было оценено в российском

контексте. В исследовании предлагаются новые переменные, которые не использовались в существующей литературе, но оказывают влияние на точность прогнозирования неплатежеспособности (например, данные о проверках, данные об участии в тендерах).

4. В этом исследовании формализован подход к оценке теоретической даты прогноза (даты, на которую должны быть рассчитаны значения независимых переменных). Большинство предыдущих исследований уделяют этому мало внимания или подход к сбору данных не сформулирован четко.
5. Данное исследование предлагает подход к оценке качества моделей, основанный на анализе прогнозируемых вероятностей неплатежеспособности для каждого наблюдения.

## **Структура диссертации**

Диссертация состоит из введения, 4 глав, заключения, списка литературы, приложений. Общий объем работы - 137 страниц основного текста (не включая список литературы и приложения), список литературы содержит 140 наименований.

## **Апробация работы**

1. VIII Международная конференция «Modern Econometric Tools and Applications – META2021» (Нижний Новгород, Россия, НИУ ВШЭ, 23–25 сентября 2021). Тема доклада: «Can the conventional approach to bankruptcy prediction be applicable to Russian service firm?».
2. Международная конференция «Analytics for Management and Economics Conference (AMEC Junior 2022)» (Санкт-Петербург, Россия, НИУ ВШЭ, 27-28 мая 2022). Тема доклада: «Default prediction for housing and utilities services management firms using non-financial data».
3. V Российский экономический конгресс «РЭК-2023» (Екатеринбург, Россия, 11–15 сентября 2023). Тема доклада: «Default prediction for auto repair firms using non-financial data».
4. Научно-исследовательский семинар «Эмпирические исследования банковской деятельности» (Москва, Россия, НИУ ВШЭ, 20 марта 2024). Тема доклада: «Использование нефинансовой информации для предсказания неплатежеспособности предприятий сферы услуг».

## **Список публикаций автора**

1. Afanasev V. Default Prediction Model for Emerging Capital Market Service Companies // Journal of Corporate Finance Research. 2023. Vol. 17. No. 1. P. 64-77. (Afanasev, 2023)
2. Afanasev V., Tarasova J. Default Prediction for Housing and Utilities Management Firms Using Non-Financial Data // Научно-исследовательский финансовый институт. Финансовый журнал. 2022. Vol. 14. No. 6. P. 91-110. (Afanasev and Tarasova, 2022)
3. Egor O. Bukharin, Mangileva S. I., Afanasev V. Default Prediction for Russian Food Service Firms: Contribution of Non-Financial Factors and Machine Learning // Journal of Applied Economic Research. 2024. Vol. 23. No. 1. P. 206-226. (Bukharin *et al.*, 2024)

## Список литературы

1. Afanasev, V. (2023), "Default Prediction Model for Emerging Capital Market Service Companies", *Journal of Corporate Finance Research*, Vol. 17 No. 1, pp. 64–77, doi: 10.17323/j.jcfr.2073-0438.17.1.2023.64-77.
2. Afanasev, V. and Tarasova, Y. (2022), "Default Prediction for Housing and Utilities Management Firms Using Non-Financial Data", *Financial Journal*, Vol. 14 No. 6, pp. 91–110, doi: 10.31107/2075-1990-2022-6-91-110.
3. Altman, E. (1968), "Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy", *The Journal of Finance*, Vol. 23 No. 4, pp. 589–609.
4. Altman, E., Iwanicz-Drozdowska, M., Laitinen, E. and Suvas, A. (2016), "Financial and nonfinancial variables as long-horizon predictors of bankruptcy", *The Journal of Credit Risk*, Vol. 12, pp. 49–78, doi: 10.21314/JCR.2016.216.
5. Altman, E., Sabato, G. and Wilson, N. (2010), "The value of non-financial information in SME risk management", *The Journal of Credit Risk*, Vol. 6, pp. 95–127, doi: 10.21314/JCR.2010.110.
6. Altman, E.I., Marco, G. and Varetto, F. (1994), "Corporate distress diagnosis: Comparisons using linear discriminant analysis and neural networks (the Italian experience)", *Journal of Banking & Finance*, Vol. 18 No. 3, pp. 505–529, doi: 10.1016/0378-4266(94)90007-8.
7. Beaver, W.H. (1966), "Financial Ratios As Predictors of Failure", *Journal of Accounting Research*, [Accounting Research Center, Booth School of Business, University of Chicago, Wiley], Vol. 4, pp. 71–111, doi: 10.2307/2490171.
8. Bhimani, A., Gulamhussen, M.A. and Lopes, S. da R. (2013), "The Role of Financial, Macroeconomic, and Non-financial Information in Bank Loan Default Timing Prediction", *European Accounting Review*, Vol. 22 No. 4, pp. 739–763, doi: 10.1080/09638180.2013.770967.
9. Blanco-Oliver, A., Diéguez, A., Alfonso, M.D. and Vazquez Cueto, M. (2016), "Hybrid model using logit and nonparametric methods for predicting micro-entity failure", *Investment Management and Financial Innovations*, Vol. 13, pp. 35–46, doi: 10.21511/imfi.13(3).2016.03.
10. Blum, M. (1974), "Failing Company Discriminant Analysis", *Journal of Accounting Research*, [Accounting Research Center, Booth School of Business, University of Chicago, Wiley], Vol. 12 No. 1, pp. 1–25, doi: 10.2307/2490525.
11. Bukharin, E.O., Mangileva, S.I. and Afanasev, V.V. (2024), "Default Prediction for Russian Food Service Firms: Contribution of Non-Financial Factors and Machine Learning", *Journal of Applied Economic Research*, Vol. 23 No. 1, pp. 206–226, doi: 10.15826/vestnik.2024.23.1.009.
12. Cao, Y., Liu, X., Zhai, J. and Hua, S. (2020), "A two-stage Bayesian network model for corporate bankruptcy prediction", *International Journal of Finance & Economics*, Vol. 27 No. 1, pp. 455–472, doi: <https://doi.org/10.1002/ijfe.2162>.
13. Coats, P.K. and Fant, L.F. (1993), "Recognizing Financial Distress Patterns Using a Neural Network Tool", *Financial Management*, Financial Management Association International, Vol. 22 No. 3, pp. 142–155.
14. Costa, M., Lisboa, I. and Gameiro, A. (2022), "Is the Financial Report Quality Important in the Default Prediction? SME Portuguese Construction Sector Evidence", *Risks*, Multidisciplinary Digital Publishing Institute, Vol. 10 No. 5, pp. 1–24, doi: 10.3390/risks10050098.
15. D'Amato, A. and Mastrolia, E. (2022), "Linear discriminant analysis and logistic regression for default probability prediction: the case of an Italian local bank", *International Journal of Managerial and Financial Accounting*, Inderscience Publishers Ltd., Vol. 14 No. 4, pp. 323–343, doi: 10.1504/IJMFA.2022.126552.
16. Deakin, E.B. (1972), "A Discriminant Analysis of Predictors of Business Failure", *Journal of Accounting Research*, [Accounting Research Center, Booth School of Business, University of Chicago, Wiley], Vol. 10 No. 1, pp. 167–179, doi: 10.2307/2490225.
17. Filomeni, S., Bose, U., Megaritis, A. and Triantafyllou, A. (2024), "Can market information outperform hard and soft information in predicting corporate defaults?", *International Journal of Finance & Economics*, Vol. 29 No. 3, pp. 3567–3592, doi: 10.1002/ijfe.2840.
18. Gruszczynski, M. (2004), "Financial Distress of Companies in Poland", Department of Applied Econometrics, Warsaw School of Economics, Working Papers, No. 1-04, doi: 10.2139/ssrn.902256.
19. Hunter, J. and Isachenkova, N. (2001), "Failure risk: A comparative study of UK and Russian firms", *Journal of Policy Modeling*, Vol. 23 No. 5, pp. 511–521, doi: 10.1016/S0161-8938(01)00064-3.
20. Jaki, A. and Cwiąg, W. (2021), "Bankruptcy Prediction Models Based on Value Measures", *Journal of Risk and Financial Management*, Multidisciplinary Digital Publishing Institute, Vol. 14 No. 1, pp. 1–14, doi: 10.3390/jrfm14010006.

21. Jandaghi, G., Saranj, A., Rajaei, R., Ghasemi, A. and Tehrani, R. (2021), "Identification of the Most Critical Factors in Bankruptcy Prediction and Credit Classification of Companies", *Iranian Journal of Management Studies*, University of Tehran, Vol. 14 No. 4, pp. 817–834, doi: 10.22059/ijms.2021.285398.673712.
22. du Jardin, P. (2009), "Bankruptcy prediction models: How to choose the most relevant variables?", *Bankers, Markets & Investors*, pp. 39–46.
23. Kanapickienė, R., Kanapickas, T. and Neciunas, A. (2023), "Bankruptcy Prediction for Micro and Small Enterprises Using Financial, Non-Financial, Business Sector and Macroeconomic Variables: The Case of the Lithuanian Construction Sector", *Risks*, Multidisciplinary Digital Publishing Institute, Vol. 11 No. 5, pp. 1-33, doi: 10.3390/risks11050097.
24. Karminsky, A. and Burekhin, R. (2019), "Comparative analysis of methods for forecasting bankruptcies of Russian construction companies", *Business Informatics*, Vol. 13 No. 3, pp. 52–66, doi: 10.17323/1998-0663.2019.3.52.66.
25. Lugovskaya, L. (2010), "Predicting default of Russian SMEs on the basis of financial and non-financial variables", *Journal of Financial Services Marketing*, Vol. 14 No. 4, pp. 301–313, doi: 10.1057/fsm.2009.28.
26. Makeeva, E. and Sinilshchikova, M. (2020), "News Sentiment in Bankruptcy Prediction Models: Evidence from Russian Retail Companies", *Корпоративные Финансы | ISSN: 2073-0438*, Vol. 14 No. 4, pp. 7–18, doi: 10.17323/j.jcfr.2073-0438.14.4.2020.7-18.
27. Odom, M. and Sharda, R. (1990), "A Neural Network Model for Bankruptcy Prediction", Vol. 2, pp. 163–168 vol.2, doi: 10.1109/IJCNN.1990.137710.
28. Ohlson, J.A. (1980), "Financial Ratios and the Probabilistic Prediction of Bankruptcy", *Journal of Accounting Research*, [Accounting Research Center, Booth School of Business, University of Chicago, Wiley], Vol. 18 No. 1, pp. 109–131, doi: 10.2307/2490395.
29. Psillaki, M., Tsolas, I.E. and Margaritis, D. (2010), "Evaluation of credit risk based on firm performance", *European Journal of Operational Research*, Elsevier, Vol. 201 No. 3, pp. 873–881.
30. Putniņš, T. and Sauka, A. (2020), *The Shadow Economy in Russia: New Estimates and Comparisons with Nearby Countries*.
31. Ragab, Y.M. and Saleh, M.A. (2021), "Non-financial variables related to governance and financial distress prediction in SMEs—evidence from Egypt", *Journal of Applied Accounting Research*, Emerald Publishing Limited, Vol. 23 No. 3, pp. 604–627, doi: 10.1108/JAAR-02-2021-0025.
32. Ravi Kumar, P. and Ravi, V. (2007), "Bankruptcy prediction in banks and firms via statistical and intelligent techniques – A review", *European Journal of Operational Research*, Vol. 180 No. 1, pp. 1–28, doi: 10.1016/j.ejor.2006.08.043.
33. Sirirattanaphonkun, W. and Pattarathammas, S. (2012), "Default Prediction for Small-Medium Enterprises in Emerging Market: Evidence from Thailand", *Seoul Journal of Business*, College of Business Administration, Vol. 18 No. 2, pp. 25–54
34. Situm, M. (2023), "Financial distress in the Austrian tourism industry: hotels and restaurants analysis", *European Journal of Tourism Research*, Vol. 34, doi: 10.54055/ejtr.v34i.2992.
35. Springate, G.L.V. (1978), *Predicting the Possibility of Failure in a Canadian Firm: A Discriminant Analysis*, Simon Fraser University.
36. Stevenson, M., Mues, C. and Bravo, C. (2021), "The value of text for small business default prediction: A Deep Learning approach", *European Journal of Operational Research*, Vol. 295 No. 2, pp. 758–771, doi: 10.1016/j.ejor.2021.03.008.
37. Williams, C.C., Nadin, S., Newton, S., Rodgers, P. and Windebank, J. (2013), "Explaining off-the-books entrepreneurship: a critical evaluation of competing perspectives", *International Entrepreneurship and Management Journal*, Vol. 9 No. 3, pp. 447–463, doi: 10.1007/s11365-011-0185-0.
38. Zhang, G., Hu, M.Y., Patuwo, B.E. and Indro, D.C. (1999), "Artificial neural networks in bankruptcy prediction: General framework and cross-validation analysis", *European Journal of Operational Research*, Vol. 116 No. 1, pp. 16–32.
39. Zhao, Y. and Lin, D. (2023), "Prediction of Micro- and Small-Sized Enterprise Default Risk Based on a Logistic Model: Evidence from a Bank of China", *Sustainability*, Multidisciplinary Digital Publishing Institute, Vol. 15 No. 5, pp. 1-13, doi: 10.3390/su15054097.
40. Zmijewski, M.E. (1984), "Methodological Issues Related to the Estimation of Financial Distress Prediction Models", *Journal of Accounting Research*, Vol. 22, pp. 59–82, doi: 10.2307/2490859.
41. Давыдова, Г.В. and Беликов, А. (1999), "Методика количественной оценки риска банкротства предприятий", *Управление Риском*, Vol. 23, No. 3, pp. 13–20.
42. Евстропов, М. (2008), "Оценка возможностей прогнозирования банкротства предприятий в России", *Вестник Оренбургского Государственного Университета*, Федеральное государственное

- бюджетное образовательное учреждение высшего образования «Оренбургский государственный университет», Россия, Оренбург, No. 4, pp. 25–32.
43. Казаков, А. and Кольшкин, А. (2018), “Разработка моделей прогнозирования банкротства в современных российских условиях”, Вестник Санкт-Петербургского Университета. Экономика, Федеральное государственное бюджетное образовательное учреждение высшего образования «Санкт-Петербургский государственный университет», Россия, Санкт-Петербург, No. 2, pp. 241–266.
  44. Качалин, Д.С. (2011), “Анализ российских моделей дробления (реорганизации) бизнеса, обеспечивающих соответствие его масштабов специальным режимам налогообложения”, Финансовая Аналитика: Проблемы и Решения, Vol. 47, No. 5.
  45. Трошкова, С. and Ильясов, Д. (2023), “Дробление бизнеса: понятие и налоговые последствия”, Инновационная экономика и общество, Vol. 40 No. 2, pp. 53–60.