

Международный научно-исследовательский журнал
«Прогрессивная экономика»
№ 6 / 2026 https://progressive-economy.ru/vypusk_1/logika-vybora-instrumentov-finansovogo-monitoringa-predpriyatij-v-usloviyah-regionalnoj-differenciaczii/
Научная статья / Original article
Шифр научной специальности ВАК: 5.2.3
УДК 338.2:005.52
DOI: 10.54861/27131211_2026_6_166



ЛОГИКА ВЫБОРА ИНСТРУМЕНТОВ ФИНАНСОВОГО МОНИТОРИНГА ПРЕДПРИЯТИЙ В УСЛОВИЯХ РЕГИОНАЛЬНОЙ ДИФФЕРЕНЦИАЦИИ

*Фан Чэньси, аспирант, Ростовский государственный экономический университет (РИНХ), г. Ростов-на-Дону, Россия
344002, Ростов-на-Дону, Ул. Большая Садовая, 69
ORCID: <https://orcid.org/0009-0000-7639-8068>
e-mail: 13707667297@163.com*

Аннотация. Статья посвящена исследованию логики выбора инструментов финансового мониторинга предприятий в условиях существенной региональной дифференциации. На фоне глобальной экономической нестабильности и неравномерного развития регионов вопрос соответствия инструментов финансового мониторинга специфике конкретной территории приобретает особую актуальность. Цель работы – построить аналитическую матрицу «региональные характеристики – адаптированный инструментарий», позволяющую органам регионального регулирования осуществлять дифференцированный выбор методов финансового мониторинга. Исследование основано на методе систематического обзора литературы; в анализ включены рецензируемые публикации 2017–2025 годов, индексируемые в базах Web of Science и Scopus. На основе анализа научной литературы в статье систематизированы три класса инструментов: традиционные статистические модели (Z-Score Альтмана, логистическая регрессия), методы машинного обучения (случайный лес, XGBoost) и инструменты глубокого обучения (LSTM, ViLSTM). Предложены три ключевых региональных детерминанты выбора инструмента: уровень экономического развития и структура предприятий, состояние цифровой инфраструктуры, качество институциональной среды и регуляторной системы. Научная новизна исследования состоит в построении регионально-дифференцированной аналитической матрицы, систематически связывающей региональные экономические характеристики с конкретными инструментами финансового мониторинга и восполняющей пробел в существующей литературе, в которой региональная неоднородность практически отсутствует в рамках выбора инструментов. Результаты исследования показывают, что традиционные инструменты наиболее применимы в слаборазвитых и слабоцифровизированных регионах, методы машинного обучения – в регионах со средним уровнем цифровизации, а инструменты глубокого обучения – в регионах с высокоразвитой цифровой экосистемой. Сделан вывод о том, что выбор инструмента финансового мониторинга должен определяться не технической



оптимальностью, а степенью соответствия региональным условиям. Полученные результаты имеют практическое значение для разработки дифференцированной региональной регуляторной политики.

Ключевые слова: финансовый мониторинг предприятий, система раннего предупреждения, региональная дифференциация, машинное обучение, глубокое обучение, региональная экономика, цифровая инфраструктура.

Конфликт интересов. Автор заявляет об отсутствии конфликта интересов.

Для цитирования: Фан Чэньси. Логика выбора инструментов финансового мониторинга предприятий в условиях региональной дифференциации // Прогрессивная экономика. 2026. № 6. С. 166–180. https://doi.org/10.54861/27131211_2026_6_166.

Статья поступила в редакцию: 28.04.2026 г. Одобрена после рецензирования: 02.06.2026 г. Принята к публикации: 04.06.2026 г.

THE LOGIC BEHIND SELECTING FINANCIAL MONITORING TOOLS FOR ENTERPRISES IN THE CONTEXT OF REGIONAL DIFFERENTIATION

*Fang Chenxi, Postgraduate Student, Rostov State University of Economics,
Rostov-on-Don, Russia
344002, Rostov-on-Don, Bolshaya Sadovaya Street, 69
ORCID: <https://orcid.org/0009-0000-7639-8068>
e-mail: 13707667297@163.com*

Abstract. This article investigates the selection logic of enterprise financial early warning tools under conditions of significant regional differentiation. Against the backdrop of global economic volatility and uneven regional development, the question of matching financial monitoring tools to the specific characteristics of a given territory has become critically important. The study aims to construct an analytical matrix of ‘regional characteristics – adapted toolkit’ to guide regional regulatory bodies in making differentiated tool selections. Based on a systematic literature review, three categories of tools are identified and classified: traditional statistical models (Altman Z-Score, logistic regression), machine learning methods (random forest, XGBoost), and deep learning tools (LSTM, BiLSTM). Three key regional determinants of tool selection are proposed: the level of economic development and enterprise structure, the state of digital infrastructure, and the quality of the institutional and regulatory environment. The scientific novelty of the study lies in the construction of a region-differentiated analytical matrix that systematically links regional economic characteristics to specific financial monitoring tools, filling a gap in existing literature where regional heterogeneity has been largely absent from tool-selection frameworks. The results indicate that traditional tools are most applicable in underdeveloped, low-digitalization regions; machine learning methods suit regions with moderate digitalization levels; while deep learning tools are appropriate for regions with highly developed digital ecosystems. The study concludes that the selection of financial monitoring tools should be driven not by

technical optimality but by the degree of fit with regional conditions. The findings contribute to regional economics research and corporate financial monitoring practice.

Keywords: enterprise financial monitoring, early warning system, regional differentiation, machine learning, deep learning, regional economics, digital infrastructure.

JEL classification: G32, G17, R11, C45.

Conflict of interest. The author declares that there is no conflict of interest.

For citation: Fang Chenxi. (2026). Logika vybora instrumentov finansovogo monitoringa predpriyatii v usloviyakh regional'noi differentsiatsii [The logic behind selecting financial monitoring tools for enterprises in the context of regional differentiation]. *Progressivnaya ekonomika* [Progressive Economy], 6, 166–180. https://doi.org/10.54861/27131211_2026_6_166. (In Russ., abstract in Eng.)

The article was submitted to the editorial office: 28/04/2026. Approved after review: 02/06/2026. Accepted for publication: 04/06/2026.

Введение

На фоне глобальной экономической нестабильности и неравномерного регионального развития эффективность инструментов финансового мониторинга предприятий всё активнее привлекает внимание как научного сообщества, так и практиков. Традиционные исследования в области финансового мониторинга, как правило, опираются на единые рыночные условия и не учитывают глубокого влияния региональных экономических характеристик на пригодность тех или иных инструментов. Между тем регионы существенно различаются по уровню экономического развития, отраслевой структуре и состоянию цифровой инфраструктуры, а эти различия непосредственно определяют логику выбора и практическую результативность инструментов финансового мониторинга.

Применительно к России особенно показательна выраженная экономическая неоднородность между субъектами федерации. А.А. Широ́в, В.В. Потапенко, К.М. Никитин и Ю.Ю. Чаплина показали, что в таких городах, как Москва, уже созданы многомерные системы краткосрочного регионального мониторинга, охватывающие макроэкономику, отраслевые секторы и малый и средний бизнес [1], тогда как предприятия отдалённых регионов по-прежнему испытывают острую нехватку возможностей для освоения цифровых инструментов. По данным Росстата, доля МСП в ВВП России составляет около 20–21%, при этом их потребности в мониторинге финансовых рисков существенно дифференцированы в зависимости от территории [2; 3].

На уровне инструментария наметилась устойчивая тенденция смещения от традиционного анализа финансовых коэффициентов к методам, основанным на данных. Song Y., Du H., Piao T. и Shi H. разработали интеллектуальную модель мониторинга и раннего предупреждения финансовых рисков на основе LSTM и Transformer [4]. Zhang Z., Liu X. и Niu H. ввели текстово-лингвистические индикаторы из MD&A и, сравнив 13

моделей, установили, что ансамблевые методы демонстрируют более стабильные результаты [5]. Вместе с тем указанные работы крайне редко включают региональную экономическую неоднородность в аналитическую рамку выбора инструментов.

П.В. Строев, О.В. Пивоварова, Х.В. Шеожев и А.И. Дудник показали, что регионы с низкой финансовой устойчивостью существенно различаются по уровню цифровизации и доступности данных [3]. В этих условиях стратегия тиражирования единых инструментов не способна учесть многообразие региональных реалий. Основываясь на вышеизложенном, настоящая статья ставит ключевой исследовательский вопрос: каким образом региональные экономические характеристики определяют логику выбора инструментов финансового мониторинга предприятий? Цель работы – построить аналитическую матрицу «региональные характеристики – адаптированный инструментарий».

Обзор литературы

Обратимся прежде всего к традиционным методам финансового мониторинга и их ограничениям. Исследования в области инструментов финансового мониторинга предприятий ведутся с 1960-х годов. Z-Score Альтмана, построенная на методе множественного дискриминантного анализа и пяти ключевых финансовых коэффициентах, на протяжении десятилетий оставалась наиболее влиятельным инструментом раннего предупреждения. Вместе с тем модели присущи существенные ограничения: она изначально разрабатывалась для производственных предприятий, и при межотраслевом применении точность прогнозирования заметно снижается; модель опирается преимущественно на ретроспективные финансовые данные и не отражает текущее финансовое состояние компании – особенно в условиях высокой рыночной волатильности [7]. Анализ финансовых коэффициентов относится к одномерным методам: нелинейные зависимости между переменными остаются вне поля анализа [8].

Применительно к условиям региональной неоднородности названные недостатки приобретают особую остроту. Региональные различия в нормативно-правовой базе и рыночной структуре объективно ограничивают возможности традиционных моделей с фиксированными параметрами поддерживать стабильное качество прогноза в разнородных территориальных контекстах [9]. Показательно, что ни в работе Altman, ни в исследовании Ohlson не был предусмотрен какой-либо механизм настройки модели под специфику отдельного региона. По существу, оба подхода изначально строились на допущении об однородности рыночной среды – предположении, которое трудно считать реалистичным применительно к российскому пространству с его выраженной межрегиональной асимметрией.

Именно стремление преодолеть эти ограничения – прежде всего неспособность традиционных моделей улавливать нелинейные зависимости и адаптироваться к региональной специфике – послужило главным стимулом

для обращения к методам машинного обучения в задачах финансового мониторинга. Многочисленные эмпирические исследования свидетельствуют о том, что модели машинного обучения в целом превосходят традиционные статистические подходы по точности прогнозирования и устойчивости [10].

L. Theodorakopoulos, A. Theodoropoulou. и A. Bakalis провели систематический обзор 21 рецензируемого исследования за 2016–2025 годы и установили, что нейронные сети и гибридные архитектуры стабильно обеспечивают высокую точность в задачах прогнозирования кредитных рисков и банкротства, а XGBoost показывает превосходную робастность на несбалансированных наборах данных [10]. F.T. Kristanti, M.Y. Febrianta, D.F. Salim, H.A. Riyadh, Y. Sagama и B.A.H. Beshr подтвердили, что ансамблевые модели на основе случайного леса и XGBoost показывают стабильные результаты в предсказании финансовых затруднений [11].

Вместе с тем следует обратить внимание на существенное методологическое ограничение, характерное для большинства работ в данной области: опора на изолированные кейсы или стандартизированные наборы данных затрудняет перенос полученных результатов на иные территориальные контексты и типы рисков [10]. При этом региональная экономическая неоднородность как фактор, влияющий на выбор инструментов мониторинга, в существующей литературе практически не рассматривается. Между тем высокая точность моделей, зафиксированная на тестовых выборках, далеко не всегда воспроизводится в условиях реальных региональных рынков – особенно там, где объём структурированных финансовых данных ограничен. Некритическое распространение подобных результатов на практику способно породить ложное представление об универсальности тех или иных инструментов и стать основой для регуляторных решений, не учитывающих специфику конкретной территории.

Вместе с тем анализ имеющихся публикаций выявляет выраженную тенденцию к «дерегionalизации» исследований по инструментам финансового мониторинга предприятий – региональное измерение остаётся практически неразработанным. Lokanan M.E., и Ramzan S. прямо указывают, что финансовое поведение существенно варьируется в зависимости от страны и региона, и это требует построения ситуационных моделей, учитывающих региональную специфику [9]. Применение методов больших данных и искусственного интеллекта в управлении финансовыми рисками демонстрирует явную отраслевую дифференциацию [10]. Таким образом, вопрос системного сопоставления инструментов финансового мониторинга с региональными экономическими характеристиками остаётся практически неисследованным. Настоящая статья призвана восполнить этот пробел.

Материалы и методы

Настоящее исследование основано на методе систематического обзора литературы (systematic literature review). Информационной базой послужили рецензируемые научные статьи, опубликованные в период с 2017 по 2025 год

и индексируемые в базах данных Web of Science, Scopus и Google Scholar. Поиск осуществлялся по ключевым терминам: «financial distress prediction», «enterprise financial monitoring», «early warning system», «machine learning bankruptcy», «regional economic heterogeneity». Критерии отбора включали: (1) наличие эмпирических или теоретических результатов в области методов финансового мониторинга предприятий; (2) релевантность к тематике региональной экономики или цифровой инфраструктуры; (3) доступность полного текста. Итоговый массив анализируемых источников составил 20 публикации. Сравнительный анализ инструментов проводился по трём параметрам: потребность в данных (объём и структурированность), интерпретируемость результатов и технологический порог входа. На основе полученных характеристик и с опорой на концепции региональной экономики и теории институциональной среды предложена аналитическая матрица сопоставления региональных условий с типом финансового инструментария.

В рамках сравнительного анализа рассматриваются три класса инструментов. Первый класс – традиционные статистические инструменты, в основе которых лежат анализ финансовых коэффициентов и дискриминантный анализ. Согласно результатам N. Mselmi, A. Lahiani и T. Namza, гибридная модель SVM-PLS обеспечивает совокупную точность 94,28% при прогнозировании финансовых затруднений французских МСП, что превосходит как логит-модель, так и нейронные сети; при этом логистическая регрессия по-прежнему даёт приемлемые результаты там, где объём доступных данных невелик [12]. S. Dogan, D. Kocak и M. Atan зафиксировали надёжность логистической регрессии на выборках с линейной структурой данных [13].

Тем не менее жёсткие линейные допущения, заложенные в основу традиционных методов, существенно затрудняют улавливание нелинейных зависимостей между финансовыми переменными, а ориентация на исторические данные ослабляет прогностические возможности модели в условиях высокой волатильности либо заметных межрегиональных различий в институциональной среде [9]. Данный класс инструментов наиболее подходит предприятиям с ограниченным объёмом накопленных оцифрованных данных и невысоким уровнем автоматизации финансового учёта, а также организациям, для которых приоритетна интерпретируемость результатов перед регуляторами. Территориальный фактор проявляется косвенно: в слаборазвитых регионах доля таких предприятий статистически выше ввиду меньшего охвата цифровыми сервисами и более низкого уровня ИТ-компетенций персонала.

Второй класс – инструменты машинного обучения, к которым относятся деревья решений, случайный лес, SVM и ансамблевые методы – в частности, XGBoost. Модели машинного обучения способны эффективно выявлять нелинейные паттерны и сложные взаимодействия между финансовыми переменными без жёстких параметрических допущений [14]. Kristanti и соавт.

(2024) установили, что ансамблевые модели на основе XGBoost и случайного леса неизменно демонстрируют надёжную точность прогнозирования финансовых затруднений [11].

Данный класс инструментов ориентирован на предприятия с достаточным объёмом структурированных исторических данных и внедрёнными системами автоматизированного учёта. Связь с территориальным фактором обусловлена тем, что уровень цифровизации предприятий в экономически развитых регионах в среднем выше: развитая региональная IT-инфраструктура, доступность квалифицированных кадров и цифровых сервисов создают благоприятную среду для накопления данных, необходимых для обучения моделей машинного обучения.

Третий класс – инструменты глубокого обучения, к которым относятся LSTM, BiLSTM, Transformer и гибридные конфигурации CNN-LSTM. В частности, W. Liu разработал модель LTR-Net, построенную на совместном использовании LSTM, Transformer и ResNet: данная архитектура позволяет обрабатывать временные ряды финансовых данных предприятий, охватывая одновременно как краткосрочные колебания, так и долгосрочные тенденции в динамике показателей [15]. S. Chen в свою очередь предложил подход на базе BiLSTM с механизмом внимания, принципиальное достоинство которого состоит в возможности анализировать финансовые данные в обоих временных направлениях, что повышает полноту улавливаемых закономерностей [16].

Однако практическое применение инструментов глубокого обучения сопряжено с серьёзными организационными и технологическими трудностями. Значительные объёмы обучающих данных и высокие требования к вычислительным мощностям делают внедрение таких моделей малореалистичным для предприятий, действующих в условиях слабой IT-инфраструктуры или недостаточной цифровой зрелости [10].

Данный класс инструментов рассчитан на крупные предприятия с высоким уровнем цифровизации, значительными объёмами временных рядов финансовых данных и собственными IT-ресурсами либо доступом к облачным вычислительным мощностям. Территориальный фактор здесь наиболее выражен: концентрация таких предприятий объективно выше в регионах с развитой цифровой экосистемой, поскольку именно там формируются условия для привлечения IT-специалистов, внедрения ERP-систем и накопления данных, достаточных для обучения моделей глубокого обучения. Системные различия трёх классов инструментов по условиям применимости обобщены в табл. 1.

Таблица 1

**Сравнение условий применимости трёх групп инструментов
финансового мониторинга**

Table 1

**Comparison of applicability conditions for three groups of financial
monitoring tools**

Группа инструментов (примеры)	Потребность в данных / Интерпретируемость	Профиль предприятия / Региональный контекст
Традиционные статистические (Z-Score, логит-регрессия)	Низкая / Высокая	Предприятия с низким уровнем цифровизации; типичны для слаборазвитых регионов
Машинное обучение (случайный лес, XGBoost)	Средняя / Средняя	Предприятия со средним уровнем цифровизации; типичны для регионов с формирующейся IT-средой
Глубокое обучение (LSTM, BiLSTM)	Высокая / Низкая	Высокоцифровизированные предприятия; типичны для регионов с развитой цифровой экосистемой

Источник: составлено автором

Source: compiled by the author

Таким образом, выбор инструмента – это проблема адаптации, обусловленная региональными экономическими условиями.

Теоретическая модель и обсуждение

Анализ литературы и характеристик инструментов позволяет выделить три ключевые региональные детерминанты, определяющие логику выбора. Первая детерминанта – уровень экономического развития и структура предприятий. Региональный ВВП и отраслевая структура непосредственно влияют на доступность и качество финансовых данных предприятий. D. Purnell, A. Etemadi, J. Камр показали, что для построения эффективных систем раннего предупреждения необходимо систематически включать несколько подгрупп макроэкономических и микро-уровневых индикаторов [17]. В регионах с низким уровнем экономического развития преобладают МСП с недостаточно развитой системой финансовой отчётности и скудной исторической базой данных.

Вторая детерминанта – состояние цифровой инфраструктуры. H. Vesha, M. Kalai, S. Houidi и K. Helali фиксируют значительный разрыв между прибрежными и внутренними регионами по уровню цифровой инфраструктуры и цифровой грамотности [6]. Y Liu., S. Ma и M. Sun подтверждают, что эффект от политики в области цифровой инфраструктуры существенно варьируется в зависимости от региона [18]. C. Wen, Y. Xiao и B. Hu показывают на примере китайских провинций, что различия в уровне цифровой финансовой инклюзии между территориями непосредственно сказываются на экономической структуре и доступности финансовых услуг для предприятий [20].

Третья детерминанта – качество институциональной среды и регуляторной системы. Y. Zhuang и H. Wei показывают, что в регионах с ненадлежащим правовым регулированием финансовые риски предприятий с большей вероятностью переходят из зоны низкого риска в зону умеренного риска, что обуславливает потребность в инструментах с непрерывным мониторинговым покрытием [19]. M.E. Lokanan и S. Ramzan указывают, что региональные диспропорции в финансовой системе существенно влияют на практическую эффективность инструментов управления финансовыми рисками предприятий [9]. На основе трёх выявленных детерминант предлагается аналитическая матрица «региональные характеристики – адаптированный инструментарий», разделяющая регионы на три типа (табл. 2).

Регионы типа А типичны для слаборазвитых внутренних или отдалённых территорий. Логистическая регрессия предъявляет невысокие требования к размеру выборки и сохраняет приемлемую точность прогнозирования даже при ограниченных данных [12]. Регионы типа Б характеризуются продолжающейся цифровой трансформацией; ансамблевые методы демонстрируют превосходную робастность при работе с несбалансированными данными [11]. Регионы типа В отличаются высоким уровнем цифровизации; модели LSTM способны эффективно улавливать долгосрочные временные зависимости в потоках доходов и расходов предприятий [15]. Вместе с тем высокие требования к вычислительным ресурсам создают барьеры для масштабного внедрения [10].

Практические следствия предложенной матрицы сводятся к следующему: тиражирование инструментов финансового мониторинга не должно ориентироваться на поиск технически «оптимального решения» – необходимо стремиться к «адаптированному решению», соответствующему региональным условиям. Полученный вывод полностью согласуется с позицией M.E. Lokanan и S. Ramzan о необходимости ситуационных моделей [9] и создаёт теоретическую основу для дифференциации региональной регуляторной политики.

Таблица 2

Аналитическая матрица «региональные характеристики – адаптированный инструментарий»

Table 2

Analytical matrix: regional characteristics and adapted financial monitoring tools

Региональные характеристики	Традиционные статистические инструменты (Z-Score, логит-регрессия)	Инструменты машинного обучения (случайный лес, XGBoost)	Инструменты глубокого обучения (LSTM, BiLSTM)
Уровень экономического развития и структура предприятий	Низкий ВВП; преобладание МСП с неразвитой системой отчётности и ограниченной базой данных	Средний уровень ВВП; диверсифицированная структура предприятий; растущий объём финансовых данных	Высокий ВВП; концентрация крупных предприятий с развитыми системами финансового учёта
Состояние цифровой инфраструктуры	Низкий уровень цифровизации; ограниченный доступ к IT-сервисам и квалифицированным кадрам	Формирующаяся цифровая инфраструктура; распространение автоматизированных систем учёта	Развитая цифровая экосистема; доступность облачных вычислений и ERP-систем
Качество институциональной среды	Слабая регуляторная система; высокие требования к интерпретируемости результатов	Умеренно развитая институциональная среда; баланс точности и интерпретируемости	Развитая регуляторная система; возможность применения сложных необъяснимых моделей
Логика выбора	Минимальные требования к данным и IT-ресурсам; высокая прозрачность для регуляторов	Баланс точности прогнозирования и доступности данных	Максимальная точность при наличии больших объёмов данных и IT-инфраструктуры

*Источник: составлено автором
Source: compiled by the author*

Заключение

Выбор инструментов финансового мониторинга рассматривается в настоящей работе на двух взаимосвязанных уровнях. На уровне регионального регулирования матрица служит ориентиром для дифференцированной политики надзора. На уровне предприятия логика выбора определяется



прежде всего внутренними характеристиками самой организации: объёмом накопленных финансовых данных, уровнем цифровизации бизнес-процессов и наличием IT-ресурсов. Региональный контекст при этом выступает не прямым детерминантом, а средовым фактором, который формирует типичный профиль предприятий данной территории: в слаборазвитых регионах большинство предприятий объективно тяготеет к традиционным инструментам не потому, что они находятся в конкретном регионе, а потому что региональная среда обуславливает более низкий уровень их цифровизации и меньший объём накопленных данных.

Во-первых, существующие инструменты финансового мониторинга предприятий системно различаются по условиям применимости: традиционные статистические инструменты, инструменты машинного обучения и инструменты глубокого обучения предъявляют принципиально разные требования к уровню цифровизации предприятия, объёму данных и технологическому порогу входа, что в совокупности обуславливает их дифференцированную востребованность в различных региональных контекстах. Следовательно, перенос результатов, полученных в одном региональном контексте, на другой требует тщательного обоснования и не может осуществляться автоматически.

Во-вторых, уровень регионального экономического развития, состояние цифровой инфраструктуры и качество институциональной среды образуют три ключевые детерминанты адаптации инструментов. Качество институциональной среды при этом играет особую роль: именно оно определяет требования к прозрачности и интерпретируемости применяемых моделей, а также устойчивость финансового положения предприятий к внешним рискам. В-третьих, критерием выбора инструментов является «степень адаптации», а не «техническая оптимальность». В слаборазвитых регионах традиционные статистические инструменты сохраняют незаменимую практическую ценность. В регионах со средним уровнем развития инструменты машинного обучения обеспечивают оптимальный баланс между точностью и осуществимостью. Масштабное внедрение инструментов глубокого обучения требует опоры на высокоразвитую цифровую экосистему.

Для региональных регуляторов практическая ценность предложенной матрицы состоит прежде всего в том, что она задаёт ориентиры для формирования стандартов финансового мониторинга с учётом трёх ключевых параметров территории: уровня экономического развития, степени охвата цифровыми технологиями и качества институциональной среды. Особо следует подчеркнуть роль цифровой инфраструктуры: её развитие не может рассматриваться как второстепенная задача – напротив, без достаточного уровня цифровизации переход к более сложным аналитическим инструментам лишается технической основы. Не менее важен вопрос интерпретируемости моделей: последовательное освоение методов объяснимого искусственного

интеллекта открывает возможность выстраивать более обоснованный диалог между разработчиками аналитических систем и регуляторными органами, что в конечном счёте расширяет практическую применимость современных инструментов мониторинга.

Настоящее исследование имеет ряд ограничений, которые определяют направления дальнейшей работы. Прежде всего, построенная матрица носит теоретический характер: её положения не прошли верификацию на эмпирическом материале конкретных регионов, что сужает возможности для однозначных практических рекомендаций. Кроме того, предложенная система детерминант сосредоточена на трёх измерениях, тогда как человеческий капитал, исторически сложившаяся деловая культура и ряд других факторов в рамках данной работы не рассматривались. Наконец, быстрое распространение генеративных моделей и больших языковых систем ставит под вопрос долгосрочную устойчивость предложенной логики выбора инструментов и требует её периодического пересмотра по мере развития технологий.

Литература

1. Широ́в А.А., Потапенко В.В., Никитин К.М., Чаплина Ю.Ю. Организация оперативного мониторинга состояния экономики региона (на примере г. Москвы) // Проблемы прогнозирования. 2022. № 3 (192). С. 6–19. <https://doi.org/10.47711/0868-6351-192-6-19>.
2. Алехнович А.О., Анучин Л.Л., Ахиев А.О. Индекс роста малых и средних предприятий – новый инструмент мониторинга состояния сектора малого и среднего предпринимательства в России // Проблемы прогнозирования. 2021. № 4 (187). С. 134–141.
3. Строев П.В., Пивоварова О.В., Шеожев Х.В., Дудник А.И. Регионы с низкой финансовой устойчивостью: анализ и активизация развития // Финансовый журнал. 2023. Т. 15, № 1. С. 26–44. <https://doi.org/10.31107/2075-1990-2023-1-26-44>.
4. Song Y., Du H., Piao T., Shi H. Research on financial risk intelligent monitoring and early warning model based on LSTM, transformer, and deep learning // Journal of Organizational and End User Computing (JOEUC). 2024. Vol. 36, No. 1. P. 1–24.
5. Zhang Z., Liu X., Niu H. et al. Financial crisis early warning of Chinese listed companies based on MD&A text-linguistic feature indicators // PLOS ONE. 2023. <https://doi.org/10.1371/journal.pone.0291818>.
6. Becha H., Kalai M., Houdi S., Helali K. Digital financial inclusion, environmental sustainability and regional economic growth in China: insights from a panel threshold model // Journal of Economic Structures. 2025. Vol. 14, No. 1. P. 1–40. <https://doi.org/10.1186/s40008-025-00347-4>.
7. Altman E.I., Iwanicz-Drozdowska M., Laitinen E.K., Suvas A. Financial Distress Prediction in an International Context: A Review and Empirical Analysis

of Altman's Z-Score Model // *Journal of International Financial Management & Accounting*. 2017. Vol. 28, No. 2. P. 131–171. <https://doi.org/10.1111/jifm.12053>.

8. Hong S., Wu H., Xu X., Xiong W. Early Warning of Enterprise Financial Risk Based on Decision Tree Algorithm // *Computational Intelligence and Neuroscience*. 2022. <https://doi.org/10.1155/2022/9182099>.

9. Lokanan M.E., Ramzan S. Predicting financial distress in TSX-listed firms using machine learning algorithms // *Frontiers in Artificial Intelligence*. 2024. Vol. 7. <https://doi.org/10.3389/frai.2024.1466321>.

10. Theodorakopoulos L., Theodoropoulou A., Bakalis A. Big data in financial risk management: evidence, advances, and open questions: a systematic review // *Frontiers in Artificial Intelligence*. 2025. <https://doi.org/10.3389/frai.2025.1658375>.

11. Kristanti F.T., Febrianta M.Y., Salim D.F., Riyadh H.A., Sagama Y., Beshr B.A.H. Advancing financial analytics: Integrating XGBoost, LSTM, and Random Forest Algorithms for precision forecasting of corporate financial distress // *Journal of Infrastructure, Policy and Development*. 2024. Vol. 8, No. 8. Art. 4972. <https://doi.org/10.24294/jipd.v8i8.4972>.

12. Mselmi N., Lahiani A., Hamza T. Financial distress prediction: the case of French small and medium-sized firms // *International Review of Financial Analysis*. 2017. Vol. 50. P. 67–80. <https://doi.org/10.1016/j.irfa.2017.02.004>.

13. Dogan S., Kocak D., Atan M. Financial Distress Prediction Using Support Vector Machines and Logistic Regression // *Advances in Econometrics, Operational Research, Data Science and Actuarial Studies*. Springer, Cham, 2022. https://doi.org/10.1007/978-3-030-85254-2_26.

14. Gao R., Cui S., Wang Y., Xu W. Predicting financial distress in high-dimensional imbalanced datasets: a multi-heterogeneous self-paced ensemble learning framework // *Financial Innovation*. 2025. Vol. 11, No. 1. Art. 50. <https://doi.org/10.1186/s40854-024-00745-w>.

15. Liu S. LTR-Net: A deep learning-based approach for financial data prediction and risk evaluation in enterprises // *PLOS ONE*. 2025. Vol. 20, No. 8. e0328013. <https://doi.org/10.1371/journal.pone.0328013>.

16. Chen W. Enterprise financial risk prediction and intelligent early warning model based on deep learning // *Discover Artificial Intelligence*. 2025. Vol. 5. Art. 227. <https://doi.org/10.1007/s44163-025-00497-1>.

17. Purnell D., Etemadi A., Kamp J. Developing an Early Warning System for Financial Networks: An Explainable Machine Learning Approach // *Entropy*. 2024. Vol. 26, No. 9. Art. 796. <https://doi.org/10.3390/e26090796>.

18. Liu Y., Ma S., Sun M. Digital infrastructure policies, local fiscal and financing constraints of Non-SOEs: Evidence from China // *PLOS ONE*. 2025. Vol. 20, No. 7. e0327294. <https://doi.org/10.1371/journal.pone.0327294>.

19. Zhuang Y., Wei H. Early warning model and prevention of regional financial risk integrated into legal system // *PLOS ONE*. 2023. Vol. 18, No. 6. e0286685. <https://doi.org/10.1371/journal.pone.0286685>.

20. Wen C., Xiao Y., Hu B. Digital financial inclusion, industrial structure and urban–rural income disparity: Evidence from Zhejiang Province, China // PLOS ONE. 2024. Vol. 19. No. 6. <https://doi.org/10.1371/journal.pone.0303666>.

References

1. Shirov A.A., Potapenko V.V., Nikitin K.M., Chaplina Yu.Yu. (2022). Organizatsiya operativnogo monitoringa sostoyaniya ekonomiki regiona (na primere g. Moskvy) [Organization of operational monitoring of the regional economy (the case of Moscow)]. Problemy prognozirovaniya [Studies on Russian Economic Development], 3(192), 6–19. <https://doi.org/10.47711/0868-6351-192-6-19>. (In Russ., abstract in Eng.).
2. Alekhnovich A.O., Anuchin L.L., Akhiev A.O. (2021). Indeks rosta malykh i srednikh predpriyatii – novyi instrument monitoringa sostoyaniya sektora malogo i srednego predprinimatel'stva v Rossii [SME Growth Index as a new tool for monitoring the small and medium-sized business sector in Russia]. Problemy prognozirovaniya [Studies on Russian Economic Development], 4(187), 134–141. (In Russ., abstract in Eng.).
3. Stroeв P.V., Pivovarova O.V., Sheozhev Kh.V., Dudnik A.I. (2023). Regiony s nizkoi finansovoi ustoichivost'yu: analiz i aktivizatsiya razvitiya [Regions with low financial sustainability: analysis and development activation]. Finansovyi zhurnal [Financial Journal], 15(1), 26–44. <https://doi.org/10.31107/2075-1990-2023-1-26-44>. (In Russ., abstract in Eng.).
4. Song Y., Du H., Piao T., Shi H. (2024). Research on financial risk intelligent monitoring and early warning model based on LSTM, transformer, and deep learning. Journal of Organizational and End User Computing (JOEUC), 36(1), 1–24. (In Eng.).
5. Zhang Z., Liu X., Niu H. et al. (2023). Financial crisis early warning of Chinese listed companies based on MD&A text-linguistic feature indicators. PLOS ONE. <https://doi.org/10.1371/journal.pone.0291818>. (In Eng.).
6. Becha H., Kalai M., Houidi S., Helali K. (2025). Digital financial inclusion, environmental sustainability and regional economic growth in China: insights from a panel threshold model. Journal of Economic Structures, 14(1), 1–40. <https://doi.org/10.1186/s40008-025-00347-4>. (In Eng.).
7. Altman E.I., Iwanicz-Drozdowska M., Laitinen E.K., Suvas A. (2017). Financial Distress Prediction in an International Context: A Review and Empirical Analysis of Altman's Z-Score Model. Journal of International Financial Management & Accounting, 28(2), 131–171. <https://doi.org/10.1111/jifm.12053>. (In Eng.).
8. Hong S., Wu H., Xu X., Xiong W. (2022). Early Warning of Enterprise Financial Risk Based on Decision Tree Algorithm. Computational Intelligence and Neuroscience. <https://doi.org/10.1155/2022/9182099>. (In Eng.).
9. Lokanan M.E., Ramzan S. (2024). Predicting financial distress in TSX-listed firms using machine learning algorithms. Frontiers in Artificial Intelligence,

7. <https://doi.org/10.3389/frai.2024.1466321>. (In Eng.).
10. Theodorakopoulos L., Theodoropoulou A., Bakalis A. (2025). Big data in financial risk management: evidence, advances, and open questions: a systematic review. *Frontiers in Artificial Intelligence*. <https://doi.org/10.3389/frai.2025.1658375>. (In Eng.).
11. Kristanti F.T., Febrianta M.Y., Salim D.F., Riyadh H.A., Sagama Y., Beshr B.A.H. (2024). Advancing financial analytics: Integrating XGBoost, LSTM, and Random Forest Algorithms for precision forecasting of corporate financial distress. *Journal of Infrastructure, Policy and Development*, 8(8), Article 4972. <https://doi.org/10.24294/jipd.v8i8.4972>. (In Eng.).
12. Mselmi N., Lahiani A., Hamza T. (2017). Financial distress prediction: the case of French small and medium-sized firms. *International Review of Financial Analysis*, 50, 67–80. <https://doi.org/10.1016/j.irfa.2017.02.004>. (In Eng.).
13. Dogan S., Kocak D., Atan M. (2022). Financial Distress Prediction Using Support Vector Machines and Logistic Regression. In: *Advances in Econometrics, Operational Research, Data Science and Actuarial Studies*. Cham: Springer. https://doi.org/10.1007/978-3-030-85254-2_26. (In Eng.).
14. Gao R., Cui S., Wang Y., Xu W. (2025). Predicting financial distress in high-dimensional imbalanced datasets: a multi-heterogeneous self-paced ensemble learning framework. *Financial Innovation*, 11(1), Article 50. <https://doi.org/10.1186/s40854-024-00745-w>. (In Eng.).
15. Liu S. (2025). LTR-Net: A deep learning-based approach for financial data prediction and risk evaluation in enterprises. *PLOS ONE*, 20(8), e0328013. <https://doi.org/10.1371/journal.pone.0328013>. (In Eng.).
16. Chen W. (2025). Enterprise financial risk prediction and intelligent early warning model based on deep learning. *Discover Artificial Intelligence*, 5, Article 227. <https://doi.org/10.1007/s44163-025-00497-1>. (In Eng.).
17. Purnell D., Etemadi A., Kamp J. (2024). Developing an Early Warning System for Financial Networks: An Explainable Machine Learning Approach. *Entropy*, 26(9), Article 796. <https://doi.org/10.3390/e26090796>. (In Eng.).
18. Liu Y., Ma S., Sun M. (2025). Digital infrastructure policies, local fiscal and financing constraints of Non-SOEs: Evidence from China. *PLOS ONE*, 20(7), e0327294. <https://doi.org/10.1371/journal.pone.0327294>. (In Eng.).
19. Zhuang Y., Wei H. (2023). Early warning model and prevention of regional financial risk integrated into legal system. *PLOS ONE*, 18(6), e0286685. <https://doi.org/10.1371/journal.pone.0286685>. (In Eng.).
20. Wen C., Xiao Y., Hu B. (2024). Digital financial inclusion, industrial structure and urban–rural income disparity: Evidence from Zhejiang Province, China. *PLOS ONE*, 19(6). <https://doi.org/10.1371/journal.pone.0303666>. (In Eng.).