

**ФОРМИРОВАНИЕ ЦИФРОВОЙ
ЭКОНОМИКИ И РАЗВИТИЕ СКВОЗНЫХ
ЦИФРОВЫХ ТЕХНОЛОГИЙ В РОССИИ КАК
ИМПЕРАТИВ НОВОЙ ПАРАДИГМЫ
ЭКОНОМИЧЕСКОГО РОСТА**

Монография

Под редакцией Шихалиевой Д.С., Подкопаева О.А.

УДК 338.2
ББК 65.05
Ф79

Авторы монографии: Алексеева Ю.Б., Бабина Е.Н., Бабина Н.В., Белов П.С., Беляева С.В., Бобошко Д.Ю., Бондаренко Г.В., Бровченко А.А., Васильева А.С., Гарифуллин В.Ф., Добродомова Т.Н., Доронина С.А., Драгина О.Г., Зверева А.С., Ковалева Е.Ю., Коница Е.А., Кузнецова М.Н., Лаврикова Н.И., Левицкая И.А., Махов С.Л., Миронова З.А., Моргачева И.Н., Мухорьянова О.А., Новикова В.И., Рагозина М.А., Ростова О.В., Рязанцев П.В., Савенкова И.В., Салихов М.Р., Салманов О.Н., Соболевская Т.Г., Федорова Н.П., Федосеев С.В., Шабаров Д.В., Ширинкина Е.В., Шихалиева Д.С., Шмелева А.С., Шмыгалева П.В., Юшманова В.А.

Научные редакторы:

Шихалиева Джаннет Сергеевна – профессор кафедры управления и предпринимательства ФГБОУ ИВО «Московский государственный гуманитарно-экономический университет», доктор экономических наук, доцент

Подкопаев Олег Александрович – доцент кафедры экономики и управления социально-культурной деятельностью ФГБОУ ВО «Самарский государственный институт культуры», кандидат экономических наук, доцент

Рецензенты:

Круглов Владимир Николаевич – доктор экономических наук, профессор кафедры менеджмента Института управления, бизнеса и технологий

Меджидов Заур Уруджалиевич – кандидат экономических наук, доцент кафедры «Информационные технологии и информационная безопасность» ГАОУ ВО «Дагестанский государственный университет народного хозяйства»

Ф79 Формирование цифровой экономики и развитие сквозных цифровых технологий в России как императив новой парадигмы экономического роста / [Алексеева Ю.Б., Бабина Е.Н., Бабина Н.В. и др.]; Под ред. Шихалиевой Д.С., Подкопаева О.А. – Самара: ООО НИЦ «ПНК», 2023. – 300 с.

В монографии «Формирование цифровой экономики и развитие сквозных цифровых технологий в России как императив новой парадигмы экономического роста» рассматриваются концептуальные основы формирования цифровой экономики и развития сквозных цифровых технологий, развитие сквозных цифровых технологий в России как императив новой парадигмы экономического роста, генезис сквозных цифровых технологий на предприятиях России, управление инновационным потенциалом наукоемких предприятий радиоэлектронной промышленности. Монография предназначена научным и практическим работникам, преподавателям, аспирантам, магистрантам, а также широким слоям читательской аудитории, интересующимся вопросами устойчивого и динамичного развития российской социально-экономической системы, теоретико-методологическими подходами и практическими результатами исследований в данной научной области.

ISBN 978-5-6049405-6-3

© Авторы исследований, 2023

© ООО НИЦ «Поволжская научная корпорация», 2023

СОДЕРЖАНИЕ

ВВЕДЕНИЕ	5
1. КОНЦЕПТУАЛЬНЫЕ ОСНОВЫ ФОРМИРОВАНИЯ ЦИФРОВОЙ ЭКОНОМИКИ И РАЗВИТИЯ СКВОЗНЫХ ЦИФРОВЫХ ТЕХНОЛОГИЙ	6
1.1. Обеспечение экономической безопасности России как неотъемлемое условие экономического роста	6
1.2. Цифровые экосистемы и их роль в развитии малого и среднего предпринимательства в РФ	15
1.3. Тенденции развития цифровой экономики в современных условиях	28
2. РАЗВИТИЕ СКВОЗНЫХ ЦИФРОВЫХ ТЕХНОЛОГИЙ В РОССИИ КАК ИМПЕРАТИВ НОВОЙ ПАРАДИГМЫ ЭКОНОМИЧЕСКОГО РОСТА	41
2.1. Внедрение сквозных цифровых технологий в информационном пространстве социальных систем	41
2.2. ESG-банкинг как долгосрочный ориентир развития банковского сектора России	52
2.3. Сравнительный анализ развития онлайн-образования в России, Китае и Бразилии	58
2.4. Правовые аспекты применения технологий искусственного интеллекта	69
2.5. Тенденции развития цифровых технологий в России: теоретические и практические аспекты	77
2.6. Анализ тенденций мирового и российского инновационного развития и роли в нем цифровых технологий	91
3. ГЕНЕЗИС СКВОЗНЫХ ЦИФРОВЫХ ТЕХНОЛОГИЙ НА ПРЕДПРИЯТИЯХ РОССИИ	103
3.1. Эффективное управление предприятием в условиях цифровой экономики	103
3.2. Тенденции и перспективы использования сквозных цифровых технологий в маркетинге	114
3.3. Аудит эффективности деятельности коммерческой организации: сущность, значение и модель проведения	127
3.4. Развитие методов прогнозирования корпоративных банкротств	140
3.5. Цифровые технологии в системе профессиональной переподготовки прокурорских работников: теоретический и прикладной аспект	165
3.6. Стратегия обеспечения единства экономического пространства путем развития когнитивных компетенций управленческого персонала	178
3.7. Бизнес-стратегирование компаний в условиях цифровой трансформации	189

3.8. Сквозной цикл автоматизированного проектирования в машиностроении	202
4. УПРАВЛЕНИЕ ИННОВАЦИОННЫМ ПОТЕНЦИАЛОМ НАУКОЕМКИХ ПРЕДПРИЯТИЙ РАДИОЭЛЕКТРОННОЙ ПРОМЫШЛЕННОСТИ	226
4.1. Теоретические аспекты управления инновационным потенциалом наукоемких предприятий радиоэлектронной промышленности	229
4.2. Методические основы оценки управления инновационным потенциалом наукоемких предприятий радиоэлектронной промышленности	266
4.3. Разработка модели управления инновационным потенциалом наукоемких предприятий радиоэлектронной промышленности	275
ЗАКЛЮЧЕНИЕ	296
КРАТКИЕ СВЕДЕНИЯ ОБ АВТОРАХ	297

3.4. Развитие методов прогнозирования корпоративных банкротств¹³

Введение

Прогнозирование банкротства уже давно является важной проблемой в науке о финансах и менеджменте, которая привлекает внимание исследователей и практиков. С большим развитием современных информационных технологий он превратился в использование алгоритмов машинного обучения или глубокого обучения для прогнозирования на основе первоначального анализа финансовой отчетности.

Прогнозирование корпоративного банкротства, является актуальной проблемой в области корпоративных финансов, поскольку финансовая устойчивость фирмы очень важна для всех экономических агентов, которые сотрудничают с фирмой: банки, биржи, акционеры, инвесторы, покупатели продукции и поставщиков сырья. Корпоративный сектор является одним из крупнейших заемщиков средств на рынке капитала. Рынок корпоративного долга огромен.

1. Модели кредитного риска, основанные на данных бухгалтерского учета и рыночной стоимости

От одномерных к многомерным методам

Одномерный подход позволяет аналитику установить, как финансовый коэффициент отличается от нормы по отрасли. Но финансовые коэффициенты имеют, как правило, разнонаправленность и появляется неопределенность их интерпретации.

Одно из классических исследований пропорционального анализа и банкротства было проведено Бивером [22]. Бивер обнаружил, что по ряду показателей можно провести различие между сопоставимыми выборками обанкротившихся и не обанкротившихся фирм за пять лет до банкротства.

Однако важность финансовых коэффициентов, принятых в исследовании, уровень их значимости остался невыясненным. Таким образом, подходящим расширением однофакторных исследований было использование их результатов путем объединения нескольких показателей в значимую прогностическую модель. При построении многомерной системы ключевыми вопросами являются:

1. Какие коэффициенты являются наиболее важными для выявления потенциала банкротства?
2. Какие веса следует придать этим выбранным соотношениям?
3. Как должны объективно устанавливаться веса?

Модель Z-SCORE Альтмана (1968)

Альтманом [11] была построена первая многомерная модель оценки кредитоспособности, названная Z-Score, которая объединила ряд показателей финансовой отчетности и рыночной стоимости. Полученная оценка затем

¹³ Авторы раздела: Салманов О.Н., Бабина Н.В.

использовалась для классификации наблюдения (фирмы) либо в несостоятельную, либо в устойчивую категорию.

Метод статистической классификации, который использовал автор, был дискриминантным анализом, который является одним из семейства статистических методов, доступных для разделения или прогнозирования состояния компаний.

Он в основном используется для классификации в задачах, где зависимая переменная является дихотомичной. Сначала создаются группы, затем данные собираются по группам. Метод анализирует набор переменных для максимизации межгрупповой дисперсии при минимизации внутригрупповой дисперсии. Это производится последовательно, и исследователь подбирает переменные на основе различных статистических критериев, как правило стремясь к максимуму дисперсии между группами при минимуме дисперсии внутри группы.

Линейная форма

$$Z = a_1x_1 + a_2x_2 + a_3x_3 + \dots + a_nx_n$$

Z = дискриминантная оценка (Z -оценка),

$a_1 \dots a_n$ = дискриминантные коэффициенты (веса),

$x_1 \dots x_n$ = Дискриминантные переменные (например, коэффициенты).

Из исходного списка 22 переменных окончательной моделью Z -Score была выбрана следующая модель с пятью переменными

$$Z = 1,2X_1 + 1,4X_2 + 3,3X_3 + 0,6X_4 + 0,999X_5$$

$$1. X_1 = WC/TA = \text{Оборотные средства} / \text{Общие активы}$$

$$2. X_2 = RE/TA = \text{Нераспределенная прибыль} / \text{Общие активы}$$

$$3. X_3 = EBIT/TA = \text{Прибыль до вычета процентов и налогов} / \text{Активы}$$

Этот коэффициент является мерой производительности активов фирмы, независимой от каких-либо налоговых факторов или факторов заемных средств.

$$4. X_4 = MVE/TL = \frac{\text{Рыночная стоимость собственного капитала}}{\text{Балансовая стоимость долгов}}$$

$$5. X_5 = S/TA = \text{Продажи} / \text{Общие активы}$$

Окончательная дискриминантная функция выражается

$$Z = 1,2 WC/TA + 1,4 RE/TA + 3,3 EBIT/TA + 0,6 MVE/TL + 0,999 S/TA$$

Точность классификации выражается как точность типа I (точность, с которой модель идентифицировала несостоятельные фирмы как неустойчивые) и точность типа II (точность, с которой модель идентифицировала устойчивые фирмы как таковые). Общая точность представляет собой комбинацию типа I и II. В контексте классификации суть метода MDA состоит в том, чтобы отнести фирму к несостоятельной или несостоятельной группе на основе ее дискриминантного балла. Фирма будет отнесена к группе, на которую она больше всего «напоминает».

В соответствии с некоторой оптимальной точкой отсечения для модели MDA классификация достигается следующим образом: фирма попадает в группу

неудачников, если ее дискриминантный балл (D_i) меньше точки отсечения, и она классифицируется в благополучную группу, если ее оценка D_i превышает или равна точке отсечки.

Для этой модели Альтман установил границы оптимальности с 1,81 до 2,99. А в диапазоне данных границ есть зона незнания.

Присвоение соответствующих вероятностей дефолта корпоративным кредитным активам представляет собой трехэтапный процесс, включающий последовательное использование:

1. Модели кредитного скоринга.
2. Эквиваленты риска рынка капитала — обычно рейтинги облигаций.
3. Назначение вероятности (PDs) и, возможно потери, LGD по кредитному портфелю.

Эквиваленты рейтингов облигаций

Получить вероятность дефолта или убытков при дефолте (LGD - Loss given default) можно путем связи расчетных кредитных рейтингов с рейтингами, которые присвоены ценным бумагам рейтинговые агентства.

В отношении нерейтинговых организаций можно рассчитать балл на основе какой-либо доступной модели и, возможно, связать его с эквивалентом рейтинга облигаций. Последнее затем может привести к оценке PD. Например, в таблице 1 перечислены эквиваленты рейтингов облигаций для различных интервалов Z-показателей на основе средних Z-показателей для облигаций, оцененных в соответствующих категориях. Можно заметить, что в период 2004–2005 гг. облигации тройного класса А имели средний Z-показатель 5,31, в то время как облигации одинарного класса В имели средний показатель 1,79. Напомним, что оценка 1,8 была верхней границей зоны неблагоприятия нашего исходного Z-показателя. Мы также указываем, что средний балл фирм, которые обанкротились, был чуть ниже нуля (-0,19).

Одним из основных применений моделей кредитного скоринга является присвоение рейтинга облигаций, эквивалентного каждому баллу. Это позволяет аналитику оценить вероятность дефолта заявителя, наблюдая за историческим опытом рейтинга каждой облигации.

Таблица 1. Средний показатель банкротства Z-Score по рейтингу облигаций S&P

Рейтинг	2004–2005	1996–2001	1992–1995
AAA	5,31	5,60	4,80
AA	4,99	4,73	4,15
A	4,22	3,74	3,87
BBB	3,37	2,81	2,75
BB	2,27	2,38	2,25
B	1,79	1,80	1,87
CCC	0,45	0,33	0,40
D	-0,19	-0,20	0,05

Источник: Altman and Hotchkiss [12].

Модель Альтмана Z-SCORE для частной фирмы

Чтобы оценить частные производственные компании, Альтман [10] пересмотрел исходную модель Z-Score, заменив балансовую стоимость на рыночную стоимость при расчете коэффициента X_4 .

$$4. X_4 = \frac{MVE}{ML} = \frac{\text{Рыночная стоимость собственного капитала}}{\text{Рыночная стоимость совокупных обязательств}}$$

Переоценив всю модель, поскольку меняются все коэффициенты, он пришел к следующей модели Z-Score:

$$Z^P = 0,717X_1 + 0,847X_2 + 3,107X_3 + 0,420X_4 + 0,998X_5$$

Пересмотренный показатель балансовой стоимости по-прежнему является третьим по значимости фактором. Действительно, порядок важности (т. е. X_3 , X_2 , X_4 , X_5 и X_1) был сохранен в модели частной фирмы.

$Z < 1,23$ = Зона I (отсутствие ошибок в классификации банкротства);

$Z > 2,90$ = зона II (отсутствие ошибок в классификации не банкротства);

Серая область = от 1,23 до 2,90. Источники: Альтман [11,12].

Непроизводственная модель Z-SCORE

Затем Альтман разработал модель, в которой исключался X_5 . С помощью исключения коэффициента выручки к общим активам достигалось снижение влияния оборачиваемости активов, которая является чувствительной переменной в непроизводственной сфере.

Новая модель Z-Score

$$Z^{NM} = 6,56X_1 + 3,26X_2 + 6,72X_3 + 1,05X_4$$

Изменяются все коэффициенты для переменных от X_1 до X_4 , а также групповые средние значения и пороговые значения. Эта конкретная модель полезна в отраслях, где фирмы финансируют свои активы очень по-разному и где корректировки, такие как капитализация аренды, не производятся. Хорошим примером этого является сектор розничной торговли.

Модель и процесс оценки развивающихся рынков

В модели развивающегося рынка был добавлен постоянный член +3,25, чтобы стандартизировать оценки с нулевой (0) оценкой, эквивалентной облигации с рейтингом D- (дефолт).

$$Z'' = 3,25 + 6,56X_1 + 3,26X_2 + 6,72X_3 + 1,05X_4$$

Эта модель использовалась для оценки финансового состояния неамериканских корпораций [15]. Ряд исследователей и практиков разработали модели типа Z-оценки во многих странах за пределами США [12].

Кредиты развивающихся рынков могут первоначально анализироваться аналогично традиционному анализу американских корпораций. После получения количественной оценки риска аналитик может использовать качественную оценку, чтобы усовершенствовать ее с учетом таких отраслевых факторов.

Не в каждой развивающейся стране есть рейтинг облигаций и статистика банкротств. В силу этого нет возможности построить модель для такой страны.

Чтобы решить эту проблему, Альтман и др. [15] модифицировали исходную модель Altman Z-Score, чтобы создать модель EMS (Emerging Market Scoring).

Таблица 2. Z-показатель и эквивалентный рейтинг облигаций

Зона	Z''- Score	Эквивалент ный рейтинг США	Рейти нг	Зон а	Z''- Score	Эквивалент ный рейтинг США	Рейтинг
Зона безопасно сти	8,15	>8,15	AAA	5,65	5,85	BBB-	Серая зона
	7,60	8,15	AA+	5,25	5,65	BB+	
	7,30	7,60	AA	4,95	5,25	BB	
	7,00	7,30	AA-	4,75	4,95	BB-	
	6,85	7,00	A+	4,50	4,75	B+	
	6,65	6,85	A	4,15	4,50	B	Банкротс тво
	6,40	6,65	A-	3,75	4,15	B-	
	6,25	6,40	BBB+	3,20	3,75	CCC+	
5,85	6,25	BBB	2,50	3,20	CCC		
				1,75	2,50	CCC-	
				<1,7 5	1,75	D	

Модель кредитного риска ZETA^R

В 1977 году авторы разработали модель, которая отражала изменения в бухгалтерской отчетности [14].

Модель с 7 переменными

Модель не только хорошо классифицировала тестовую выборку, но и оказалась наиболее надежной в различных процедурах валидации.

В этой модели следующие изменения в составе переменных:

Стабильность прибыли, X_2 ; обслуживание долга, X_3 ; размер, X_7 .

Точность классификации ZETA, по мнению автора [14], в сравнении с точностью модели Z-Score увеличивается. Объясняется это учетом улучшений, внесенных в разработку модели — ZETA более точен, чем Z-Score, особенно в более отдаленные годы, предшествующие банкротству.

Модель Альмана и Сабато для малого и среднего бизнеса (МСП)

Альтман и Сабато [13] построили модель типа Z-Score для малого и среднего бизнеса (малые и средние предприятия, определяемые как фирмы с годовым объемом продаж от 1 до 65 миллионов долларов и совокупными активами от 1 до 100 миллионов долларов). В этой модели используются пять финансовых коэффициентов и данные о 120 дефолтах и 1890 не дефолтах за период 1994–2002 гг. Коэффициенты следующие (в скобках указана учетная категория этих коэффициентов):

- Краткосрочная задолженность/балансовая стоимость собственного капитала (леверидж)
- Денежные средства/общие активы (ликвидность)
- EBITDA/общие активы (прибыльность)

- Нераспределенная прибыль/общие активы (покрытие)
- EBITDA/Процентные расходы (счет)

Две версии модели были построены с использованием логистической регрессии: первая использовала переменные как они есть, а вторая применяла к переменным логарифмическое преобразование.

Модель была также переоценена с использованием множественного дискриминантного анализа (MDA), и было обнаружено, что результаты проверки MDA несколько уступают результатам логистической регрессии (коэффициент точности 59,87 процента по сравнению с 87,22 процента для зарегистрированных предикторов)

2. Модели условной вероятности

После периода, когда MDA явно доминировали, этот метод был заменен менее требовательными статистическими методами, такими как логит-анализ (LA), пробит-анализ (РА) и линейное вероятностное моделирование (LPM). Эти методы приводят к «моделям условной вероятности» Zavgren [78], Doumpos & Zoroudinis, [34], состоящим из комбинации переменных, которые лучше всего различают группу несостоятельных и несостоятельных фирм. James A. Ohlson [53] был пионером в использовании логит-анализа финансовых коэффициентов для прогнозирования банкротства компании, а Zmijewski [80] был пионером в применении пробит-анализа (ПА).

До сих пор ЛА считался очень популярным методом прогнозирования банкротств. Количество исследований с использованием ПА намного меньше, вероятно, потому что этот метод требует больше вычислений.

Модели условной вероятности позволяют оценить вероятность банкротства компании в зависимости от ряда характеристик фирмы с помощью нелинейной оценки максимального правдоподобия.

Модели основаны на определенном допущении относительно распределения вероятностей. Логит-модели предполагают логистическое распределение, тогда как пробит-модели предполагают нормальное распределение.

Отличие моделей этой группы проистекает из распределений вероятности дефолта и характера функциональной зависимости между финансовыми коэффициентами заемщика и его вероятностью банкротства. В практическом применении выделяются функции распределения стандартного нормального закона:

$$\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt$$

и логистического закона:

$$\Lambda(x) = \frac{1}{1 + e^{-x}}$$

При применении в модели бинарного выбора функции применения стандартного нормального закона такая модель называется пробит-моделью

(*probit-model*), а в случае применения логистического закона – логит-моделью (*logit-model*).

Вероятность дефолта *i*-ой компании:

$$p_i = P(y_1 = 1) = F(X_i^T \beta)$$

где β – вектор коэффициентов модели для каждой из объясняющей переменной.

Отсюда можем выразить:

$$E(Y) = Pr(Y = 1) = F\left(\beta_0 + \sum_{j=1}^k \beta_j X_j\right)$$

Тогда логит-модель может быть представлена:

$$P(y_1 = 1) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_n X_{in})}}$$

где X_{ij} – значение *j*-го показателя для *i*-ой компании, β_j – регрессионный коэффициент для *j*-го показателя; *n* – количество показателей (объясняющих переменных) [4].

Поскольку логит-анализ явно является наиболее популярным методом условной вероятности в литературе по прогнозированию корпоративных банкротств, мы сосредоточимся на этом конкретном методе условной вероятности и не будем подробно останавливаться на других.

Логистическая функция подразумевает, что логит-показатель (то есть вероятность отказа) $P1$ имеет значение в интервале $[0,1]$. Когда статус сбоя кодируется как единица (ноль), высокий (низкий) логит-показатель указывает на высокую вероятность сбоя и, следовательно, на плохое финансовое состояние. В контексте классификации суть модели ЛА состоит в том, чтобы отнести фирмы к несостоятельным или несостоятельным группам на основе их «логит-показателя» и определенного порогового балла для модели. В случае, когда отказ кодируется как единица, а высокий логит-показатель указывает на высокую вероятность отказа, фирма классифицируется в несостоятельную группу, если ее логит-показатель превышает точку отсечения, и классифицируется в несостоятельную группу, если ее оценка ниже или равна пороговому значению. Подобно MDA, модель ЛА основана на принципе «сходства»: фирмы относятся к группе, на которую они больше всего похожи.

Как и в модели MDA, точность классификации или «производительность» модели ЛА можно оценить на основе частоты ошибок типа I и типа II, процента правильных классификаций, невзвешенной частоты ошибок, рабочей кривой приемника (Steele, [66]), функция компромисса, коэффициент Джини (Ooghe et al., [54]; Ooghe & Balcaen, [55]), R^2 -тип меры и меры, основанные на энтропии (Joos et al., [43]).

При применении ЛА не делается никаких предположений относительно распределения независимых переменных — ЛА не требует многомерных переменных с нормальным распределением или равных дисперсионных матриц — или относительно априорных вероятностей отказа (Ohlson [53]; Zavgren, [78]; Joos et al., [40]). Поскольку ЛА не требует ограничительных допущений MDA и позволяет работать с непропорциональными выборками, метод ЛА обычно

считается «менее требовательным», чем MDA. Тем не менее, ЛА основывается на двух предположениях. Во-первых, метод ЛА требует, чтобы зависимая переменная была дихотомической, а группы были дискретными, непересекающимися и идентифицируемыми.

Во-вторых, при выборе оптимальной вероятности отсечения следует учитывать стоимость частоты ошибок типа I и типа II. Однако из-за субъективности выбора этих издержек неправильной классификации на практике (Steele, [65]) большинство исследователей минимизируют общую частоту ошибок и, следовательно, имплицитно предполагают равные издержки ошибок первого и второго рода (Ohlson, [53], Zavgren, [78]). Ohlson [53] — один из немногих исследователей, которые прямо признали влияние выбора стоимости ошибки на соответствующую частоту ошибок. Он сообщает о частоте ошибок своей модели для различных пороговых значений, связанных с различной стоимостью ошибки. Точно так же Ooghe et al. [57] приводят таблицу с несколькими возможными пороговыми значениями (для любого коэффициента стоимости ошибок) и соответствующие результаты работы модели, и приводят таблицы перцентилей с возможными точками отсечки для несостоятельных и несостоятельных компаний. Это позволяет внешнему пользователю модели оценить производительность модели для любой комбинации стоимости ошибок. С другой стороны, Koh [44] показал, что в его модели ЛА выбор оптимальной точки отсечения довольно нечувствителен и, следовательно, устойчив к различным спецификациям затрат на ошибочную классификацию.

В логит-анализе нет предположений относительно распределения независимых переменных и априорных вероятностей неудач, ЛА обладает рядом других важных преимуществ. Во-первых, выход модели ЛА, логит-показатель, представляет собой показатель от нуля до единицы. Это позволяет сразу оценить вероятность дефолта (Ohlson, [53]; Ooghe et al., [57]). Затем, полученные коэффициенты в модели логит-анализа, можно истолковывать отдельно как значимость каждой из независимых переменных в объяснении оценочной вероятности отказа (Ohlson, [53]; Zavgren, [78]), при условии, что между переменными нет мультиколлинеарности. В-третьих, модели ЛА допускают качественные переменные с категориями, а не с непрерывными данными. В этом случае используются фиктивные переменные (Ohlson, [53]; Joos et al., [40]). Наконец, привлекательна нелинейная форма логит-функции. Лежащая в основе логистическая функция подразумевает, что по сравнению с фирмой со средним здоровьем чрезвычайно здоровая (или слабая) компания должна испытать пропорционально большее ухудшение (или улучшение) своих переменных, чтобы ухудшить (или улучшить) свой показатель финансового здоровья. ((Laitinen & Kankaanraa [47]).

Тем не менее, ЛА имеет и ряд серьезных недостатков. Во-первых, ЛА-модели чрезвычайно чувствительны к проблеме мультиколлинеарности. Следует избегать включения переменных с высокой степенью корреляции (Ooghe et al., [57]; Joos et al., [40]; Doumpos & Zoroudinis, [34]). Однако, поскольку большинство моделей ЛА основаны на финансовых коэффициентах, которые сами по себе сильно коррелированы, поскольку часто имеют один и тот же

числитель или знаменатель, проблема мультиколлинеарности может быть серьезной (Tucker, [74]). Во-вторых, LA-модели очень чувствительны к выбросам (т. е. несогласованным наблюдениям) и отсутствующим значениям.

Наконец, хотя логит-модели не требуют нормального распределения переменных, они остаются чувствительными к крайней ненормальности. Следовательно, перед оценкой модели LA данные сначала необходимо преобразовать или удалить (удаление выбросов), чтобы приблизить или улучшить нормальность.

Хотя классические статистические методы MDA и LA широко используются в исследованиях прогнозирования корпоративных отказов, существует ряд общих проблем, связанных с применением этих методов к теме прогнозирования корпоративных отказов. В этом разделе представлен обширный обзор и обсуждение проблем, связанных с (1) предположением о дихотомической зависимой переменной, (2) методом выборки, (3) предположением о стационарности и нестабильностью данных, (4) выбором независимых переменных, (5) использование информации о годовом отчете и (6) измерение времени.

Включение макроэкономических переменных

В классических исследованиях, посвященных вопросам банкротства, использовались только бухгалтерские и рыночные данные. Однако со временем стало ясно, что любая модель, содержащая только информацию из финансовой отчетности, не может точно предсказать неудачу или несостоятельность фирмы (Zavgren, [78]). Поэтому исследователи стали вводить в модели банкротства новые виды показателей. В целом все факторы, связанные с банкротством, можно разделить на две основные категории: внутренние и внешние. В свою очередь, внутренние делятся на факторы бухгалтерского учета и корпоративного управления, а внешние – на макроэкономические и рыночные факторы (Fedorova et.al., [36]).

Многочисленные исследования подтверждают зависимость между макроэкономическими переменными (такими как ВВП, рост ВВП, инвестиции в основной капитал, экспорт и импорт товаров и услуг, процентная ставка, курсы основных валют, волатильность валютного курса, денежная масса, денежный агрегат, отношение объемов кредитов к ВВП, уровень цен, стоимость нефти) и уровнем банкротств.

Вклад российских авторов в прогнозирование банкротств

Первые работы, включая работу Иркутской государственной экономической академии, А.Д. Шеремета и Н.Г. Кондракова, Г.И. Савицкой, Зайцевой, Р.С. Сайфулина и Г.Г. Кадыкова, Л.В. Донцовой и Н.А. Никифоровой были направлены в определенной мере на адаптацию модели Альтмана, но не оказались успешными. В основном модели позволяли рассчитывать рейтинг.

Богданова Т.К. и Баклакова А.В. [1] построили модель логистической регрессии для прогнозирования вероятности банкротства авиапредприятий. Луговская [50] анализирует российские дефолтные компании с помощью линейного дискриминантного анализа, Жданов и Афанасьев [3] используют линейный дискриминантный анализ и логит-модель, а, Гиленко, Довженко и

Фёдорова [2], концентрируются на логит- и пробит-моделях, Макеева и Бакурова [5] применяют нейронные сети. При этом авторы не учитывают размер компаний. Тотьмянина К.М. [6], Карминский А.М. [4] разработали logit-модель вероятности дефолта корпоративных заемщиков строительной отрасли с учетом макроэкономической конъюнктуры.

Федорова Е. и др. [36] применяя методы машинного обучения для прогнозирования банкротства в выборке французских, итальянских, российских и испанских фирм, установили, что включение показателя неопределенности экономической политики (EPU) в модели прогнозирования банкротства заметно повышает их точность.

Ограничения многомерных моделей

Хотя во многих случаях было показано, что многомерные модели кредитного скоринга, основанные на бухгалтерском учете, достаточно хорошо работают в разные периоды времени и во многих разных странах (Altman and Narayanan, [14]), они также подвергались критике по ряду других причин. Поскольку они основаны главным образом на учетных данных по балансовой стоимости (которая измеряется с дискретными интервалами), эти модели могут не учитывать более тонкие и быстро меняющиеся условия заемщика, т. е. те, которые могли бы быть отражены в данных и значениях рынка капитала. Кроме того, мир по своей сути нелинейный. В результате линейный дискриминантный анализ и линейные вероятностные модели могут оказаться не такими точными, как модели, которые ослабляют базовое предположение о линейности независимых переменных. Эта проблема была решена в некоторых из последних моделей, таких как RiskCalc и CreditModel.

Поскольку данные бухгалтерского учета дают неполную картину истинного состояния и перспектив фирмы, любая модель, основанная на этих данных, неизбежно должна страдать определенными ограничениями. Поскольку бухгалтеры еще не придумали хороший способ отчета о внебалансовых рисках, такие модели не могут хорошо справляться с этими рисками. Кроме того, по причинам, связанным с оценкой активов, структурой баланса или регулированием, эти модели не могут измерить риск коммунальных предприятий, финансовых компаний, новых компаний и компаний в добывающих отраслях, таких как нефть и горнодобывающая промышленность.

Производительность и недостатки

Точность классификации или «производительность» модели MDA в основном оценивается на основе частоты ошибок типа I и типа II. Кроме того, часто используется процент правильных классификаций или невзвешенная частота ошибок⁶. Помимо этих мер погрешности, которые все требуют определения определенной точки отсечки, производительность модели MDA также может быть оценена на основе стохастического доминирования. В этом отношении «Рабочая кривая получателя (Receiver Operating Characteristic Curve - ROC)» (Steele, [66]) и «компромиссная функция» (Ooghe et al., [55]) дают четкое графическое представление производительности приемника. модели и не требуют указания точки отсечки. Чем больше площадь под ROC или чем ближе функция компромисса к обеим осям, тем лучше производительность модели. В

том же контексте коэффициент Джини является очень подходящим критерием эффективности модели. Коэффициент Джини представляет собой агрегированный показатель эффективности, отражающий разницу между функцией компромисса модели и функцией компромисса недискриминационной модели: чем выше коэффициент Джини, тем лучше. дискриминация между несостоятельными и несостоятельными фирмами (Ooghe et al., [55]).

Другими возможными показателями эффективности являются показатели типа R^2 и показатели, основанные на энтропии. Показатели типа R^2 указывают процентную долю дисперсии, которая объясняется моделью. Например, мера подсчета R^2 сообщает о количестве правильно и ошибочно классифицированных фирм. Меры, основанные на энтропии, используются в качестве показателей эффективности в исследованиях по прогнозированию неудач, например, Zavgren, [78]. Эти энтропийные меры оценивают только различительную способность модели и не позволяют апостериорно учитывать затраты на ошибочную классификацию и пропорции населения.

Хотя Altman & Eisenbeis [9] отмечают, что мультиколлинеарность среди независимых переменных не создает проблем в моделях MDA, большинство авторов согласны с тем, что, когда корреляция между независимые переменные серьезны, коллинеарность, возможно, вызывает некоторые проблемы. Это приводит к нестабильным и труднообъяснимым оценкам параметров и может влиять на точность результатов классификации. (Joy & Tollefson, [41]; Ooghe et al., [57]; Back et al., [17]). Следовательно, следует проводить корреляционный анализ и мультиколлинеарные тесты и избегать включения переменных с высокой степенью корреляции в модель MDA.

Методика MDA исходит из нескольких предположений. Прежде всего, MDA предполагает, что набор данных является дихотомическим: группы дискретны, непересекающиеся и идентифицируемые.

Во-вторых, использование MDA также основано на трех ограничительных допущениях: (1) многомерная нормальность распределения, 2) равенство матриц групповой дисперсии между финансово устойчивыми и неустойчивыми, 3) безусловная вероятность отказа. Указанные статистические предположения как правило, редко удовлетворяют данным, и в силу чего выводы могут вызывать сомнения (Joy & Tollefson, [41]; Zavgren, [78]).

Первое статистическое допущение о многомерной нормальности часто нарушается (Taffler, [69]; Barnes, [21]), что может привести к систематической ошибке в критериях значимости и в оценках частоты ошибок (Richardson & Davidson, [60]). Здесь следует упомянуть, что многомерное нормальное распределение априори требует одномерной нормальности (Karels & Prakash, [42]). По этой причине некоторые исследователи проверяют одномерную нормальность переменных и косвенно пренебрегают проверкой многомерной нормальности. Следует отметить, что имеется достаточно доказательств того, что переменные финансового коэффициента, которые в основном используются в моделях MDA, обычно демонстрируют ненормальное распределение (Barnes, [20, 21]). Некоторые исследователи делают поправку на одномерную ненормальность и пытаются аппроксимировать одномерную нормальность

путем преобразования переменных перед оценкой своей модели. Taffler [68]) и Altman et al. [14], например, принудили свои ненормальные переменные к нормальному распределению с помощью нормализующего преобразования. В литературе нет общих указаний относительно соответствующего преобразования для приближения к нормальности. Например, Taffler [68] преобразовывал переменные с помощью обратных или логарифмических преобразований. Альтман и др. [14] использовали логарифмическое преобразование, а Deakin [33] предоставил доказательства того, что использование квадратного корня или логарифмически нормального преобразования финансовых коэффициентов может привести к нормальному распределению.

Другие исследователи аппроксимируют одномерную нормальность, «обрезая» выбросы перед оценкой своей модели. Обрезка может включать в себя «удаление выбросов», что включает в себя разделение выбросов по отношению к нормальному распределению, или «упорядочивание», которое касается изменения значения выброса на значение ближайшего не выброса, чтобы, наконец, распределение соответствовало нормальному распределению (Taffler, [68]; Barnes, [21]; Ooghe et al., [56]). Хотя преобразование переменных может привести к нормально распределенным переменным, (1) предположение о многомерной нормальности все еще нарушается и (2) преобразование может изменить взаимосвязь между переменными (Eisenbeis, [35]) и, следовательно, может исказить модель MDA. Подводя итог, можно сказать, что к этому вопросу нужно подходить с осторожностью.

Второе допущение, которое необходимо проверить перед разработкой модели MDA, — это допущение о равных дисперсионных матрицах. Если это допущение нарушается, это повлияет на тесты значимости различий переменных средних между несостоятельной и несостоятельной группой фирм. Кроме того, в случае неравных дисперсионных матриц необходимо использовать правило квадратичной классификации – квадратичную модель MDA (Eisenbeis, [35]; Zavgren, [78]). На практике, однако, исследователи избегают работы с квадратичными моделями MDA, потому что эти модели очень сложны и, по-видимому, превосходят линейные модели MDA только в случае (1) больших выборок, (2) небольшого числа независимых переменных относительно выборки. и (3) очень существенные различия в дисперсионных матрицах.

Поэтому они просто пытаются преобразовать данные таким образом, чтобы матрицы дисперсии не слишком различались, и применяют линейный MDA (Taffler, [67]).

Третье допущение гласит, что при выборе оптимальной пороговой оценки оценочной модели априорные вероятности принадлежности к несостоятельной или несостоятельной группе (т. е. совокупности) и затраты типа I и следует учитывать ошибку второго рода (Eisenbeis, [35]; Deakin, [32]; Zavgren, [78]; Steele, [65]). Если это ограничительное допущение нарушается, заявленная точность модели MDA будет необъективной и не будет указывать на точность модели применительно к генеральной совокупности. В этом отношении Deakin [32] отмечает, что для получения точного представления о частоте ошибок,

которые могут быть получены при применении модели в «реальном мире», требуется спецификация априорных вероятностей и затрат на ошибочную классификацию. Оптимальная точка отсечения должна быть получена в результате минимизации «функции общих потерь», которая включает частоту ошибок и соответствующие доли населения, а также затраты на ошибочную классификацию. На практике, однако, определение стоимости ошибки представляется очень субъективным решением: стоимость последствий, связанных с обоими типами ошибок, в основном неосвязаема и неизмерима и зависит от рискованного поведения лица, принимающего решение, и его действий. или ее отношение к пропорции стоимостных факторов. Кроме того, определение пропорций населения представляется очень сложным и субъективным, поскольку необходимо выбрать определенный учетный период.

В отличие от Альтмана и др. [14] и Taffler [67], которые являются двумя исследованиями из небольшого числа, в которых принимается во внимание отношение обеих издержек ошибок, большинство исследователей пренебрегают указанием издержек ошибок и/или долей населения. Они неявно предполагают, что (1) затраты на ошибочную классификацию равны и что (2) пропорции выборки равны пропорциям генеральной совокупности. Очевидно, что пренебрежение этими факторами имеет некоторые важные последствия. Поскольку на практике затраты на неправильную классификацию несостоятельной фирмы (ошибка I типа) часто намного выше, чем затраты на неправильную классификацию несостоятельной фирмы (ошибка II рода), пренебрежение затратами на неправильную классификацию обычно приводит к относительно высоким потерям I рода ошибки. Напротив, поскольку частота популяции не банкротящихся фирм намного больше, чем частота популяции несостоятельных фирм, пренебрежение частотами популяции подразумевает слишком сильное внимание к уменьшению числа ошибок первого рода, что приводит к относительно низкой частоте ошибок первого рода и относительно высокой частоте ошибок. ошибка II рода.

Однако существуют некоторые возможные решения проблем, связанных с определением оптимальной точки отсечки. Первое решение состоит в том, чтобы сообщить о результатах классификации (ошибки типа I и типа II) модели для различных пороговых значений.

Другим вариантом является метод «черно-серо-белый». Этот метод определяет более низкую пороговую оценку как оценку, в которой модель имеет 0% ошибки типа II, и более высокую пороговую оценку как оценку с 0% ошибкой типа I. Область между этими двумя оценками является серой зоной. При применении этого метода «черное-серое-белое» предсказательная сила модели оценивается процентом фирм, попадающих в серую зону.

Хотя MDA является наиболее часто используемым методом моделирования при прогнозировании отказов, он имеет ряд серьезных недостатков, помимо проблем, связанных с нарушением основных допущений. Во-первых, MDA требует, чтобы правило классификации было линейным, а это означает, что дискриминантный показатель выше или ниже определенного порогового значения автоматически сигнализирует о хорошем или плохом

финансовом состоянии. В том же отношении правило классификации MDA интуитивно противоречит тому факту, что некоторые переменные не показывают линейной связи с финансовым здоровьем: некоторые переменные указывают на финансовые проблемы как при очень низком, так и при очень высоком значении.

Во-вторых, мы должны иметь в виду, что дискриминантные баллы являются лишь порядковыми мерами, которые позволяют проводить относительное (порядковое) ранжирование между фирмами. MDA также может генерировать вероятности отказа, но для этого требуется субъективная и, возможно, неточная оценка вероятностей, связанных с конкретными дискриминантными показателями (Zavgren, [78]). В-третьих, хотя MDA очень похож на метод множественного регрессионного анализа, в вычислительном отношении он не эквивалентен. Метод оценки методом наименьших квадратов непригоден при оценке линейной зависимости с бинарной зависимой переменной (Bilderbeek, [24]).

Следовательно, в моделях MDA стандартизированные коэффициенты нельзя интерпретировать как -коэффициенты регрессии и, следовательно, они не указывают на относительную важность различных переменных (Altman, [11]; Joy & Tollefson, [41]; Eisenbeis, [35], Taffler, [68]).

Коэффициенты MDA не уникальны — уникальны только переменные — и они не учитывают взаимные корреляции между переменными в модели. Кроме того, как указывает Zavgren [78], мы должны иметь в виду, что попытка оценить значение отдельных коэффициентов неуместна с точки зрения цели техники MDA. Напротив, Scott [61] утверждает, что, если выполняются необходимые предположения модели MDA относительно коллинеарности, стандартизированные коэффициенты могут использоваться для оценки важности отдельных переменных. Также Blum [25] делает выводы об относительной важности переменных, сравнивая ранжирование переменных по относительной величине стандартизированных коэффициентов. Он предполагает, что эти рейтинги могут дать приблизительную оценку относительной важности. Eisenbeis [35] и Joy & Tollefson [41] упоминают некоторые возможные методы, предложенные в литературе, которые пытаются оценить относительную важность независимых переменных.

3. Методы машинного обучения

Машинное обучение — это мощная отрасль искусственного интеллекта, которая имеет широкое применение в банковской и финансовой сферах. Это позволяет финансовым учреждениям обнаруживать мошеннические транзакции и помогает менеджерам в оценке кредитоспособности, ранжировании и принятии решений о предоставлении. Финансовые роботы-консультанты и чат-боты оказывают банковскую помощь клиентам, системы распределения активов обеспечивают оценку риска и доходности для инвесторов, в то время как автоматические страховые услуги доступны для страхователей; финансовые приложения машинного обучения бесконечны. Благодаря своей способности обрабатывать огромные объемы данных и одновременно учитывать

нелинейности в данных, машинное обучение оказалось на переднем крае статистики. В последние десятилетия было проведено большое количество исследований с использованием вычислительного интеллекта в финансах (Ozbayoglu, Gudelek, & Sezer, [58]).

Последние достижения машинного обучения используют модели:

к ближайших соседей, байесовские классификаторы, деревья решений, случайный лес, методы опорных векторов, теорию нечетких множеств, карты Кехонена, модели генетического алгоритма, модели глубокого обучения, такие как искусственная нейронная сеть / глубокая нейронная сеть, нейронная сеть с прямой связью, нейронная сеть с обратным распространением, многослойный персептрон, сверточная нейронная сеть, рекуррентная нейронная сеть, модели обучения с подкреплением, гибридные и ансамблевые модели.

В 1990-х годах исследования показали, что методы машинного обучения, такие как искусственные нейронные сети, могут обеспечить лучшие результаты, чем статистические, такие как дискриминантный анализ и логит-анализ, с точки зрения точности прогнозирования (Lacher et al., [46], Lee et al., [48], Serrano-Cinca, [62]). С тех пор многие исследования начали использовать различные методы машинного обучения для прогнозирования финансовых трудностей, такие как методы опорных векторов, k-ближайший сосед, деревья решений и нейронные сети (Barboza et al., [19], Yeh et al., [75], Tsai et al., [73]).

Barboza et al., [19] пришли к выводу, что модели машинного обучения показывают в среднем примерно на 10% большую точность по сравнению с традиционными моделями.

Методы машинного обучения, применяемые для прогнозирования банкротства, включают модели одиночного и ансамблевого классификаторов. Модели классификаторов ансамбля можно разделить на три типа: бэггинг, бустинг и суммирование. В предыдущих исследованиях модели прогнозирования банкротства чаще всего оценивались с использованием одиночных классификаторов и/или ансамблей бустинга и/или бэггинга.

Методы ансамблевого обучения, которые сочетают в себе несколько методов классификации, показали превосходную производительность прогнозирования по сравнению с методами одиночной классификации.

Значительное количество работ установления вероятности дефолтов проводилось с использованием машинного обучения: нейронных сетей (Brédart, [26]), метод опорных векторов (SVM) (Li, Sun, [49], Shin, Lee, Kim, [63]) и AdaBoost (Alfaro-Cortes et al. [8], Ramakrishnan, Mirzaei, Bekri, [59]).

В последние десятилетия искусственные нейронные сети широко использовались для прогнозирования банкротства корпораций. Преимущество этих моделей заключается в способности обнаруживать нелинейные взаимосвязи и демонстрировать хорошую производительность при наличии зашумленной информации, как это обычно бывает, в задачах прогнозирования банкротства корпораций. **AdaBoost** — это новый алгоритм обучения ансамбля, который последовательно строит свои базовые классификаторы, используя разные версии обучающего набора данных. По мнению авторов, данный подход

уменьшает ошибку обобщения примерно на тридцать процентов по сравнению с ошибкой, полученной с помощью нейронной сети.

Помимо генетического алгоритма (Back, Laitinen, Sere [16], Gordini, [37]), который обычно используется в задачах оптимизации, и рассуждений, основанных на прецедентах (Bryant, [27], Chou, Hsieh, Qiu, [30]), применялись для получения решения правило банкротства.

Потенциально пригодные финансовые коэффициенты в силу нелинейных связей с вероятностью банкротства, могут быть не выбраны. Чтобы избежать этой промашки, Shirata [28] использовал алгоритм дерева классификации и регрессии. Однако остается проблема, заключающаяся в том, что нельзя гарантировать оптимальность точности предсказания для метода в целом.

Для решения этой задачи, авторы [70, 71] применили AdaBoost для выполнения обоих процессов в единой среде, в которой их алгоритмы определяют эффективные финансовые коэффициенты из большого числа кандидатов и построение прогнозной модели путем голосования по взвешенному большинству с выбранными показателями. Были рассмотрены и другие подходы, которые вообще не используют финансовую информацию; например, Shirata and Sakagami [64] предсказали корпоративное банкротство, применив методы анализа текста к финансовым отчетам или документам по связям с корпоративными инвесторами.

Метод ансамбля

Основная концепция метода ансамбля заключается в том, что различные точки зрения на различные аспекты проблемы могут быть объединены для получения высококачественного решения. Ряд исследователей установили, что метод ансамбля обеспечивает лучшую эффективность классификации, чем автономные модели, в прогнозировании банкротства и оценке кредитоспособности [52].

Авторы показывают, что метод «Случайное подпространство» превосходит другие методы ансамбля, протестированные в этой статье. Кроме того, лучшим автономным методом является многослойная нейронная сеть персептрона, а лучшим методом, протестированным в этой работе, является случайное подпространство нейронной сети Левенберга-Марквардта.

Бустинг и бэггинг (Boosting and Bagging) — два основных средства ансамблевого метода. Повышение — это метод, который сначала получает базовый классификатор из исходного набора данных, затем корректирует распределение обучающего набора данных на основе производительности базового классификатора и обучает следующий базовый классификатор с помощью скорректированного распределения выборки. Он присваивает вес каждому набору обучения, который можно использовать для создания набора бутстреп-выборок из исходных данных Begley, Ming, Watts, [23]. Kim и Urneja [43] применили Adaboost, типичный метод бустинга, для прогнозирования финансового дефолта ресторанов и получили успешный прогноз. В отличие от бустинга, бэггинг использует начальную загрузку, которая генерирует случайные подмножества данных путем выборки из заданного набора данных. Это метод, созданный несколькими независимыми классификаторами, который

запускает подпрограмму своих учеников, а затем объединяет их с помощью метода усреднения модели, чтобы уменьшить переоснащение модели. Одним из типичных подходов к бэггингу является случайный лес (Random Forest - RF), который основан на другой традиционной модели машинного обучения, дереве решений (Decision Tree - DT). Kruppa & et.al. [45] представили общую основу для оценки кредитного риска по отдельным вероятностям дефолта с использованием RF, который показал лучшие результаты, чем LR.

Нейронные сети

Применение нейросетевого анализа для классификации кредитных рисков получило широкое распространение. Нейросетевой анализ (НС) подобен нелинейному дискриминантному анализу тем, что он исключает предположение о том, что переменные, входящие в функцию прогнозирования банкротства, связаны линейно и независимо. Нейросетевые модели кредитного риска исследуют потенциально «скрытые» корреляции между прогностическими переменными, которые затем вводятся в качестве дополнительных объясняющих переменных в функцию нелинейного прогнозирования банкротства.

Нейронная сеть представляет собой набор простых вычислительных элементов, которые связаны между собой. Человеческий мозг представляет собой набор взаимосвязанных нейронов. В мозгу электрические сигналы, передаваемые между нейронами, либо подавляются, либо усиливаются в зависимости от того, чему нейронная сеть научилась в прошлом. Аналогичным образом искусственные нейроны могут быть созданы с использованием аппаратного или программного обеспечения, чтобы вести себя аналогично биологическому нейрону. Поведение сети вытекает из коллективного поведения взаимосвязанных единиц. Связи между единицами (нейронами) не являются жесткими, но могут быть изменены посредством процессов обучения, порожденных взаимодействием сети с внешним миром. Нейронные сети также используются с применением метода ансамбля [72].

Методы опорных векторов (SVM)

Метод опорных векторов был предложен Cortes and Vapnik [31]. Метод опорных векторов или SVM (от англ. Support Vector Machines) — это линейный алгоритм, используемый в задачах классификации и регрессии. Данный алгоритм имеет широкое применение на практике и может решать как линейные, так и нелинейные задачи. Суть работы метода опорных векторов проста: алгоритм создает линию или гиперплоскость, которая разделяет данные на классы. Основной задачей алгоритма является поиск наиболее правильной линии, или гиперплоскость, разделяющую данные на два класса. SVM это алгоритм, который получает на входе данные, и возвращает такую разделяющую линию. Известны работы, в которых применение метода опорных векторов приводит к большей точности, чем NN [63].

Методы глубокого обучения

Глубокое обучение (deep learning) привлекает большое внимание в области машинного обучения и искусственного интеллекта и достигло больших успехов, особенно в распознавании изображений, голоса и обработки естественного языка. Однако количество приложений глубокого обучения к

финансовому анализу ограничено, за исключением работ о прогнозировании колебаний цен на акции Aggarwal, Aggarwal, [7], Bao, Yue, Rao, [18] где рекуррентные нейронные сети часто используются для анализа временных рядов.

Пример использования глубокого обучения в финансовом анализе, помимо прогнозирования колебаний цен на акции, приводится Yeh, Wang, and Tsai [76], которые предсказали вероятность банкротства с помощью сети глубокого доверия (DBN) с пятью слоями, где изменения в волатильность курса акций представлена в виде линейного графика (бинарное изображение), и каждое значение пикселя (1 или 0) соответствует видимой переменной. Они сообщили, что эффективность различения для выявления обанкротившихся и действующих компаний превосходит обычный алгоритм SVM. Lee, Jang и Park [48] также оценили объем валовых продаж, операционную прибыль и чистую прибыль с помощью DBN. Они сосредоточились не только на финансовых показателях за предыдущий финансовый год, но и на количестве патентных заявок и долях патентов в отрасли за три года до этого. Эти функции используются в качестве видимых переменных для обучения DBN с шестью слоями.

Еще одна важная модель глубокого обучения — сверточная нейронная сеть (CNN - convolutional neural networks). Они применяются для решения задач идентификации в различных областях, и в некоторых областях они демонстрируют более высокую точность распознавания, чем обычные методы. Однако о применении сверточных нейронных сетей в финансовом анализе сообщалось лишь в небольшом количестве исследований по прогнозированию движения цен на акции. Причина этого, по-видимому, в том, что сверточные нейронные сети больше подходят для применения к изображениям и менее подходят для общих числовых данных, включая финансовые отчеты.

Nosaka [39] предложил метод набора финансовых коэффициентов, который выводится из финансовой отчетности и представляется в виде изображения в градациях серого. Изображение, сгенерированное этим процессом, используется для обучения и тестирования сверточной нейронной сети. Кроме того, размер набора данных увеличивается с использованием средневзвешенных значений для создания точек синтетических данных. Всего для обучения сверточной нейронной сети на базе GoogLeNet используется 7520 изображений для классов обанкротившихся и продолжающих существование предприятий. Эта модель, по утверждению автора [39] превосходит репрезентативные традиционные модели, включая большинство традиционных методов машинного обучения.

Mai et al. [51] представили модели глубокого обучения для прогнозирования корпоративного банкротства с использованием раскрытия текстовой информации. Хотя текстовые данные распространены, они редко учитываются в моделях поддержки принятия финансовых решений. Глубокое обучение использует слои нейронных сетей для извлечения функций из текстовых данных для прогнозирования. Авторы [51] показали, что модели глубокого обучения обеспечивают превосходную эффективность прогнозирования банкротства с использованием текстовых раскрытий. Когда

текстовые данные используются в сочетании с традиционными коэффициентами, основанными на учете, и рыночными переменными, модели глубокого обучения могут еще больше повысить точность прогнозов.

Заключение

С момента введения Z-балла Альтмана в 1968 году, [11] наблюдается распространение статистических моделей, которые сочетают финансовые коэффициенты и социально-экономические/макроэкономические факторы с передовыми математическими методами для оценки кредитоспособности публичных или частных компаний быстрым, автоматизированным и масштабируемым способом.

Дискриминантный анализ и логистическая регрессия были двумя хорошо известными методами статистического машинного обучения, используемыми в прогнозировании банкротства.

Методы машинного обучения считаются одними из самых важных из последних достижений в прикладной математике со значительными последствиями для задач классификации. Методы машинного обучения оценивают закономерности в наблюдениях одной и той же классификации и выявляют признаки, которые дифференцируют наблюдения разных групп. Методы машинного обучения считаются одними из самых важных из последних достижений в прикладной математике со значительными последствиями для задач классификации. Методы машинного обучения оценивают закономерности в наблюдениях одной и той же классификации и выявляют признаки, которые дифференцируют наблюдения разных групп.

Модели машинного обучения были очень успешными в финансовых приложениях, и многие исследования изучают их использование в прогнозировании банкротства. Модели Альтмана и Олсона по-прежнему актуальны не только из-за их прогностической силы, но и из-за их простых, практичных и последовательных структур.

В более позднее время стало применяться глубокое обучение. Оно стало обеспечивать сильные инструменты для большого круга приложений, а также в решении задач классификации в бизнесе и управлении, таких как прогнозирование банкротства и кредитный скоринг.

Отметим возможные инновационные изменения и будущие тенденции в прогнозировании банкротства с использованием машинного обучения и методов глубокого обучения [77].

Первую тенденцию, которую надо выделить, это диверсификация источников данных. Данные могут быть как числовые, так и текстовые. То, что использовались числовые данные, это всем понятно. Но теперь и текстовые данные становятся, такие как новости, источником прогнозирования. Это позволило выдвинуть новую концепцию, при которой данные становятся разнородными, с несколькими источниками. Эта концепция требует более продвинутой техники классификации, такой как техника глубокого обучения, CNN.

Вторую тенденцию, которую надо выделить, является интерпретируемость показателей моделей. Появились работы, которые разработали модель для

баланса точности, сложности и интерпретируемости [79]. Но, по-прежнему, выделить, какой из показателей модели имеет наибольшее влияние на банкротство, сложно. Проблема повышения интерпретируемости моделей прогнозирования остается.

Область исследований прогнозирования банкротства продолжает развиваться со многими новыми различными прогностическими моделями, разработанными с использованием различных инструментов. В ряде работ (Nafiz A. Alaka et.al. [38]) показано, как восемь популярных и перспективных инструментов работают на основе 13 ключевых критериев в области исследований моделей прогнозирования банкротства. Эти инструменты включают в себя два статистических инструмента: множественный дискриминантный анализ и логистическую регрессию; и шесть инструментов искусственного интеллекта: искусственная нейронная сеть, метод опорных векторов, нечеткие множества, принятие решений по случаям (прецедентам), дерево решений и генетический алгоритм. В число критериев авторы включили точность, дисперсию данных, требуемый метод выбора переменных, и другие [38]. В целом было установлено, что ни один инструмент не является преимущественно лучше других инструментов по отношению к 13 определенным критериям. Сделан важный вывод о том, что общая модель с более высокой производительностью может быть найдена только путем информированной интеграции инструментов для формирования гибридной модели.

Настоящая работа способствует систематическому пониманию методологических проблем, связанных со статистическими, экспертными системами с искусственным интеллектом и теоретическими подходами к решению проблем прогнозирования корпоративного дефолта.

Список литературы

1. Богданова Т.К., Баклакова А.В. Инструментальные средства прогнозирования вероятности банкротства авиапредприятий. // Инжиниринг бизнеса, 2008, №1.
2. Гиленко, Е. В., Довженко, С. Е., Федорова, Е. А., (2012), “Модели прогнозирования банкротства: особенности российских предприятий”, ФГО-БУВПО «Финансовый Университет при Правительстве Российской Федерации», pp. 85–92.
3. Жданов, В. Ю., Афанасьева, О. А., (2011), Модель диагностики риска банкротства предприятий авиационно-промышленного комплекса, Корпоративные финансы, No. 4, pp. 77–89.
4. Карминский А.М. Кредитные рейтинги и их моделирование. М.: Изд. дом Высшей школы экономики, 2015.
5. Макеева, Е. Ю., Бакурова, А. О., (2006), “Прогнозирование банкротства компаний нефтегазового сектора с использованием нейросетей”, Общественные науки и современность, No. 6, pp. 22–30.
6. Тотьмянина К.М. Моделирование вероятности дефолта корпоративных заемщиков с учетом макроэкономической конъюнктуры. Корпоративные финансы. 2014а, №1.

7. Aggarwal, S., Aggarwal, S., 2016. Deep investment in financial markets using deep learning models. *International Journal of Computer Applications* 162, 403–413.
8. Alfaro-Cortés, Esteban & Rubio, Noelia & Gámez, Matías & Elizondo, David. (2008). Bankruptcy forecasting: An empirical comparison of AdaBoost and neural networks. *Decision Support Systems*. 45. 110-122. 10.1016/j.dss.2007.12.002.
9. Altman E.I., Eisenbeis R.A., 1978, Financial applications of discriminant analysis: A clarification. *Journal of Financial and Quantitative Analysis*, March 1978, p. 185-195.
10. Altman, E. 1993. *Corporate Financial Distress and Bankruptcy*. 2nd ed. New York: John Wiley & Sons.
11. Altman, E. I. 1968. "Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy." *Journal of Finance* 23, no. 4:589–609.
12. Altman, E. I., and E. Hotchkiss. 2005. *Corporate Financial Distress and Bankruptcy*, 3rd ed. New York: John Wiley & Sons.
13. Altman, E. I., and G. Sabato. 2007. Modeling Credit Risk for SMEs: Evidence from the U.S. Market." *Abacus* 19, no. 6:716–723.
14. Altman, E. I., R. G. Haldeman, and P. Narayanan. 1977. "ZETA Analysis: A New Model to Identify Bankruptcy Risk of Corporations." *Journal of Banking and Finance* 1, no. 1:29–54.
15. Altman, E., J. Hartzell, and M. Peck. 1995a. "Emerging Markets Corporate Bonds: A Scoring System." *The Future of Emerging Market Flows*, edited by R. Levich. Kluwer, Holland: J.P. Mei, 1997
16. Back B., Laitinen T., Sere K. Neural networks and genetic algorithms for bankruptcy predictions, *Expert Systems with Applications*, Volume 11, Issue 4, 1996.
17. Back B., Laitinen T., Sere K., Van Wezel M., 1996b. Choosing bankruptcy predictors using discriminant analysis, logit analysis and genetic algorithms. *Turku Centre for Computer Science Technical Report nr.40*, September 1996, p. 1-18.
18. Bao, W., Yue, J., Rao, Y., 2017. A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PLoS One* 12 (7).
19. Barboza F., Kimura H., Edward Altman E. Machine learning models and bankruptcy prediction, *Expert Systems with Applications*, Volume 83, 2017, Pages 405-417.
20. Barnes P., 1982, Methodological implications of non-normality distributed financial ratios. *Journal of Business Finance and Accounting*, Vol. 9, nr. 1, Spring 1982, p. 51-62.
21. Barnes P., 1987, The analysis and use of financial ratios: A review article. *Journal of Business Finance and Accounting*, Vol. 14, nr. 4, Winter 1987, p. 449-461.
22. Beaver, W. 1966. "Financial Ratios as Predictors of Failures." In *Empirical Research in Accounting, selected studies*, supplement to *Journal of Accounting Research* 4, no. 3:71–111.
23. Begley J, Ming J, Watts S. Bankruptcy classification errors in the 1980s: An empirical analysis of Altman's and Ohlson's models[J]. *Review of Accounting Studies*, 1996, 1(4): 267-284.

24. Bilderbeek J., 1979, An empirical study of the predictive ability of financial ratios in the Netherlands. *Zeitschrift Für Betriebswirtschaft*, May 1979, p. 388-407.
25. Blum M., 1974, Failing company discriminant analysis. *Journal of Accounting Research*, Vol. 12, nr. 1, p. 1-25.
26. Brédart, Xavier. "Bankruptcy Prediction Model Using Neural Networks." *Accounting and Finance Research* 3 (2014): 124.
27. Bryant, S.M.: A case-based reasoning approach to bankruptcy prediction Modeling. *International Journal of Intelligent Systems in Accounting, Financial and Management* 6, 195–214 (1997)
28. C.Y. Shirata. Financial ratios as predictors of bankruptcy in Japan: An empirical research Proceedings of the second Asian pacific interdisciplinary research in accounting conference. 1998.
29. Caouette, J., E. Altman, and P. Narayanan. 1998. *Managing Credit Risk*. New York: John Wiley & Sons.
30. Chou C., Hsieh S., Qiu C., Hybrid genetic algorithm and fuzzy clustering for bankruptcy prediction. *Applied Soft Computing*, Volume 56, 2017, Pages 298-316.
31. Cortes C, Vapnik V. Support-vector networks[J]. *Machine learning*, 1995, 20(3): 273-297.
32. Deakin E., 1976, On the nature of the distribution of financial accounting ratios: some empirical evidence. *The Accounting Review*, Vol. 51, nr. 1, January 1976, p. 90-97.
33. Deakin E., 1977, Business failure prediction: an empirical analysis, p. 72-98. In: Altman, Sametz, 1977, *Financial crisis: institutions and markets in a fragile environment*.
34. Doumpos M., Zopoudinis C., 1999, A multicriteria discrimination method for the prediction of financial distress: the case of Greece. *Multinational Finance Journal*, Vol. 3, nr. 2, p. 71-101.
35. Eisenbeis, 1977, Pitfalls in the application of discriminant analysis in business. *Journal of Finance*, Vol. 32, nr. 3, June 1977, p. 875-900
36. Fedorova E., Ledyeva S., Drogovoz P., Nevredinov A. Economic policy uncertainty and bankruptcy filings. *International Review of Financial Analysis*, Volume 82, July 2022, 102174.
37. Gordini, Niccolo. (2014). A genetic algorithm approach for SMEs bankruptcy prediction: Empirical evidence from Italy. *Expert Systems with Applications*. 41. 6433–6445. 10.1016/j.eswa.2014.04.026.
38. Hafiz A. Alaka, Lukumon O. Oyedele, Hakeem A. Owolabi, Vikas Kumar, Saheed O. Ajayi, Olugbenga O. Akinade, Muhammad Bilal, Systematic review of bankruptcy prediction models: Towards a framework for tool selection, *Expert Systems with Applications*, Volume 94, 2018, Pages 164-184.
39. Hosaka T. Bankruptcy prediction using imaged financial ratios and convolutional neural networks [J]. *Expert Systems with Applications*, 2019, 117: 287-299
40. Joos Ph., Ooghe H., Sierens N., 1998a, Methodologie bij het opstellen en beoordelen van kredietclassificatiemodellen. *Tijdschrift voor Economie en Management*, Vol. 18, nr. 1, p. 1-48.

41. Joy O.M., Tollefson J.O., 1978, Some clarifying comments on discriminant analysis. *Journal of Financial and Quantitative Analysis*, March 1978, p. 197-200.

42. Karels G.V., Prakash A.J., 1987, Multivariate normality and forecasting of business bankruptcy. *Journal of Business Finance & Accounting*, Vol. 14, nr. 4, Winter 1987, p. 573-593.

43. Kim S Y, Upneja A. Predicting restaurant financial distress using decision tree and AdaBoosted decision tree models[J]. *Economic Modelling*, 2014, 36: 354-362.

44. Koh H.C., 1992, The sensitivity of optimal cutoff points to misclassification costs of Type I and Type II errors in the going-concern prediction context. *Journal of Business Finance & Accounting*, Vol. 19, nr. 2, January 1992, p. 187-197.

45. Kruppa J, Schwarz A, Armingier G, et al. Consumer credit risk: Individual probability estimates using machine learning[J]. *Expert Systems with Applications*, 2013, 40(13): 5125-5131

46. Lacher, R. C., Coats, P. K., Sharma, S. C., & Fant, L. F. (1995). A Neural Network for Classifying the Financial Health of a Firm. *European Journal of Operational Research*, 85(1), 53–65. [http://dx.doi.org/10.1016/0377-2217\(93\)E0274-2](http://dx.doi.org/10.1016/0377-2217(93)E0274-2)

47. Laitinen T., Kankaanpää M., 1999, Comparative analysis of failure prediction methods: the Finnish case. *The European Accounting Review*, Vol. 8, nr. 1, p. 67-92.

48. Lee, J., Jang, D., Park, S., 2017. Deep learning-based corporate performance prediction model considering technical capability. *Sustainability* 9 (6), 899(article number).

49. Li H., Sun J. Gaussian case-based reasoning for business failure prediction with empirical data in China. *Information Sciences*, Volume 179, Issues 1–2, 2 January 2009, Pages 89-108.

50. 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.

51. Mai F, Tian S, Lee C, et al. Deep learning models for bankruptcy prediction using textual disclosures[J]. *European Journal of Operational Research*, 2019, 274(2): 743-758.

52. Nanni L, Lumini A. An experimental comparison of ensemble of classifiers for bankruptcy prediction and credit scoring[J]. *Expert systems with applications*, 2009, 36(2).

53. Ohlson J., 1980, Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, Vol. 18, nr. 1, Spring 1980, p. 109-131

54. Ooghe H., Balcaen S., 2002c, Are failure prediction models transferable from one country to another? An empirical study using Belgian financial statements. *Proceedings of the 9th Annual Conference of the Multinational Finance Society*, 30/06/02 – 03/07/02, Cyprus.

55. Ooghe H., Camerlynck J., Balcaen S., 2003, The Ooghe-Joos-De Vos failure prediction models: a cross-industry validation. *Brussels Economic Review*, Vol. 46, nr. 1, Spring 2003, p. 39-70.

56. Ooghe H., Joos P., De Bourdeaudhuij C., 1995, Financial distress models in Belgium: The results of a decade of empirical research. *International Journal of Accounting*, Vol. 30, p. 245-274.
57. Ooghe H., Joos P., De Vos D., De Bourdeaudhuij C., 1994a, Towards an improved method of evaluation of financial distress models and presentation of their results. Working Paper, January 1994, Department of Corporate Finance, Ghent University, Belgium, 22p.
58. Ozbayoglu, A.M., Gudelek, M.U., & Sezer, O.B. (2020). Deep Learning for Financial Applications: A Survey. *Appl. Soft Comput.*, 93, 106384.
59. Ramakrishnan, Suresh A L, Masoud Mirzaei and Mahmoud Bekri. A multi-industry de-fault prediction model using logistic regression and decision tree. *Research Journal of Applied Sciences, Engineering and Technology* 9 (2015): 856-861.
60. Richardson F.M., Davidson L.F., 1984, On linear discrimination with accounting ratios. *Journal of Business Finance and Accounting*, Vol. 11, nr. 4, Winter 1984, p. 511-525.
61. Scott E., 1978, On the financial applications of discriminant analysis: comment. *Journal of Financial and Quantitative Analysis*, March 1978, p. 201-205.
62. Serrano-Cinca C. Feedforward neural networks in the classification of financial information. *The European Journal of Finance* 3 (3), 1998, №12, 183-202
63. Shin K S, Lee T S, Kim H. (2005). Shin, K.S.: An Application of Support Vector Machines in Bankruptcy Prediction Model. *Expert Systems and Applications* 28, 127-135. *Expert Systems with Applications*. 28. 127-135. 10.1016/j.eswa.2004.08.009.
64. Shirata, C. Y., Sakagami, M., 2008. An analysis of the going concern assumption: Text mining from Japanese financial reports. *Journal of Emerging Technologies in Accounting* 5 (1), 1–16.
65. Steele A., 1995, Going concern qualifications and bankruptcy prediction. Paper presented at the European Accounting Association, February 1995, p. 1-28.
66. Steele A., 2002, Receiver Operating Characteristics (ROC) curves and stochastic dominance in discriminant functions: an application in bankruptcy diagnosis. Working paper, August 2002, Warwick Business School, University of Warwick, p. 1-36.
67. Taffler R.J., 1982, Forecasting company failure in the UK using discriminant analysis and financial ratio data. *Journal of the Royal Statistical Society*, Vol. 145, Part 3, p. 342-358.
68. Taffler R.J., 1983, The assessment of company solvency and performance using a statistical model. *Accounting and Business Research*, Vol. 15, nr. 52, Autumn 1983, p. 295-307.
69. Taffler R.J., Tisshaw H., 1977, Going, Going, Gone - Four Factors Which Predict. *Accountancy*, Vol. 88, March 1977, p. 50-54.
70. Takata, Y., Hosaka, T., Ohnuma, H., 2015. Financial ratios extraction using AdaBoost for delisting prediction. *Proceedings of the Seventh International Conference on Information*, 158–161.

71. Takata, Y., Hosaka, T., Ohnuma, H., 2017. Boosting approach to early bankruptcy prediction from multiple-year financial statements. *Asia Pacific 735 Journal of Advanced Business and Social Studies* 3 (2), 66–76.

72. Tsai C F, Wu J W. Using neural network ensembles for bankruptcy prediction and credit scoring[J]. *Expert systems with applications*, 2008, 34(4): 2639-2649.

73. Tsai Chih-Fong, Hsu Yu-Feng, Yen David C. A comparative study of classifier ensembles for bankruptcy prediction, *Applied Soft Computing*, Volume 24, 2014, Pages 977-984.

74. Tucker J, 1996, Neural networks versus logistic regression in financial modelling: a methodological comparison. Paper published in Proceedings of the 1996 World First Online Workshop on Soft Computing (WSC1), Nagoya University, Japan, August 19-30, 1996.

75. Yeh C., Chi D., Lin Y. Going-concern prediction using hybrid random forests and rough set approach, *Information Sciences*, Volume 254, 2014, Pages 98-110.

76. Yeh, S., Wang, C., Tsai, M., 2015. Deep belief networks for predicting corporate de-faults. Proceedings of the 24th Wireless and Optical Communication 740 Conference, 159–163.

77. Yi Qu, Pei Quan, Minglong Lei, Yong Shi, Review of bankruptcy prediction using machine learning and deep learning techniques, *Procedia Computer Science*, Volume 162, 2019, Pages 895-899.

78. Zavgren C.V., 1985, Assessing the vulnerability to failure of American industrial firms: A logistic analysis. *Journal of Business Finance and Accounting*, Vol. 12, nr. 1, Spring 1985, p. 19-45.

79. Zhu X, Li J, Wu D, et al. Balancing accuracy, complexity and interpretability in consumer credit decision making: A C-TOPSIS classification approach[J]. *Knowledge-Based Systems*, 2013, 52: 258-267

80. Zmijewski M.E., 1984, Methodological issues related to the estimation of financial distress prediction models. *Journal of Accounting Research*, Supplement to Vol. 22, p. 59-86.

ЗАКЛЮЧЕНИЕ

В первой главе монографии «Концептуальные основы формирования цифровой экономики и развития сквозных цифровых технологий» проводится анализ вопросов обеспечения экономической безопасности России как неотъемлемое условие экономического роста, изучение цифровых экосистем и их роли в развитии малого и среднего предпринимательства в РФ, анализ тенденций развития цифровой экономики в современных условиях.

Во второй главе монографии «Развитие сквозных цифровых технологий в России как императив новой парадигмы экономического роста» исследуются вопросы внедрения сквозных цифровых технологий в информационном пространстве социальных систем, изучается ESG-банкинг как долгосрочный ориентир развития банковского сектора России, проводится сравнительный анализ развития онлайн-образования в России, Китае и Бразилии, исследуются правовые аспекты применения технологий искусственного интеллекта, анализируются тенденции развития цифровых технологий в России: теоретические и практические аспекты, проводится анализ тенденций мирового и российского инновационного развития и роли в нем цифровых технологий.

В третьей главе монографии «Генезис сквозных цифровых технологий на предприятиях России» рассматриваются вопросы эффективного управления предприятием в условиях цифровой экономики, изучаются тенденции и перспективы использования сквозных цифровых технологий в маркетинге, исследуются вопросы аудита эффективности деятельности коммерческой организации, проводится анализ развития методов прогнозирования корпоративных банкротств, исследуются цифровые технологии в системе профессиональной переподготовки прокурорских работников, анализируется стратегия обеспечения единства экономического пространства путем развития когнитивных компетенций управленческого персонала, исследуется бизнес-стратегирование компаний в условиях цифровой трансформации, сквозной цикл автоматизированного проектирования в машиностроении.

В четвертой главе монографии «Управление инновационным потенциалом наукоемких предприятий радиоэлектронной промышленности» исследуются теоретические аспекты управления инновационным потенциалом наукоемких предприятий радиоэлектронной промышленности, изучаются методические основы оценки управления инновационным потенциалом наукоемких предприятий радиоэлектронной промышленности, разрабатывается модель управления инновационным потенциалом наукоемких предприятий радиоэлектронной промышленности.

Общая объединяющая тема монографии создала широкие рамки для участия специалистов, интересующихся вопросами формирования цифровой экономики и развитием сквозных цифровых технологий в России как императивом новой парадигмы экономического роста, теоретико-методологическими подходами и практическими результатами исследований в данной научной области. НИЦ «ПНК» приносит искреннюю признательность всем участникам издания и выражает надежду, что данная книга не станет последней в серии оригинальных монографий.

КРАТКИЕ СВЕДЕНИЯ ОБ АВТОРАХ

Алексеева Юлиана Борисовна – начальник отдела кадров прокуратуры г. Санкт-Петербурга

Бабина Елена Николаевна – профессор Северо-Кавказского федерального университета, доктор экономических наук, доцент

Бабина Наталья Владимировна – доцент кафедры финансов и бухгалтерского учета, проректор Государственного бюджетного образовательного учреждения высшего образования Московской области «Технологический университет имени дважды Героя Советского Союза, летчика-космонавта А.А. Леонова», кандидат экономических наук, доцент

Белов Павел Сергеевич – доцент ЕТИ ФГБОУ ВО МГТУ «СТАНКИН», кандидат технических наук, доцент

Беляева Светлана Викторовна – доцент кафедры экономики, финансов и права Филиала ФГБОУ ВО «Российский экономический университет имени Г.В. Плеханова», в г. Пятигорске, кандидат экономических наук

Бобошко Диана Юрьевна – доцент НИТУ «МИСиС», кандидат экономических наук

Бондаренко Галина Васильевна – доцент Ставропольского филиала МПГУ, кандидат экономических наук, доцент

Бровченко Анастасия Александровна – аспирант ФГБОУ ВО «МГТУ «СТАНКИН»

Васильева Анастасия Сергеевна – доцент кафедры истории, экономики и права, Северный (Арктический) федеральный университет имени М.В. Ломоносова, кандидат экономических наук, доцент

Гарифуллин Вадим Фанисович – и.о. директора ФБУ «Красноярский ЦСМ», канд. тех. наук., доцент кафедры «Радиоэлектронные системы» института Инженерной физики и радиоэлектроники ФГАОУ ВО «Сибирский Федеральный университет», доцент кафедры «Электронная техника и телекоммуникации» института Информатики и телекоммуникаций ФГБОУ ВО «Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева»

Добродомова Татьяна Николаевна – доцент НИУ БелГУ, кандидат экономических наук, доцент

Ростова Ольга Владимировна – доцент Санкт-Петербургского политехнического университета Петра Великого, кандидат экономических наук, доцент

Рязанцев Павел Владимирович – специалист ООО «Газпром ВНИИГАЗ», магистрант ФГБОУ ВО «Российский государственный университет правосудия»

Савенкова Ирина Викторовна – доцент Южного федерального университета, кандидат экономических наук, доцент

Салихов Марат Рафикович – аспирант Сургутского государственного университета

Салманов Олег Николаевич – профессор кафедры финансов и бухгалтерского учета ГБОУ ВО Московской области «Технологический университет имени дважды Героя Советского Союза, летчика-космонавта А.А. Леонова», доктор экономических наук, доцент

Соболевская Татьяна Григорьевна – доцент ФГБОУ ВО Российский биотехнологический университет, г. Москва, кандидат экономических наук

Федорова Наталья Петровна – доцент Удмуртский ГАУ г. Ижевск, кандидат экономических наук, доцент

Федосеев Сергей Витальевич – профессор ФГБОУ ВО «Российский государственный университет правосудия», кандидат технических наук, доцент

Шабаров Дмитрий Валентинович – прокурор отдела кадров прокуратуры г. Санкт-Петербурга

Ширинкина Елена Викторовна – заведующий кафедрой менеджмента и бизнеса Сургутский государственный университет, доктор экономических наук, доцент

Шихалиева Джаннет Сергеевна – профессор кафедры управления и предпринимательства ФГБОУ ИВО «Московский государственный гуманитарно-экономический университет», доктор экономических наук, доцент

Шмелева Анастасия Сергеевна – ассистент Санкт-Петербургского политехнического университета Петра Великого

Шмыгалева Полина Владимировна – доцент Северо-Кавказского федерального университета, кандидат социологических наук, доцент

Юшманова Виктория Анатольевна – и.о. начальника проектного офиса АО «НПП «Радиосвязь», магистр ФГБОУ ВО «Сибирский государственный университет науки и технологий имени академика М.Ф. Решетнева

Научное издание

ФОРМИРОВАНИЕ ЦИФРОВОЙ ЭКОНОМИКИ И РАЗВИТИЕ СКВОЗНЫХ ЦИФРОВЫХ ТЕХНОЛОГИЙ В РОССИИ КАК ИМПЕРАТИВ НОВОЙ ПАРАДИГМЫ ЭКОНОМИЧЕСКОГО РОСТА

Монография

Под редакцией Шихалиевой Д.С., Подкопаева О.А.

Подготовка оригинал-макета Подкопаев О.А.
Подготовка обложки Подкопаев О.А.

Подписано в печать 10.04.2023. Бумага офсетная.
Формат 60x84 1/16. Гарнитура Times New Roman.
Печать оперативная. Усл. печ. л. 17,4. Тираж 500 экз.

Издательство ООО «Поволжская научная корпорация».
443082 г. Самара, ул. Тухачевского, 80, оф. 218
Тел.: (917) 812-32-82
E-mail: info@naucorp.ru

ISBN 978-5-6049405-6-3



9 785604 940563