

**БАНКОВСКИЕ РИСКИ:
ТЕОРИЯ, ПРАКТИКА,
МЕТОДОЛОГИЯ**

ЭВОЛЮЦИЯ МОДЕЛЕЙ ОПРЕДЕЛЕНИЯ ВЕРОЯТНОСТИ КОРПОРАТИВНОГО ДЕФОЛТА

В статье рассмотрено развитие моделей прогнозирования вероятности корпоративных дефолтов от множественного дискриминантного анализа, бинарных логит- и пробит-моделей до моделей машинного обучения, которые стали разрабатываться благодаря новым технологиям. Авторами выявлена тенденция к созданию эффективных моделей для определения вероятности дефолта отечественных предприятий.

КЛЮЧЕВЫЕ СЛОВА: многомерный дискриминантный анализ, логит-анализ, пробит-анализ, экспертные системы с искусственным интеллектом, прогнозирование корпоративных банкротств



Салманов Олег Николаевич — д. э. н., профессор кафедры финансов и бухгалтерского учета МГОТУ (г. Королев)



Бабина Наталья Владимировна — к. э. н., доцент кафедры финансов и бухгалтерского учета, проректор МГОТУ (г. Королев)

ВВЕДЕНИЕ

Прогнозирование корпоративного банкротства является актуальной проблемой в области корпоративных финансов, поскольку финансовая устойчивость фирмы очень важна для всех экономических агентов, которые с ней сотрудничают: для банков, бирж, акционеров, инвесторов, покупателей продукции и поставщиков сырья.

Корпоративный сектор является одним из крупнейших заемщиков средств на рынке капитала. Рынок корпоративного долга огромен.

Несмотря на популярность классических методов возникло несколько проблем, связанных с применением этих методов к прогнозированию корпоративных банкротств, однако в существующей литературе отсутствует четкий и всесторонний анализ этой проблемы.

Многие исследования были посвящены поиску лучшей модели прогнозирования корпоративных банкротств, поэтому в данной работе рассматривается эволюция моделей и даются критические замечания к ним.

МОДЕЛИ КРЕДИТНОГО РИСКА, ОСНОВАННЫЕ НА ДАННЫХ БУХГАЛТЕРСКОГО УЧЕТА И РЫНОЧНОЙ СТОИМОСТИ

В 1966 г. У. Бивер [19] первым построил модель прогнозирования корпоративных банкротств с помощью финансовых коэффициентов. Он применил одномерную модель — модель одномерного дискриминантного анализа — к ряду финансовых коэффициентов парной выборки состоятельных и несостоятельных компаний, чтобы предсказать их банкротство. Однако важность финансовых коэффициентов, принятых в исследовании, и уровень их значимости остались невыясненными.

Э. Альтманом была построена первая многомерная модель оценки кредитоспособности, названная Z-Score (Z-счет), которая объединила ряд показателей финансовой отчетности и рыночной стоимости [16]. Полученная оценка затем использовалась для классификации наблюдения (фирмы) либо в несостоятельную, либо в устойчивую категорию.

Метод статистической классификации, который использовал автор, — множественный дискриминантный анализ (МДА) — принадлежит к семейству статистических методов, доступных для разделения или прогнозирования состояния компаний. В основном он используется для классификации в задачах, где зависимая переменная является дихотомичной. Сначала создаются группы, затем данные распределяются по ним. Метод используется для анализа набора переменных для максимизации межгрупповой дисперсии при минимизации внутригрупповой. Процесс выполняется последовательно, исследователь подбирает переменные на основе различных статистических критериев, как правило, стремясь к максимуму дисперсии между группами при минимуме дисперсии внутри группы.

Из исходного списка 22 переменных в качестве окончательной Э. Альтманом была выбрана следующая модель с пятью переменными:

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

где

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

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

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

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

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

Окончательная дискриминантная функция:

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

Точность классификации выражается как точность типа I (отсутствие ошибок первого и второго типа (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 типов I и II. В контексте классификации суть метода МДА состоит в том, чтобы отнести фирму к группе состоятельных или несостоятельных на основе ее дискриминантного балла. Фирма будет отнесена к группе, которую она больше всего «напоминает». В соответствии с некоторой оптимальной точкой отсечения для модели МДА классификация производится следующим образом: фирма попадает в группу «неудачников», если ее дискриминантный балл (D_i) меньше точки отсечения, и в «благополучную» группу, если D_i превышает точку отсечения и находится на одном уровне с ней.

Для этой модели Э. Альтман установил границы оптимальности с 1,81 до 2,99. В диапазоне данных границ есть промежуточная зона, или зона незнания (спекулятивные рейтинги от BBB до B-).

Присвоение соответствующих вероятностей дефолта корпоративным кредитным активам

представляет собой трехэтапный процесс, включающий последовательное:

- 1) применение моделей кредитного скоринга;
- 2) использование эквивалентов риска рынка капитала (обычно рейтингов облигаций);
- 3) назначение вероятности и, возможно, поте-ри по кредитному портфелю.

Получить вероятность дефолта или убытков при дефолте можно путем связи расчетных кредитных рейтингов с рейтингами, которые присвоены ценным бумагам рейтинговыми агентствами.

Затем Э. Альтман создал модели для оценки частных производственных компаний, заменив балансовую стоимость на рыночную при расчете коэффициента X_4 и переоценив всю модель, поскольку меняются все коэффициенты:

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

В дальнейшем Э. Альтман разработал:

- непроизводственную модель Z-Score, из которой исключалось значение X_5 :

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

- модель EMS (Emerging Market Scoring) — модель оценки развивающихся рынков;
- модель кредитного риска ZETA^R, которая отражала изменения в бухгалтерской отчетности;
- модель с семью переменными;
- модель Альтмана и Сабато для малого и среднего бизнеса.

Ряд исследователей и практиков разработали модели типа Z-оценки во многих странах за пределами США [16], среди которых наиболее популярными в нашей стране являлись модели Р. Таффлера [40] и Дж. Фулмера [22].

Учитывая разнообразие методов, доступных в настоящее время для прогнозирования неплатежеспособности, необходимо понимать не только сильные стороны любой модели прогнозирования, но и ее ограничения. Мультиколлинеарность среди независимых переменных, по мнению Э. Альтмана [16], не создает проблем в моделях МДА. Большинство авторов согласны, что, когда корреляция между независимыми переменными

высока, коллинеарность, возможно, вызывает некоторые проблемы. Это приводит к нестабильным и труднообъяснимым оценкам параметров и может влиять на точность результатов классификации [33]. Следовательно, следует проводить корреляционный анализ и мультиколлинеарные тесты и избегать включения переменных с высокой степенью корреляции в модель МДА.

Методика МДА исходит из нескольких предположений прежде всего о том, что набор данных является непересекающимся. Есть также три ограничительных допущения:

- 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 фактическим данным, в силу чего выводы могут вызывать сомнения [45].

Статистическое допущение о многомерной нормальности часто нарушается, что может привести к систематической ошибке в критериях значимости и в оценках частоты ошибок. Если нарушается второе допущение (о равных дисперсионных матрицах), это повлияет на тесты значимости различий переменных между несостоятельной и состоятельной группами фирм. Третье допущение гласит, что 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 [39, 45]. Если оно нарушается, то модель МДА будет необъективной и неточной применительно к генеральной совокупности.

МДА имеет ряд серьезных недостатков помимо проблем, связанных с нарушением основных допущений.

1. Модель 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.

2. Мы должны иметь в виду, что дискриминантные баллы являются лишь порядковыми мерами, которые позволяют проводить относительное (порядковое) ранжирование фирм. МДА также может отражать вероятность отказа, но для этого требуется субъективная и, возможно, неточная оценка вероятностей, связанных с конкретными дискриминантными показателями [45].

3. Хотя МДА очень похож на метод множественного регрессионного анализа, в вычислительном отношении он не эквивалентен ему.

Следовательно, в моделях МДА стандартизированные коэффициенты нельзя интерпретировать как коэффициенты регрессии, они не указывают на относительную важность различных переменных [16].

До 1980-х гг. метод МДА преобладал в литературе, посвященной моделям корпоративных дефолтов. После 1980-х гг. его использование сократилось, но метод применялся для сравнительных исследований. Другими словами, МДА представляется общепринятым «стандартным методом».

МОДЕЛИ УСЛОВНОЙ ВЕРОЯТНОСТИ

После периода явного доминирования МДА был заменен менее требовательными статистическими методами, такими как логит-анализ (ЛА), пробит-анализ (ПА) и линейное вероятностное моделирование (ЛВМ). На этих методах основываются «модели условной вероятности». Дж. Олсон [32] первым использовал ЛА финансовых коэффициентов для прогнозирования банкротства компании, а М. Змиевский был первым в применении ПА [47]. 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 — нормальное. Считается, что функция распределения $F(x)$ некоторой случайной величины X — это $F_x(x) = P(X < x)$. 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 нормального закона распределения ее принято называть пробит-моделью, а в случае применения логистического закона — логит-моделью. Последняя может быть представлена следующим образом:

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

где X_{ij} — значение j -го показателя для i -й компании;

β_j — коэффициент для j -го показателя.

Логистическая функция подразумевает, что логит-показатель (т.е. вероятность отказа) $P1$ имеет значение в интервале $[0, 1]$. Когда статус банкротства кодируется как единица (ноль), высокий (низкий) логит-показатель указывает на высокую вероятность сбоя и, следовательно, на плохое финансовое состояние. Рассматривая задачу классификации, модель ЛА относит фирмы к определенной группе на основе их логит-показателя и порога отсечения.

Как и в модели МДА, точность классификации, или «производительность», модели ЛА можно оценить на основе частоты ошибок типа I и типа II, процента правильных классификаций, невзвешенной частоты ошибок, кривых рабочих характеристик приемника [39], функции компромисса, коэффициента Джини [34], R^2 и мер, основанных

на энтропии [25]. При применении ЛА не делается никаких предположений относительно распределения независимых переменных — модель не требует многомерных переменных с нормальным распределением, или равных дисперсионных матриц, или относительно априорных вероятностей отказа [25, 32, 45]. Поскольку ЛА не нужны ограничительные допущения МДА и данный метод позволяет работать с непропорциональными выборками, ЛА обычно считается «менее требовательным», чем МДА. Тем не менее ЛА основывается на двух предположениях:

1) метод требует, чтобы зависимая переменная была дихотомической, а группы были дискретными, непересекающимися и идентифицируемыми;

2) при выборе оптимальной вероятности отсека следует учитывать стоимость частоты ошибок типа I и типа II. Предельная оценка должна быть функцией стоимости ошибки типа I (убыток по ссуде, понесенный в результате принятия плохой кредитной истории) и стоимости ошибки типа II (доход, потерянный из-за того, что не кредитуются хороший кредитный риск из-за ошибки модели). Однако из-за субъективности выбора и издержек неправильной классификации на практике [39] большинство исследователей минимизируют общую частоту ошибок и, следовательно, неявно предполагают равные издержки ошибок первого и второго рода [32, 45].

В логит-анализе нет предположений относительно распределения независимых переменных и априорных вероятностей неудач. ЛА обладает рядом других важных преимуществ.

1. Выход модели — логит-показатель — представляет собой показатель от нуля до единицы. Это позволяет сразу оценить вероятность дефолта [32, 33].

2. Полученные коэффициенты в модели ЛА можно трактовать отдельно как значимость каждой из независимых переменных в объяснении оценочной вероятности отказа [32, 45] при условии, что между переменными нет мультиколлинеарности.

3. Модели ЛА допускают качественные переменные с категориями, а не с непрерывными

данными. В этом случае используются фиктивные переменные [25, 32].

4. Привлекательна нелинейная форма логит-функции.

Тем не менее ЛА имеет и ряд серьезных недостатков.

1. ЛА-модели чрезвычайно чувствительны к проблеме мультиколлинеарности. Следует избегать включения переменных с высокой степенью корреляции [25, 33]. Поскольку большинство моделей ЛА основаны на финансовых коэффициентах, которые сами по себе сильно коррелированы, т.к. часто имеют один и тот же числитель или знаменатель, проблема мультиколлинеарности может быть серьезной.

2. ЛА-модели очень чувствительны к выбросам (т.е. несогласованным наблюдениям) и отсутствующим значениям.

3. Хотя логит-модели не требуют нормального распределения переменных, они остаются чувствительными к крайней ненормальности. Следовательно, перед использованием модели ЛА данные сначала необходимо преобразовать или удалить выбросы, чтобы повысить нормальность.

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 дефолт или несостоятельность фирмы [40], поэтому исследователи стали вводить в модели банкротства новые виды показателей.

Многочисленные исследования подтверждают зависимость между макроэкономическими переменными, такими как ВВП, его рост, инвестиции в основной капитал, процентная ставка, курсы основных валют, их волатильность, денежная масса, денежный агрегат, отношение объемов кредитов

к ВВП, уровень цен, стоимость нефти, и уровнем банкротств.

МОДЕЛИ МАШИННОГО ОБУЧЕНИЯ

Машинное обучение относится к области искусственного интеллекта (ИИ), который имеет широкое применение в банковской и финансовой сферах. Это позволяет финансовым учреждениям обнаруживать мошеннические транзакции и помогает менеджерам в оценке платежеспособности, ранжировании и принятии решений о предоставлении кредитов. Финансовые роботы-консультанты и чат-боты оказывают банковскую помощь клиентам, системы распределения активов обеспечивают оценку риска и доходности для инвесторов, страхователям доступны автоматические страховые услуги.

Применение машинного обучения в сфере финансов не ограничено благодаря способности ИИ обрабатывать огромные объемы данных и одновременно учитывать их нелинейность. В последние десятилетия было проведено большое количество исследований с использованием ИИ в финансах [35].

Последние достижения машинного обучения используют следующие модели: k-ближайших соседей, байесовские классификаторы, деревья решений, метод случайного леса, методы опорных векторов, теория нечетких множеств, карты Кохонена, 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 перцептрон, сверточная нейронная сеть, рекуррентная нейронная сеть, модели обучения с подкреплением, гибридные и ансамблевые модели.

В 1990-х гг. исследования показали, что модели машинного обучения, такие как искусственные нейронные сети, могут обеспечить лучшие результаты, чем статистические, такие как дискриминантный и логит-анализ, с точки зрения точности

прогнозирования [28]. С тех пор во многих исследованиях используются различные методы машинного обучения для прогнозирования финансовых трудностей, такие как методы опорных векторов, метод k-ближайших соседей, деревья решений и нейронные сети [18, 42, 43]. Ф. Барбоза и соавторы [18] пришли к выводу, что модели машинного обучения показывают в среднем примерно на 10% больше точности по сравнению с традиционными моделями.

Модели машинного обучения, применяемые для прогнозирования банкротства, включают модели одиночного и ансамблевого классификаторов. Последние, в свою очередь, 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 по установлению вероятности дефолтов проводилось с использованием нейронных сетей [20], метода опорных векторов [29, 37] и алгоритма AdaBoost [15].

В последние десятилетия искусственные нейронные сети широко использовались для прогнозирования банкротства корпораций. Преимущество этих моделей заключается в способности обнаруживать нелинейные взаимосвязи и демонстрировать высокую производительность при наличии зашумленной информации, как это обычно бывает в задачах прогнозирования банкротства корпораций. AdaBoost — это новый алгоритм ансамблевого обучения, который последовательно строит базовые классификаторы, используя разные версии обучающего набора данных. По мнению авторов, данный подход уменьшает ошибку обобщения примерно на 30% по сравнению с ошибками работы нейронных сетей.

Генетический алгоритм [24], который обычно используется в задачах оптимизации, и метод,

основанный на прецедентах [21], применялись для получения решения правила банкротства. Проблема состоит в том, что потенциально пригодные финансовые коэффициенты в силу нелинейных связей с вероятностью банкротства могут быть не выбраны для построения моделей прогнозирования. Чтобы избежать этой нежелательной ситуации, некоторые исследователи применяли алгоритм «дерева классификации». Однако выбор показателей и построение моделей прогнозирования с помощью машинного обучения характеризуются тем, что нельзя гарантировать оптимальность точности предсказания для метода в целом.

Для решения этой задачи Й. Таката и соавторы [41] применили AdaBoost для выполнения выбора финансовых показателей и построения модели прогнозирования в единой среде. Алгоритмы AdaBoost позволили выбрать эффективные финансовые коэффициенты из большого числа вариантов и построить прогнозную модель. Были рассмотрены и другие подходы, в которых вообще не используется финансовая информация, например, С. Ширата и М. Сакаю [38] предсказали корпоративное банкротство, применив методы анализа текста к финансовым отчетам и документам, связанным с коммуникацией с корпоративными инвесторами.

1. Метод ансамбля. Основная концепция данного метода заключается в том, что различные точки зрения на разные аспекты проблемы можно объединить для получения высококачественного решения. Ряд исследователей установили, что метод ансамбля обеспечивает лучшую эффективность классификации, чем автономные модели, при прогнозировании банкротства и оценке кредитоспособности [31]. По мнению авторов, метод случайного подпространства превосходит другие ансамблевые методы. Лучшим автономным методом является многослойная нейронная сеть перцептрон, а лучшим методом, протестированным в этой работе, — алгоритм Левенберга — Марквардта.

Бустинг и бэггинг — два основных средства ансамблевого метода. Бустинг — 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 данных, который можно использовать для создания набора бутстреп-выборок из исходных данных. С. Ким и А. Апнейя [26] применили AdaBoost, типичный метод бустинга, для прогнозирования финансового дефолта ресторанов и получили успешный прогноз.

В отличие от бустинга, бэггинг использует начальный ввод данных, который генерирует случайные их подмножества путем выборки из заданного набора. Одним из типичных подходов к бэггингу является метод случайного леса, который основан на другой традиционной модели машинного обучения — дереве решений. Дж. Краппа и соавторы [27] представили общую основу для оценки кредитного риска по отдельным вероятностям дефолта с использованием метода случайного леса, который показал лучшие результаты, чем оптимизированная модель логистической регрессии.

2. Нейронные сети. Применение нейросетевого анализа (НСА) для классификации кредитных рисков получило широкое распространение. НСА подобен нелинейному дискриминантному анализу: 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. Связи между единицами (нейронами) не являются жесткими, но могут быть изменены посредством процессов обучения, порожденных взаимодействием сети с внешним миром.

3. Метод опорных векторов (МОВ). При этом методе алгоритм создает линию или гиперплоскость, которая разделяет данные на классы.

Хотя известно, что нейронная сеть с обратным распространением ошибки (back-propagation neural network — BPN) хорошо справляется с задачами распознавания образов. Метод обратного распространения ошибки — метод вычисления градиента, который используется при обновлении весов многослойного перцептрона. У него есть некоторые ограничения, заключающиеся в том, что найти подходящую структуру модели и оптимальное решение — это искусство. Кроме того, для поиска весов сети необходимо загрузить в нее как можно больше обучающих наборов данных. В то же время, поскольку МОВ захватывает геометрические характеристики пространства признаков без получения весов сетей из обучающих данных, он способен извлекать оптимальное решение даже при небольшой обучающей выборке. К. Шин, Т. Ли и Х. Ким [37] подтвердили, что классификатор МОВ превосходит BPN в прогнозировании корпоративного банкротства. Результаты авторов показывают, что точность и эффективность обобщения МОВ выше, чем у BPN, поскольку размер обучающей выборки меньше.

4. Глубокое обучение. Данный метод особенно эффективен при распознавании изображений, голоса и обработке естественного языка. Однако применение глубокого обучения в сфере финансового анализа ограничено. Исключениями являются, например, работы о прогнозировании колебаний цен акций [13, 17], в них рекуррентные нейронные сети используются для анализа временных рядов.

Пример использования глубокого обучения в финансовом анализе помимо прогнозирования колебаний цен на акции приводится в работе, посвященной предсказанию вероятности банкротства с помощью глубокой сети доверия (deep belief networks — DBN) [44]. Вероятность банкротства прогнозируется с помощью DBN с пятью слоями: волатильность курса акций в ней представлена в виде линейного графика (бинарного изображения), каждое значение пикселя (1 или 0) соответствует

видимой переменной. Авторы сообщили, что эффективность различения для выявления обанкротившихся и действующих компаний превосходит обычный алгоритм МОВ. Дж. Ли, Д. Джанг и С. Парк [28] 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 исследования. Эти функции применялись в качестве видимых переменных для обучения DBN с шестью слоями.

Еще одна важная модель глубокого обучения — сверточная нейронная сеть. Она применяется для идентификации в различных областях и в некоторых из них демонстрирует 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, по-видимому, в том, что сверточные нейронные сети больше подходят для исследования изображений и менее — для изучения числовых данных, включая финансовые отчеты.

Т. Хосака [24] предложил метод набора финансовых коэффициентов, который выводится из финансовой отчетности и может быть представлен в виде изображения в градациях серого. Сгенерированное изображение используется для обучения и тестирования сверточной нейронной сети. По мнению автора, данная модель имеет преимущество перед традиционными методами машинного обучения.

Ф. Май и соавторы [30] предложили модели глубокого обучения для прогнозирования корпоративного банкротства с использованием раскрытия текстовой информации. Хотя текстовых данных немало, они редко учитываются в моделях поддержки принятия финансовых решений. Авторы показали, что модели глубокого обучения обеспечивают превосходную эффективность прогнозирования банкротства с использованием текстовых данных. Когда такие данные используются в сочетании

с традиционными данными учета и рыночными переменными, модели глубокого обучения могут еще больше повысить точность прогнозов.

ВКЛАД РОССИЙСКИХ АВТОРОВ В ПРОГНОЗИРОВАНИЕ БАНКРОТСТВ

Исследования российских авторов также прошли аналогичные этапы. Работы первого этапа, выполненные до 2000 г., включая труды А.Д. Шеремета и Н.Г. Кондракова, Г.В. Савицкой, О.П. Зайцевой, Р.С. Сайфуллина и Г.Г. Кадыкова, Г.В. Давыдовой и А.Ю. Беликова, Л.В. Донцовой и Н.А. Никифоровой [3, 7], были направлены в определенной мере на адаптацию модели Э. Альтмана, но не оказались успешными в отличие от последующих этапов, связанных с разработкой логит-моделей для отечественной экономики и применением машинного обучения. Сравнение моделей приведено также в статьях Е.А. Федоровой и др. [10, 11, 12].

Т.К. Богданова и А.В. Баклакова [1] построили модель логистической регрессии для прогнозирования вероятности банкротства авиапредприятий. В. Жданов и О. Афанасьева [4] используют линейный дискриминантный анализ и логит-модель, Е. Макеева и А. Бакурова [8], С. Горбатков и С. Фархиева [2] применяют нейронные сети. При этом авторы не учитывают размер компаний.

К. Тотьмянина [9] и А. Карминский [5] разработали логит-модель вероятности дефолта корпоративных заемщиков строительной отрасли с учетом макроэкономической конъюнктуры. В статье Е. Федоровой и др. [10] анализируется важный вопрос о применимости зарубежных моделей к отечественным предприятиям. А. Карминский и Р. Бурехин [6] рассмотрели разные алгоритмы и установили, что искусственные нейронные сети превосходят другие методы, в то время как модели логистической регрессии в сочетании с дискретизацией близки к ним по эффективности.

ЗАКЛЮЧЕНИЕ

Предсказание корпоративных банкротств стало крупной областью исследований в области корпоративных финансов. С момента введения модели Э. Альтмана в 1968 г. [16] наблюдается распространение статистических моделей, которые сочетают финансовые коэффициенты и социально-экономические / макроэкономические факторы с передовыми математическими методами для оценки кредитоспособности публичных или частных компаний. Дискриминантный анализ и логистическая регрессия были двумя хорошо известными статистическими методами, используемыми в прогнозировании банкротства.

Методы машинного обучения считаются одними из самых важных последних достижений прикладной математики, значительно упростивших классификацию. Методы машинного обучения оценивают закономерности в наблюдениях одной и той же классификации и выявляют признаки, по которым дифференцируются группы. Они успешно применяются в финансовой сфере, и многие исследования изучают их использование в прогнозировании банкротства. Модели Э. Альтмана и Дж. Олсона по-прежнему актуальны не только из-за их прогностической силы, но и из-за их простой, практичной и последовательной структуры.

Позднее стало использоваться глубокое обучение, в том числе в решении задач классификации, таких как прогнозирование банкротства.

Отметим возможные инновационные изменения и тенденции в прогнозировании банкротства с использованием машинного обучения и методов глубокого обучения [42].

1. Диверсификация источников данных. Данные могут быть как числовыми, так и текстовыми. Это позволило выдвинуть новую концепцию, в рамках которой можно обрабатывать разнородные данные, получаемые из нескольких источников.

2. Интерпретируемость показателей моделей. Появились работы, в которых представлены модели баланса точности, сложности и интерпретируемости [46], однако выделить, какой из показателей

оказывает наибольшее влияние на банкротство, сложно. Проблема повышения интерпретируемости моделей остается актуальной.

Е.А. Федорова и др. [10, 12] отмечают, что эффективнее применять методики для того экономического периода, в котором они были созданы, и что модели, разработанные за рубежом, могут не учитывать особенности отечественной экономики. Впрочем, об этом говорил еще Э. Альтман [16], так же как и о важности распределения моделей по отраслям. С этим связана важность разработки моделей прогнозирования банкротства для разных отраслей российского бизнеса.

Область прогнозирования банкротства продолжает развиваться, разрабатывается много новых прогностических моделей. В некоторых работах [14] показано, что общая модель с более высокой производительностью может быть найдена только путем интеграции инструментов для формирования гибридной модели.

Научная значимость данной статьи заключается в систематизации полученных знаний и возможности их использования в дальнейших исследованиях, направленных на разработку моделей прогнозирования корпоративного банкротства.

ЛИТЕРАТУРА

1. Богданова Т.К., Баклакова А.В. Инструментальные средства прогнозирования вероятности банкротства авиапредприятий // Инжиниринг бизнеса. — 2008. — №1. — С. 45–61.
2. Горбатов С.А., Фархиева С.А. Нейросетевая модель диагностики стадий развивающегося банкротства корпораций // Финансы: теория и практика. — 2018. — №22(3). — С. 112–123. — DOI: 10.26794/2587–5671–2018–22–3–112–123.
3. Гранкин В.Ф., Марченкова И.Н., Удовикова А.А. Сравнительный анализ российских и зарубежных методик прогнозирования вероятности банкротства // Вестник Курской государственной сельскохозяйственной академии. — 2018. — №5. — С. 169–176.
4. Жданов В.Ю., Афанасьева О.А. Модель диагностики риска банкротства предприятий авиационно-промышленного комплекса // Корпоративные финансы. — 2011. — №4. — С. 77–89.
5. Карминский А.М. Кредитные рейтинги и их моделирование. — М.: Издательский дом Высшей школы экономики, 2015.
6. Карминский А.М., Бурехин Р.Н. Сравнительный анализ методов прогнозирования банкротств российских строительных компаний // Бизнес-информатика. — 2019. — Том 13. — №3. — С. 52–66. — DOI: 10.17323/1998-0663.2019.3.52.66.
7. Котлярова О.А., Бжассо А.А. Сравнительный анализ отечественных и зарубежных моделей оценки и прогнозирования вероятности банкротства компаний: необходимость их применения в России в современных условиях // Экономика и бизнес: теория и практика. — 2020. — №9–1(67). — С. 155–159.
8. Макеева Е.Ю., Бакурова А.О. Прогнозирование банкротства компаний нефтегазового сектора с использованием нейросетей // Общественные науки и современность. — 2006. — №6. — С. 22–30.
9. Тотьмянина К.М. Моделирование вероятности дефолта корпоративных заемщиков с учетом макроэкономической конъюнктуры // Корпоративные финансы. — 2014. — №1. — С. 5–19.
10. Федорова Е.А., Гиленко Е.В., Довженко С.Е. Модели прогнозирования банкротства: особенности российских предприятий // Проблемы прогнозирования. — 2013. — №2. — С. 85–92.
11. Федорова Е.А., Довженко С.Е., Федоров Ф.Ю. Модели прогнозирования банкротства российских предприятий: отраслевые особенности // Проблемы прогнозирования. — 2016. — №3. — С. 32–40.
12. Федорова Е.А., Хрустова Л.Е., Чекризов Д.В. Отраслевые особенности применения моделей прогнозирования банкротства предприятия // Стратегические решения и риск-менеджмент. — 2018. — №1(104). — С. 64–71.
13. Aggarwal S., Aggarwal S. (2016). «Deep investment in financial markets using deep learning models». *International Journal of Computer Applications*, Vol. 162, pp. 403–413.
14. Alaka H.A., Oyedele L.O., Owolabi H.A., Kumar V., Ajayi S.O., Akinade O.O., Bilal M. (2018). «Systematic review of bankruptcy prediction models: towards a framework for tool selection». *Expert Systems with Applications*, Vol. 94, pp. 164–184.
15. Alfaro-Cortés E., Rubio N., Gámez M., Elizondo D. (2008). «Bankruptcy forecasting: an empirical comparison of AdaBoost and neural networks». *Decision Support Systems*, Vol. 45, pp. 110–122.
16. Altman E.I., Hotchkiss E. (2005). *Corporate Financial Distress and Bankruptcy*. New York: John Wiley & Sons.
17. Bao W., Yue J., Rao Y. (2017). *A Deep Learning Framework for Financial Time Series Using Stacked Autoencoders and Long-Short Term Memory*. — <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0180944>.

18. Barboza F., Kimura H. (2017). «Edward Altman E. Machine learning models and bankruptcy prediction». *Expert Systems with Applications*, Vol. 83, pp. 405–417.
19. Beaver W. (1966). «Financial ratios as predictors of failures». *Empirical Research in Accounting*, Vol. 4(3), pp. 71–111.
20. Brédart X. (2014). «Bankruptcy prediction model using neural networks». *Accounting and Finance Research*, Vol. 3, p. 124.
21. Chou C., Hsieh S., Qiu C. (2017). «Hybrid genetic algorithm and fuzzy clustering for bankruptcy prediction». *Applied Soft Computing*, Vol. 56, pp. 298–316.
22. Fulmer J., Moon J., Gavin T., Erwin M. (1984). «A bankruptcy classification model for small firms». *Journal of Commercial Bank Lending*, July, pp. 25–37.
23. Gordini N. (2014). «A genetic algorithm approach for SMEs bankruptcy prediction: empirical evidence from Italy». *Expert Systems with Applications*, Vol. 41, pp. 6433–6445.
24. Hosaka T. (2019). «Bankruptcy prediction using imaged financial ratios and convolutional neural networks». *Expert Systems with Applications*, Vol. 117, pp. 287–299.
25. Joos Ph., Ooghe H., Sierens N. (1998). «Methodologie bij het opstellen en beoordelen van kredietclassificatiemodellen». *Tijdschrift voor Economie en Management*, Vol. 18(1), pp. 1–48.
26. Kim S.Y., Upneja A. (2014). «Predicting restaurant financial distress using decision tree and AdaBoosted decision tree models». *Economic Modelling*, Vol. 36, pp. 354–362.
27. Kruppa J., Schwarz A., Armingier G. et al. (2013). «Consumer credit risk: individual probability estimates using machine learning». *Expert Systems with Applications*, Vol. 40(13), pp. 5125–5131.
28. Lee J., Jang D., Park S. (2017). *Deep Learning-Based Corporate Performance Prediction Model Considering Technical Capability*. — <https://www.mdpi.com/2071-1050/9/6/899>.
29. Li H., Sun J. (2009). «Gaussian case-based reasoning for business failure prediction with empirical data in China». *Information Sciences*, Vol. 179(1–2), pp. 89–108.
30. Mai F., Tian S., Lee C. et al. (2019). «Deep learning models for bankruptcy prediction using textual disclosures». *European Journal of Operational Research*, Vol. 274(2), pp. 743–758.
31. Nanni L., Lumini A. (2009). «An experimental comparison of ensemble of classifiers for bankruptcy prediction and credit scoring». *Expert Systems with Applications*, Vol. 36(2), pp. 3028–3033.
32. Ohlson J. (1980). «Financial ratios and the probabilistic prediction of bankruptcy». *Journal of Accounting Research*, Vol. 18(1), pp. 109–131.
33. Ooghe H., Balcaen S. (2002). *Are Failure Prediction Models Transferable from One Country to Another? An Empirical Study Using Belgian Financial Statements*. — <https://public.vlerick.com/Publications/d2b8d457-69a9-e011-8a89-005056a635ed.pdf>.
34. Ooghe H., Camerlynck J., Balcaen S. (2003). «The Ooghe — Joos — De Vos failure prediction models: a cross-industry validation». *Brussels Economic Review*, Vol. 46(1), pp. 39–70.
35. Ozbayoglu A.M., Gudelek M.U., Sezer O.B. (2020). *Deep Learning for Financial Applications: a Survey*. — https://www.researchgate.net/publication/341292744_Deep_learning_for_financial_applications_A_survey.
36. Qu Y., Quan P., Lei M., Shi Y. (2019). «Review of bankruptcy prediction using machine learning and deep learning techniques». *Procedia Computer Science*, Vol. 162, pp. 895–899.
37. Shin K.S., Lee T.S., Kim H. (2005). «An application of support vector machines in bankruptcy prediction model». *Expert Systems and Applications*, Vol. 28, pp. 127–135.
38. Shirata C.Y., Sakaue M. (2008). «An analysis of the going concern assumption: text mining from Japanese financial reports». *Journal of Emerging Technologies in Accounting*, Vol. 5(1), pp. 1–16.
39. Steele A. (2002). *Receiver Operating Characteristics (ROC) Curves and Stochastic Dominance in Discriminant Functions: an Application in Bankruptcy Diagnosis*. Coventry: University of Warwick, pp. 1–36.
40. Taffler R.J., Tisshaw H. (1977). «Going, going, gone — four factors which predict». *Accountancy*, Vol. 88, pp. 50–54.
41. Takata Y., Hosaka T., Ohnuma H. (2017). «Boosting approach to early bankruptcy prediction from multiple-year financial statements». *Asia Pacific Journal of Advanced Business and Social Studies*, Vol. 3(2), pp. 66–76.
42. Tsai Ch.F., Hsu Y.F., Yen D.C. (2014). «A comparative study of classifier ensembles for bankruptcy prediction». *Applied Soft Computing*, Vol. 24, pp. 977–984.
43. Yeh C., Chi D., Lin Y. (2014). «Going-concern prediction using hybrid random forests and rough set approach». *Information Sciences*, Vol. 254, pp. 98–110.
44. Yeh S., Wang C., Tsai M. (2015). «Deep belief networks for predicting corporate defaults». In: *2015 24th Wireless and Optical Communication Conference (WOCC)*, pp. 159–163.
45. Zavgren C.V. (1985). «Assessing the vulnerability to failure of American industrial firms: a logistic analysis». *Journal of Business Finance and Accounting*, Vol. 12(1), pp. 19–45.
46. Zhu X., Li J., Wu D. et al. (2013). «Balancing accuracy, complexity and interpretability in consumer credit decision making: a C-TOPSIS classification approach». *Knowledge-Based Systems*, Vol. 52, pp. 258–267.
47. Zmijewski M.E. (1984). «Methodological issues related to the estimation of financial distress prediction models». *Journal of Accounting Research*, Vol. 22, pp. 59–86.