

УДК 336.71:658.15:004.85

*Боцман Дмитрий Алексеевич,
студент,*

*МИРЭА – Российский технологический университет,
г. Москва*

*Шугайлов Никита Александрович,
студент,*

*МИРЭА – Российский технологический университет,
г. Москва*

Научный руководитель:

*Марухленко Анатолий Леонидович,
к. т. н. доцент*

**ПРЕДИКТИВНОЕ МОДЕЛИРОВАНИЕ РИСКОВ БАНКРОТСТВА:
ПРОБЛЕМА СХОДИМОСТИ АЛГОРИТМОВ МАШИННОГО
ОБУЧЕНИЯ НА НЕНОРМАЛИЗОВАННЫХ ФИНАНСОВЫХ
ДАННЫХ**

Аннотация. В статье исследуется проблема применения алгоритмов машинного обучения для прогнозирования корпоративных банкротств на основе финансовой отчетности. В статье наглядно продемонстрированы последствия игнорирования базовых аксиом машинного обучения (необходимости масштабирования данных) в прикладных задачах экономики. Эмпирически проиллюстрировано, как использование ненормализованных финансовых показателей приводит к вычислительной нестабильности и разрушению предиктивной способности скоринговых моделей. В качестве решения предложен метод на базе логистической регрессии со строгой процедурой Z-стандартизации признакового пространства, что позволило полностью восстановить сходимость алгоритма. Для адаптации модели к специфике банковского риск-менеджмента внедрена модифицированная

функция взвешенных потерь (*Cost-Sensitive Learning*), компенсирующая экстремальный дисбаланс классов в выборке. Эмпирическое тестирование на массиве данных 78 682 предприятий продемонстрировало высокую эффективность алгоритма: полнота выявления дефолтов (*Recall*) составила 85,8%. Анализ усредненных весовых коэффициентов обеспечил высокую экономическую транспарентность модели, математически подтвердив стабилизирующую роль рыночной капитализации и критическое влияние избыточной долговой нагрузки на вероятность банкротства. Предложенная методология доказывает целесообразность использования интерпретируемых алгоритмов (*white-box*) для превентивного мониторинга кредитных рисков.

Ключевые слова: прогнозирование банкротства, машинное обучение, логистическая регрессия, риск-менеджмент, Z-стандартизация, расходимость алгоритма, интерпретируемый ИИ.

PREDICTIVE MODELING OF BANKRUPTCY RISK: THE CONVERGENCE PROBLEM OF MACHINE LEARNING ALGORITHMS ON UNNORMALIZED FINANCIAL DATA

Abstract. *This article investigates the problem of applying machine learning algorithms to predict corporate bankruptcies based on financial statements. The article clearly demonstrates the consequences of ignoring fundamental machine learning axioms (the necessity of data scaling) in applied economic tasks. It empirically illustrates how the use of unnormalized financial indicators leads to computational instability and the degradation of the predictive capability of scoring models. As a solution, a method based on logistic regression with a strict Z-standardization procedure of the feature space is proposed, which allowed for the complete restoration of the algorithm's convergence. To adapt the model to the specifics of bank risk management, a modified weighted loss function (*Cost-Sensitive Learning*) was introduced to compensate for the extreme class imbalance in the*

sample. Empirical testing on a dataset of 78,682 enterprises demonstrated the high efficiency of the algorithm: the recall of default detection reached 85.8%. The analysis of averaged weight coefficients provided high economic transparency of the model, mathematically confirming the stabilizing role of market capitalization and the critical impact of excessive debt burden on the probability of bankruptcy. The proposed methodology proves the viability of using interpretable (white-box) algorithms for proactive credit risk monitoring.

Keywords: *bankruptcy prediction, machine learning, logistic regression, risk management, Z-standardization, algorithm divergence, interpretable AI.*

В последние десятилетия роль машинного обучения (ML) в финансовой аналитике и системах кредитного скоринга претерпела качественные изменения. Современные методы обработки данных позволяют автоматизировать оценку рисков, повышая эффективность принятия управленческих решений. Традиционные статистические подходы, такие как модель Z-score Э. Альтмана, долгое время служили фундаментом финансового анализа, однако сегодня они все чаще уступают место высокоточным алгоритмам машинного обучения, включая градиентный бустинг и нейронные сети.

Несмотря на рост предсказательной точности, внедрение сложных ML-алгоритмов сталкивается с серьезным противоречием. Многие современные модели функционируют как «черные ящики», логика работы которых остается непрозрачной для пользователя. В условиях принятия решений с высокой ценой ошибки, таких как корпоративное кредитование, отсутствие интерпретируемости результатов становится критическим барьером для доверия со стороны бизнеса и регуляторов. Таким образом, актуальной научной задачей является поиск баланса между высокой предиктивной силой современных алгоритмов и требованием математической прозрачности, характерной для интерпретируемых моделей типа «белого ящика» (white-box models).

Объектом исследования выступает процесс оценки финансовой устойчивости и вероятности банкротства корпоративных контрагентов в банковском секторе.

Предметом исследования являются методы и алгоритмы машинного обучения, используемые для прогнозирования банкротства, а также способы обеспечения их вычислительной стабильности и интерпретируемости в современных экономических условиях.

Несмотря на значительный прогресс в области ML, развитие моделей прогнозирования банкротства ограничено рядом нерешенных проблем:

1. **Вычислительная нестабильность:** Исследователи нередко концентрируются исключительно на выборе архитектуры алгоритма, оставляя без внимания математические свойства исходных данных. Обучение моделей на ненормализованных показателях финансовой отчетности, характеризующихся значительной разницей в масштабах, приводит к плохой обусловленности задачи и критическому нарушению сходимости (расходимости) алгоритмов оптимизации.

2. **Дисбаланс данных:** Редкая встречаемость событий банкротства в реальной экономике создает дисбаланс в выборках. Классические ML-алгоритмы склонны игнорировать класс банкротов, максимизируя общую точность за счет предсказания стабильного состояния большинства компаний.

3. **Отсутствие интерпретируемости:** Непрозрачность алгоритмов «черного ящика» ограничивает возможности экспертов по верификации принимаемых решений, что препятствует интеграции ML-моделей в реальные бизнес-процессы кредитных организаций.

Целью данной работы является адаптация интерпретируемого подхода к предиктивному финансовому моделированию на базе логистической регрессии и эмпирическая демонстрация уязвимостей машинного обучения при работе с сырыми финансовыми данными. Для достижения поставленной цели необходимо решить следующие задачи:

1. Продемонстрировать влияние специфики исходной финансовой отчетности (масштабных диспропорций) на сходимость итеративных методов оптимизации.

2. Эмпирически подтвердить критическую важность базовых методов предобработки (*Z*-стандартизации) для обеспечения работоспособности экономических скоринговых моделей.

3. Оценить влияние метода *Cost-Sensitive Learning* (алгоритмического взвешивания штрафов) на повышение метрики Recall (полноты) в условиях дисбаланса классов при сохранении экономической интерпретируемости вектора весов модели.

4. Провести сравнительный вычислительный эксперимент, подтверждающий состоятельность предложенного интерпретируемого метода по сравнению с моделями «черного ящика» в задачах обеспечения финансовой устойчивости предприятий.

Исторически оценка финансового состояния предприятий базировалась на одномерном анализе (*univariate analysis*) разрозненных показателей, что не позволяло корректно учесть взаимосвязи между ними и приводило к противоречивым выводам [1, с. 112]. Фундаментальный сдвиг в методологии прогнозирования банкротств произошел благодаря Э. Альтману (1968), предложившему применять многомерный дискриминантный анализ (MDA) [2, с. 591]. Этот статистический метод позволил преобразовать профиль финансовых характеристик в интегральный индекс (*Z*-score), разделяющий компании на устойчивые и склонные к дефолту [2, с. 594].

Главным преимуществом модели Альтмана стала ее полная методологическая прозрачность и возможность строго интерпретировать экономический смысл каждого коэффициента. Вычислительная простота сделала линейный дискриминантный анализ основным инструментом практического риск-менеджмента на долгие годы [3, с. 5].

Несмотря на историческую значимость, классические модели обладают критическими математическими ограничениями. Дискриминантный анализ

требует строго нормального распределения переменных и равенства ковариационных матриц выборок банкротов и здоровых компаний [4, с. 94]. В реальной экономике эти параметрические условия практически невыполнимы. Кроме того, неспособность классических моделей улавливать сложные нелинейные зависимости обусловила необходимость перехода к более гибким алгоритмам машинного обучения [3, с. 8].

Математические ограничения классических подходов стимулировали переход к многомерным алгоритмам машинного обучения (ML). Доминирующее положение в задачах кредитного скоринга заняли ансамблевые методы (Random Forest, Gradient Boosting) и нейронные сети [4, с. 95]. Их ключевое преимущество – способность автономно выявлять скрытые нелинейные взаимосвязи финансовых коэффициентов без жестких допущений о нормальности распределения. Эмпирически доказано, что современные ML-модели статистически значимо превосходят дискриминантную Z-модель Альтмана по метрике общей предсказательной точности (Accuracy) [3, с. 14].

Успешность интеграции ML подтверждается и на массивах отечественной финансовой отчетности. В частности, формирование моделей бинарной классификации [5, с. 31] и адаптация алгоритмов (например, SVM и логистической регрессии) к российским показателям баланса обеспечивают более точный и устойчивый прогноз вероятности банкротства по сравнению с традиционными формулярными подходами [6, с. 45].

Тем не менее, непрерывное усложнение математической архитектуры ансамблевых моделей и нейронных сетей ради роста точности (Accuracy) породило новую фундаментальную проблему, резко ограничивающую их практическое применение в банковском секторе.

Этой проблемой стал острый кризис интерпретируемости. Современные ансамблевые методы и нейросети работают как «черный ящик» (black box), скрывая логику распределения весов отдельных признаков. В задачах с высокой ценой ошибки (high-stakes decisions), к которым относится корпоративное кредитование, необоснованное применение

неинтерпретируемых алгоритмов неприемлемо: риск-менеджмент требует точного понимания конкретных причин потенциального дефолта [3, с. 16].

В фундаментальном исследовании С. Рудин (2019) математически доказана методологическая некорректность конструирования объяснений постфактум (*post-hoc explanations*) для сложных алгоритмов. Подобные надстройки лишь аппроксимируют исходную модель и могут вводить аналитиков в заблуждение [7, с. 207]. Новейшие попытки преодолеть эту дилемму с помощью инструментов объяснимого искусственного интеллекта (*Explainable AI*) в финансовом скоринге [8, с. 2] также базируются на аппроксимации и не решают базовую проблему алгоритмической непрозрачности. Исходя из этого, обосновывается необходимость перехода к изначально интерпретируемым моделям (*white-box models*).

В связи с этим возврат к прозрачным линейным классификаторам, таким как логистическая регрессия, становится объективной методологической необходимостью. Она обеспечивает полную экономическую транспарентность весовых коэффициентов. Однако применение классических оптимизационных алгоритмов к массивам современной корпоративной отчетности обнажает новый барьер – проблему обеспечения вычислительной стабильности при работе со специфическими финансовыми данными.

Обеспечение вычислительной стабильности интерпретируемых моделей дополнительно осложняется фундаментальной спецификой финансовых данных – экстремальным дисбалансом классов. В реальной экономике доля банкротств редко превышает 5–10% от общего числа функционирующих предприятий [10, с. 2]. Подобная асимметрия критически искажает логику работы стандартных ML-алгоритмов: стремясь минимизировать совокупную ошибку, они смещают границу принятия решений и максимизируют общую точность за счет полного игнорирования миноритарного класса банкротов [9, с. 2].

Для решения данной проблемы в литературе часто применяются методы искусственного изменения выборки (*Undersampling* или алгоритмы семейства

SMOTE). Однако случайное удаление примеров мажоритарного класса ведет к потере потенциально значимой информации, а генерация синтетических миноритарных данных (oversampling) искажает реальную финансовую картину и провоцирует переобучение (overfitting) [9, с. 4]. В связи с этим математически более корректным подходом выступает алгоритмическое взвешивание (Cost-Sensitive Learning). Интеграция штрафных коэффициентов непосредственно в функцию потерь сохраняет естественную дисперсию данных и принуждает модель фокусироваться на выявлении дефолтов [9, с. 2].

В парадигме риск-менеджмента это смещает фокус оценки качества: метрика полноты (Recall) становится приоритетнее общей точности (Accuracy), поскольку финансовая цена пропуска фактического банкротства (ложноотрицательное срабатывание) несоизмеримо выше издержек на дополнительный аудит контрагента при ложной тревоге [1, с. 17].

Одним из недостаточно освещённых аспектов применения методов машинного обучения в задачах прогнозирования банкротства остается влияние предварительной обработки финансовых данных на вычислительную устойчивость алгоритмов градиентной оптимизации. Большинство исследователей фокусируются исключительно на архитектуре ML-моделей, упуская из виду, что сырые экономические данные характеризуются значительной дисперсией в масштабах показателей: коэффициенты рентабельности измеряются в сотых долях, тогда как совокупные активы и выручка – в миллиардах.

Обучение предиктивных моделей на ненормализованных данных с использованием методов градиентной оптимизации неизбежно приводит к математической проблеме плохой обусловленности (ill-conditioned problem) и последующей расходимости алгоритма. Как отмечает К. В. Воронцов, алгоритм стохастического градиентного спуска экстремально чувствителен к масштабу измерения признаков: если норма вектора объекта принимает чрезмерно большие значения, итерационный процесс расходится или демонстрирует вычислительную неэффективность [11, с. 60]. Перемножение

ошибки предсказания на ненормализованные финансовые показатели экстремально больших порядков делает шаг антиградиента чрезмерным. В результате целевая функция начинает хаотично осциллировать, и оптимизация весовых коэффициентов становится вычислительно невозможной.

Несмотря на то, что необходимость нормализации данных перед применением градиентного спуска является фундаментальной аксиомой машинного обучения, в прикладных экономических и управленческих исследованиях этим этапом нередко пренебрегают. Данная работа призвана наглядно продемонстрировать, как игнорирование этого базового правила при работе со специфическими финансовыми массивами приводит к полному разрушению алгоритмической сходимости, и почему Z-стандартизация является важным условием для построения корректных моделей риск-менеджмента.

В качестве эмпирической базы исследования используется открытый набор данных финансовой отчетности *American Companies Bankruptcy Prediction* [12]. Вектор признаков исходной информационной матрицы включает 18 объективных коэффициентов (ликвидности, рентабельности, оборачиваемости и структуры капитала), собранных по 78 682 предприятиям.

Разведочный анализ данных выявил экстремальный дисбаланс классов: доля финансово стабильных компаний составляет 93,37% (73 462 наблюдения), тогда как доля обанкротившихся предприятий – всего 6,63% (5 220 наблюдений). В отличие от упрощенных подходов, предполагающих искусственное сокращение выборки (*Undersampling*) и ведущих к потере ценной экономической информации, в настоящей работе предиктивное моделирование реализуется на полном объеме данных с сохранением естественной структуры распределения.

Для обеспечения статистической надежности выводов и исключения фактора случайного успеха при разбиении данных применяется метод стратифицированной K-кратной кросс-валидации (*Stratified K-Fold Cross-Validation*) при $K=5$ [13]. Исходный датасет разделяется на 5 репрезентативных

блоков (фолдов), в каждом из которых строго сохраняется исходное соотношение классов (93,37% к 6,63%). Модель обучается последовательно 5 раз: на каждом шаге 4 блока формируют обучающее подмножество (Train), а оставшийся блок выступает в качестве отложенной валидационной выборки (Test). Итоговые метрики качества рассчитываются как среднее арифметическое по результатам всех 5 итераций.

Для предотвращения методологической ошибки «утечки данных» (data leakage) этап нормализации признаков интегрирован непосредственно внутрь цикла кросс-валидации. Параметры Z-стандартизации (математическое ожидание μ и стандартное отклонение σ) вычисляются на каждой итерации исключительно по обучающим фолдам, после чего масштабирование применяется к валидационному фолду:

$$x'_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j}$$

где x_{ij} / x'_{ij} – исходное / нормализованное значение признака, μ_j / σ_j – среднее значение / стандартное отклонение признака j

Для решения задачи бинарного прогнозирования выбран аппарат логистической регрессии, представленный в линейном матричном виде. Данный алгоритм относится к классу интерпретируемых моделей (white-box models), что позволяет полностью обойти проблему некорректного восприятия предиктивных систем как «черных ящиков» в сфере финансового анализа [7].

Финансовое состояние каждого предприятия формализуется в многомерном векторном пространстве [14]. Связь признаков с целевым статусом описывается уравнением:

$$z = Xw + \varepsilon$$

где X – нормализованная информационная матрица признаков, w – вектор искомых весовых коэффициентов, а ε – вектор случайных отклонений. Полученное скалярное произведение трансформируется в вероятностное значение дефолта $\hat{y} \in [0,1]$ с помощью логистической функции активации (сигмоиды) [11].

Для компенсации дисбаланса классов в математическое ядро алгоритма внедрена технология взвешивания потерь (Cost-Sensitive Learning). Вместо изменения объема выборки корректируется сама целевая функция: веса классов устанавливаются обратно пропорционально частоте их встречаемости в обучающих данных [9]. Вес для стабильных компаний (w_0) фиксируется на базовом уровне, тогда как штраф за ошибку на миноритарном классе банкротств (w_1) увеличивается примерно в 14 раз ($w_1 \approx 14.11$).

С учетом стоимостного взвешивания классов целевая функция минимизации (Weighted Log Loss) принимает следующий вид:

$$L_w = -\frac{1}{N} \sum_{i=1}^N [w_1 y_i \log(\hat{y}_i) + w_0 (1 - y_i) \log(1 - \hat{y}_i)]$$

где N – число наблюдений в обучающем подмножестве, y_i – фактический статус компании (1 – дефолт, 0 – стабильность), \hat{y}_i – это то, что предсказала ваша модель. Данная модификация функции потерь принуждает численный метод оптимизации уделять приоритетное внимание поиску паттернов банкротства, давая штраф модели за пропуск критического риска [9].

Поиск оптимальных параметров вектора весов w реализуется с помощью итеративного численного метода градиентного спуска:

$$w_{k+1} = w_k - \alpha \nabla L_w(w_k)$$

где α – зафиксированный шаг обучения (скорость спуска, $\alpha=0.5$), а $\nabla L_w(w_k)$ – вектор градиента взвешенной функции потерь. Механика сходимости численного метода исследуется путем сравнения динамики функции потерь на траекториях оптимизации ненормализованной и стандартизированной матриц X .

Эффективность построенного ML-пайплайна оценивается на основе усредненной по 5 фолдам Матрицы ошибок (Confusion Matrix). Финансовая специфика задачи антикризисного менеджмента обуславливает выбор полноты (Recall) в качестве ключевой метрики эффективности, поскольку минимизация ложноотрицательных результатов (пропущенных дефолтов) имеет решающее значение для минимизации убытков кредиторов.

На первом этапе вычислительного эксперимента была предпринята попытка обучения базовой модели логистической регрессии на исходной, «сырой» информационной матрице без применения процедур математического масштабирования. Целью данного этапа являлась эмпирическая проверка гипотезы о невозможности сходимости численных методов оптимизации при работе с реальной финансовой отчетностью.

На данном этапе в качестве алгоритма оптимизации применялся классический стохастический градиентный спуск (SGD). Экстремально высокий для логистической регрессии шаг обучения ($\alpha=0.5$) был зафиксирован намеренно в качестве вычислительного стресс-теста, чтобы максимально наглядно проиллюстрировать эффект нестабильности и осцилляции градиента при работе с сырыми данными. Динамика логарифмической функции потерь (Log Loss) в процессе итеративного обучения на ненормализованных данных представлена на Рисунке 1.




Рисунок 1. Расходимость алгоритма на сырых данных

Как наглядно демонстрирует визуализация, алгоритм абсолютно лишен вычислительной стабильности. Вместо плавного асимптотического снижения ошибки к глобальному минимуму наблюдается хаотичная осцилляция функции потерь. Уже на первой итерации ошибка совершает резкий скачок, после чего функция продолжает колебаться в экстремально высоком коридоре значений (от 13 до 17.5).

Математическая природа данного явления кроется в плохой обусловленности (ill-conditioning) исходной матрицы признаков из-за существенного расхождения масштабов дисперсии исходных признаков. Экономические показатели в информационной матрице имеют принципиально разную размерность: коэффициенты рентабельности измеряются в сотых долях, тогда как показатели выручки и совокупных активов – в миллиардах. При вычислении вектора антиградиента эти диспропорции многократно умножаются, в результате чего шаг градиентного спуска становится чрезмерно большим. Алгоритм постоянно «перешагивает» оптимум, делая процесс нахождения корректных весов невозможным.

Полученный результат экспериментально доказывает, что применение алгоритмов машинного обучения в финансовом анализе без предварительной строгой Z-стандартизации признакового пространства приводит к полному разрушению предиктивной способности модели.

Для устранения выявленной вычислительной нестабильности и проблемы расходимости алгоритма информационная матрица была подвергнута строгой процедуре Z-стандартизации. Параметры нормализации вычислялись изолированно внутри каждого фолда кросс-валидации для предотвращения утечки данных (data leakage).

Результат применения математического масштабирования признаков наглядно продемонстрирован на Рисунке 2.




Рисунок 2. Сходимость алгоритма после Z-стандартизации

Как видно из представленного графика, после нормализации пространства признаков кривая обучения кардинально меняет свой характер. Функция потерь (Log Loss) демонстрирует плавное, монотонное убывание на протяжении всех итераций градиентного спуска, асимптотически приближаясь к своему глобальному минимуму. Вычислительная стабильность алгоритма полностью восстановлена: вектор градиента больше не подвержен экстремальным скачкам из-за разницы в размерностях финансовых показателей. Это позволяет модели корректно обновлять весовые коэффициенты и выявлять скрытые экономические паттерны.

Добившись строгой математической сходимости, мы провели оценку качества классификации. Обучение финальной рабочей конфигурации логистической регрессии осуществлялось с применением продвинутого квазиньютоновского алгоритма оптимизации L-BFGS. Оптимизатор функционировал в связке со встроенным алгоритмом взвешивания потерь (Cost-Sensitive Learning), который автоматически компенсировал

экстремальный дисбаланс выборки, установив штраф за пропуск дефолта в пропорции 1:14.11.

Результаты 5-кратной стратифицированной кросс-валидации (при базовом пороге отсечения 0.5) позволили сформировать комплексную картину эффективности алгоритма через призму четырех ключевых метрик машинного обучения:

- Полнота выявления (Recall): 0.858
- Общая точность (Accuracy): 0.368
- Точность прогноза класса (Precision): 0.084
- Гармоническое среднее (F1-Score): 0.153

Специфический баланс полученных показателей обусловлен фундаментальной проблемой антикризисного управления – компромиссом между точностью и полнотой (Precision-Recall Trade-off). Алгоритм, математически сфокусированный на минимизации критических рисков, продемонстрировал высокую полноту (Recall = 85,8%). Из 5 220 фактических банкротов в тестовых выборках модель успешно идентифицировала 4 488 предприятий (см. Рисунок 3).

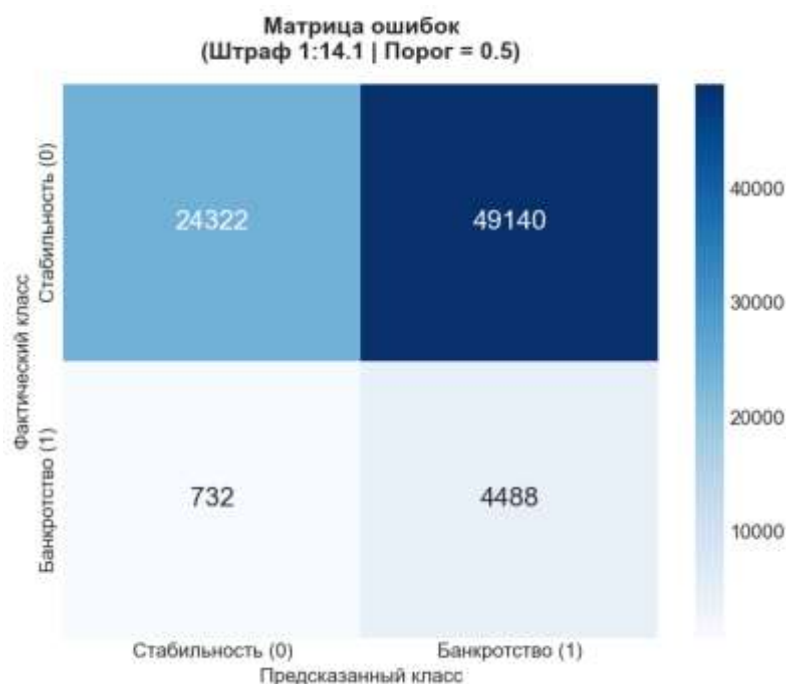


Рисунок 3. Суммарная матрица ошибок (Confusion Matrix) финальной предиктивной модели при базовом пороге классификации (0.5) и автоматическом взвешивании классов (1:14.11)

Однако обратной стороной высокой чувствительности алгоритма стало ожидаемое падение прецизионности. Анализ суммарной матрицы ошибок (Рисунок 3) показывает, что смещение баланса прогнозов привело к 49 140 ложноположительным срабатываниям (False Positives). Низкий показатель Precision указывает на то, что из всех компаний, отнесенных алгоритмом к классу риска, лишь малая часть действительно потерпела крах. Как следствие, интегрирующая метрика F1-Score, представляющая собой гармоническое среднее между Precision и Recall, также зафиксировалась на невысоком уровне (15,3%).

С точки зрения абстрактной статистики такие значения Precision и Accuracy могут показаться субоптимальными, однако в парадигме банковского сектора они абсолютно оправданы. Ложноположительное срабатывание генерирует для кредитора лишь операционные издержки на проведение дополнительного ручного аудита контрагента.

В рамках данного исследования штрафные коэффициенты в матрице ошибок (1 к 14.11) были установлены строго обратно пропорционально частоте классов (статистический подход), что было необходимо для базовой компенсации математического дисбаланса обучающей выборки. Однако при внедрении разработанного алгоритма в реальную ИТ-инфраструктуру коммерческого банка расчет данных весов должен быть переведен из статистической плоскости в сугубо финансовую. В парадигме продвинутого риск-менеджмента (в частности, в рамках стандартов Базель II/III [15]) штраф за пропуск дефолта (w_1) должен калиброваться на основе показателя уровня потерь при дефолте (Loss Given Default, LGD) и величины подверженности кредитному риску (Exposure at Default, EAD). В свою очередь, вес w_0 (штраф за ложную тревогу) будет определяться стоимостью ручного андеррайтинга и возможной упущенной выгодой от необоснованного отказа кредитоспособному заемщику. Важным преимуществом предложенной архитектуры Cost-Sensitive Learning является её математическая гибкость: она позволяет напрямую интегрировать эмпирические экономические параметры

(LGD и издержки аудита) в функцию потерь без изменения базовой логики предиктивной модели.

В целях эмпирической валидации предложенной линейной модели и оценки её сравнительной эффективности был проведен вычислительный эксперимент (Baseline). В качестве альтернативного нелинейного алгоритма, относящегося к классу непрозрачных моделей («черный ящик»), применялся ансамблевый метод случайного леса (Random Forest). Обучение альтернативной модели осуществлялось на идентичной выборке с применением стратифицированной кросс-валидации и алгоритмической балансировки классов.

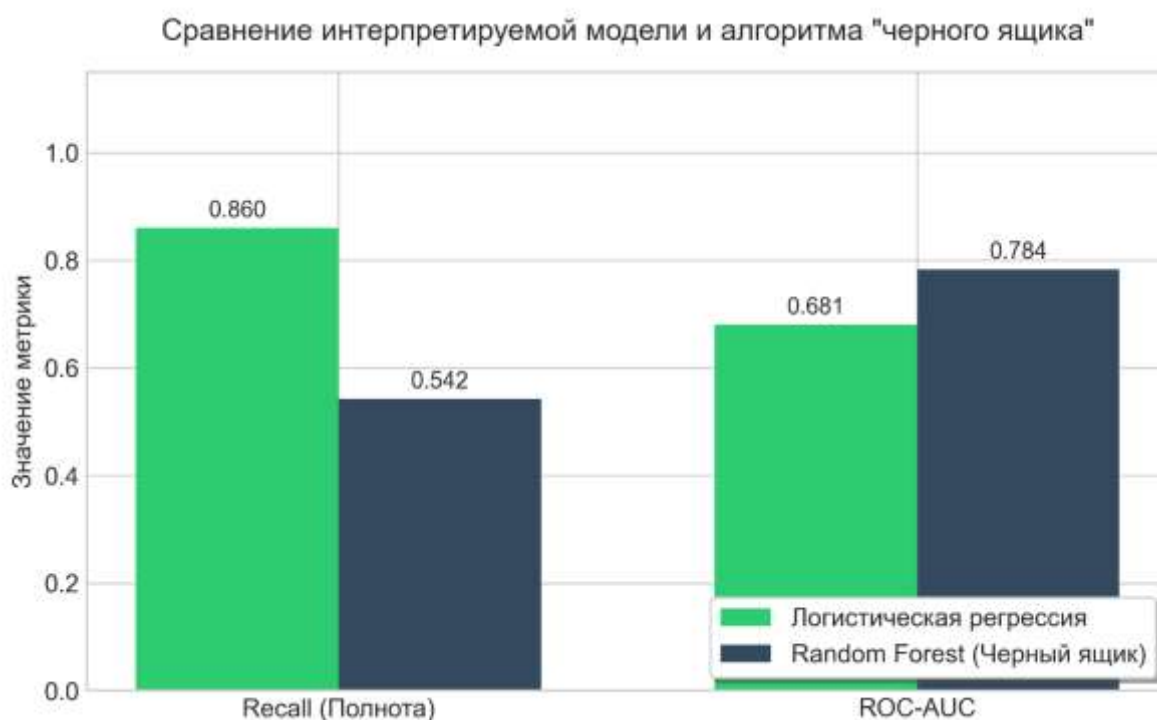


Рисунок 4. Эмпирическое сравнение метрик логистической регрессии и ансамблевого алгоритма Random Forest

Результаты сравнительного анализа подтверждают целесообразность применения предложенного алгоритмического пайплайна в задачах кредитного риск-менеджмента. По ключевой для данной предметной области метрике полноты (Recall) логистическая регрессия показала значение 0.860. Ансамблевый алгоритм Random Forest продемонстрировал значение Recall на уровне 0.542, что эквивалентно ошибке второго рода (ложноотрицательное

срабатывание) в 45,8% случаев. Более высокое значение интегральной метрики ROC-AUC у модели Random Forest (0.784 против 0.681) отражает её способность к выявлению сложных нелинейных зависимостей и лучшую общую разделительную способность. Тем не менее, в условиях дисбаланса стоимости ошибок при корпоративном кредитовании минимизация ложноотрицательных прогнозов имеет приоритетное значение. Таким образом, применение логистической регрессии с функцией взвешенных потерь является оптимальным решением: алгоритм обеспечивает необходимый уровень выявления потенциальных дефолтов, сохраняя при этом полную математическую интерпретируемость весовых коэффициентов, недоступную для нелинейных ансамблевых моделей.

Использование аппарата логистической регрессии позволило не только получить вероятностный прогноз дефолта, но и провести строгую интерпретацию влияния каждого экономического показателя на итоговый результат. В отличие от алгоритмов класса «черный ящик», логистическая функция обладает высокой прозрачностью: анализ усредненного вектора весовых коэффициентов w позволяет оценить вклад каждого признака.

Специфика корпоративной финансовой отчетности неразрывно связана с проблемой мультиколлинеарности – высокой степенью линейной зависимости между различными экономическими показателями (например, активами, обязательствами и выручкой). Классическая логистическая регрессия в таких условиях дает нестабильные оценки коэффициентов с завышенной дисперсией, что делает их прямую интерпретацию некорректной. Для нейтрализации данного математического эффекта в архитектуру предложенной модели на этапе оптимизации функции потерь была интегрирована L2-регуляризация (гребневая регрессия). Добавление штрафа за сложность (нормы вектора весов L2) алгоритмически ограничивает неконтролируемый рост коэффициентов при мультиколлинеарных признаках, перераспределяя информационный вес между ними и стабилизируя дисперсию. Следует подчеркнуть, что интеграция штрафных функций

регуляризации стала математически возможной исключительно благодаря проведенной ранее процедуре Z-стандартизации: применение L-регуляризаторов на сырых данных привело бы к некорректному (несоразмерному) штрафованию признаков с естественной большой размерностью. Благодаря применению L2-регуляризации полученный усредненный вектор w является устойчивым, что обеспечивает строгую математическую состоятельность его последующей экономической интерпретации.

Сортировка коэффициентов по модулю выявила пять наиболее значимых предикторов финансовой несостоятельности предприятий, которые формируют два разнонаправленных кластера (Рисунок 5).

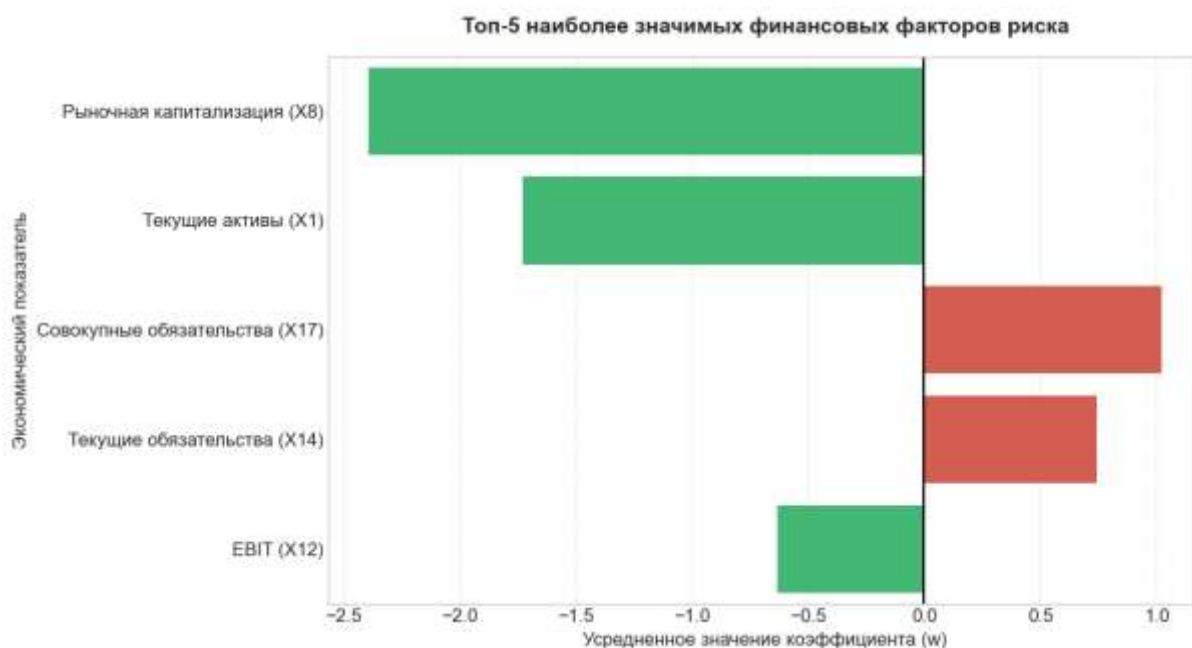


Рисунок 5. Топ-5 наиболее значимых финансовых факторов риска (усредненные веса по итогам 5-кратной кросс-валидации)

В первый кластер (факторы стабильности, зеленая зона на Рисунке 5) вошли показатели, имеющие значительный отрицательный вес. Наибольшее стабилизирующее влияние на предиктивную модель оказывает рыночная капитализация (X8) (с коэффициентом ниже -2.0), за которой следуют текущие активы (X1) и показатель операционной прибыли EBIT (X12). В контексте

фундаментального корпоративного анализа данные векторы математически отражают запас финансовой прочности организации – высокую оценку бизнеса инвесторами, наличие достаточного объема ликвидных средств и высокую операционную эффективность. Математическая логика алгоритма полностью совпадает с классической экономической теорией: наращивание «подушки» ликвидности и капитализации экспоненциально снижает вероятность перехода компании в состояние банкротства.

Во второй кластер (факторы риска, красная зона) вошли коэффициенты с положительными весами, увеличивающие итоговую вероятность дефолта. Доминирующими триггерами финансового кризиса алгоритм определил совокупные обязательства (X17) (наивысший положительный вес, превышающий 1.0) и текущие обязательства (X14). Данные параметры являются прямыми математическими маркерами высокой долговой нагрузки бизнеса. Избыточное давление долгов на денежный поток в периоды макроэкономической нестабильности критически снижает способность предприятия обслуживать свои кредиты, что алгоритм безошибочно фиксирует как прямой сигнал к повышению вероятности дефолта.

Таким образом, проведенный вычислительный эксперимент доказывает, что применение Z-стандартизации в связке с модифицированной функцией потерь позволяет трансформировать логистическую регрессию в высокоточный и, что наиболее важно для банковского сектора, экономически прозрачный инструмент риск-менеджмента.

Проведенное исследование доказывает, что прямое применение алгоритмов машинного обучения к «сырым» данным корпоративной финансовой отчетности является существенной методологической ошибкой. Фундаментальные различия в размерностях экономических показателей неизбежно приводят к вычислительной нестабильности и расходимости численных методов оптимизации, что полностью нивелирует предиктивную способность модели. Решением данной проблемы выступает строгое применение математической Z-стандартизации признакового пространства.

Как показал вычислительный эксперимент, предварительное масштабирование данных не только восстанавливает сходимость логистической регрессии, но и создает надежный фундамент для выявления скрытых паттернов финансовой несостоятельности.

Адаптация предиктивных моделей под специфику антикризисного управления требует осознанного отказа от максимизации классической метрики общей точности (Accuracy) в пользу полноты выявления рисков (Recall). Применение встроенной функции взвешенных потерь (Cost-Sensitive Learning) позволило настроить алгоритм на минимизацию наиболее критичного для кредиторов типа ошибок – пропуска фактического дефолта. Полученная конфигурация логистической регрессии успешно идентифицирует порядка 86% компаний, реально подверженных риску банкротства, компенсируя низкую прецизионность прогноза (Precision) и рост ложноположительных срабатываний предотвращением существенных финансовых потерь.

Важным научно-практическим преимуществом предложенного подхода является его высокая прозрачность и интерпретируемость. Анализ усредненных весовых коэффициентов позволил математически подтвердить базовые постулаты корпоративных финансов: наращивание собственного капитала, рыночной капитализации и операционной эффективности (ЕВІТ) выступает главным стабилизирующим фактором. В то же время избыточный рост совокупных и текущих обязательств является ключевым триггером финансового краха.

Примененная методология интерпретируемого машинного обучения лишена недостатков алгоритмов класса «черный ящик» и может быть эффективно интегрирована в процессы риск-менеджмента коммерческих банков для превентивного мониторинга кредитного портфеля и ранней диагностики вероятности дефолта заемщиков.

Литература:

1. Veganzones D., Séverin E. An investigation of bankruptcy prediction in imbalanced datasets // *Decision Support Systems*. – 2018. – Vol. 112. – P. 111–124.
2. Altman E. I. Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy // *The Journal of Finance*. – 1968. – Vol. 23, No. 4. – P. 589–609.
3. Moscatelli M., Narizzano S., Parlapiano F., Viggiano G. Corporate default forecasting with machine learning // *Bank of Italy Temi di Discussione (Working Paper)*. – 2019. – No. 1256. – P. 1–39.
4. Zięba M., Tomczak S. K., Tomczak J. M. Ensemble Boosted Trees with Synthetic Features Generation in Application to Bankruptcy Prediction // *Expert Systems with Applications*. – 2016. – Vol. 58. – P. 93–101.
5. Опекунов А. Н., Кузьмина М. Г. Принципы формирования моделей прогнозирования вероятности банкротства предприятий с использованием элементов машинного обучения // *Известия высших учебных заведений. Поволжский регион. Экономические науки*. – 2019. – С. 30–35.
6. Местников С. В., Нелунов А. И. Применение и адаптация модели машинного обучения для прогнозирования банкротства организаций // *Вестник Северо-Восточного федерального университета им. М.К. Аммосова*. – 2023. – С. 45–52.
7. Rudin C. Stop explaining black box machine learning models for high stakes decisions and use interpretable models instead // *Nature Machine Intelligence*. – 2019. – Vol. 1, No. 5. – P. 206–215.
8. Fasano F., Adornetto C., Zahid I. et al. The dilemma of accuracy in bankruptcy prediction: a new approach using explainable AI techniques to predict corporate crises // *European Journal of Innovation Management*. – 2025. – P. 1–25.
9. Le T., Vo M. T., Vo B., Lee M. Y., Baik S. W. A Hybrid Approach Using Oversampling Technique and Cost-Sensitive Learning for Bankruptcy Prediction // *Complexity*. – 2019. – P. 1–12.

10. Noh S.-H. Comparing the Performance of Corporate Bankruptcy Prediction Models Based on Imbalanced Financial Data // Sustainability. – 2023. – Vol. 15. – P. 4794.
11. Воронцов К. В. Математические методы обучения по прецедентам (теория обучения машин). – М., 2020. – 141 с.
12. American Company Bankruptcy Prediction Dataset [Электронный ресурс] // Kaggle. URL: <https://www.kaggle.com/datasets/utkarshx27/american-companies-bankruptcy-prediction-dataset> (дата обращения: 31.05.2026).
13. Hastie T., Tibshirani R., Friedman J. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. – 2nd ed. – New York: Springer, 2009. – 745 p.
14. Кремер Н. Ш. Линейная алгебра: учебник и практикум для вузов. – М.: Юрайт, 2023. – 422 с.
15. Халл Дж. К. Управление рисками и финансовые институты. – М.: Диалектика, 2020. – 1072 с.