

Разработка подхода к классификации дефолта заемщика на основе интеграции методов предварительной обработки и методов машинного обучения

А. Ф. Константинов[✉], Л. П. Дьяконова

Российский экономический университет имени Г. В. Плеханова
115054, Россия, Москва, Стремянный переулок, 36

Аннотация. Задача прогнозирования дефолта заемщиков лежит в основе финансовой стабильности кредитных организаций и является актуальной.

Цель исследования – разработка и оценка работы интегрального метода прогнозирования дефолта заемщика.

Материалы и методы. Исследование проведено путем моделирования работы интегрального метода прогнозирования дефолта заемщиков, анализа и сравнения полученных результатов с базовой моделью ИИ и формирования выводов.

Результаты. По итогам анализа зависимостей разработан и просчитан интегральный метод прогнозирования дефолта заемщика, который показал значительный рост показателей качества (рост средней точности – на 0,383, рост f1-score на – 0,509 и точности – на 0,792) относительно базовой модели. В данной статье приведены результаты экспериментов по улучшению показателей качества моделей машинного обучения, выполняющих прогнозирование дефолта заемщика.

Выводы. Разработка интегральных методов прогнозирования дефолта заемщиков позволит повысить точность и надежность прогнозных моделей, что имеет большое практическое значение.

Ключевые слова: методы снижения дисбаланса классов, метод выделения аномалий в отдельную модель, метод баггинга, интегральный метод прогнозирования дефолта заемщика

Поступила 11.06.2025, одобрена после рецензирования 15.08.2025, принята к публикации 25.09.2025

Для цитирования. Константинов А. Ф., Дьяконова Л. П. Разработка подхода к классификации дефолта заемщика на основе интеграции методов предварительной обработки и методов машинного обучения // Известия Кабардино-Балкарского научного центра РАН. 2025. Т. 27. № 5. С. 68–79. DOI: 10.35330/1991-6639-2025-27-5-68-79

MSC: 90C99

Original article

Comparative analysis of class imbalance reduction methods in building machine learning models in the financial sector

A.F. Konstantinov[✉], L.P. Dyakonova

Plekhanov Russian University of Economics
36 Stremyanny lane, Moscow, 115054, Russia

Abstract. Borrower default prediction is a pressing issue that underlies the financial stability of credit institutions.

Aim. This study is to develop and evaluate an integrated borrower default prediction method.

Materials and methods. The study was conducted by simulating the integrated borrower default prediction method, analyzing and comparing the results with the baseline AI model, and drawing conclusions.

Results. Based on the analysis of dependencies, an integrated borrower default prediction methods developed and calculated. It demonstrated a significant improvement in quality metrics (an increase in average accuracy of 0.383, an increase in f1-score of 0.509, and an increase in accuracy of 0.792) relative to the baseline model. This article presents the results of experiments aimed at improving the quality metrics of machine learning models used to predict borrower default.

Conclusion. The development of integrated borrower default prediction methods will improve the accuracy and reliability of forecast models, which is of great practical importance.

Keywords: methods for reducing class imbalance, methods for isolating anomalies into a separate model, bagging method, integral method for predicting borrower default

Submitted on 11.06.2025,

approved after reviewing on 15.08.2025,

accepted for publication on 25.09.2025

For citation. Konstantinov A.F., Dyakonova L.P. Comparative analysis of class imbalance reduction methods in building machine learning models in the financial sector. *News of the Kabardino-Balkarian Scientific Center of RAS.* 2025. Vol. 27. No. 5. Pp. 68–79. DOI: 10.35330/1991-6639-2025-27-5-68-79

ВВЕДЕНИЕ

По данным Центрального банка Российской Федерации «О развитии банковского сектора Российской Федерации в декабре 2024» [1], в декабре 2024 года объем проблемных кредитов составлял 4,8 трлн руб. В корпоративном портфеле доля проблемных кредитов осталась на уровне 3,8 %, а в розничном – 4,6 %. При этом за 2024 год доля проблемных корпоративных кредитов сократилась на 0,6 п.п. – с 4,4 % на начало года, но это связано с ростом портфеля (объем проблемных кредитов вырос за год на 4,1 %). Доля розничных проблемных кредитов, напротив, выросла на 0,5 п.п., что обусловлено постепенным вызреванием кредитов, выданных по высоким ставкам, а также ростом просрочек по кредитам наличными, предоставленным в том числе в 1 полугодии 2024 года, когда банки активно кредитовали новых заемщиков без кредитной истории. Даже минимальное увеличение показателей качества методов прогнозирования дефолта заемщиков и снижение доли проблемных кредитов приведут к значительным эффектам как для потребителей (за счет снижения надбавки на риск в стоимости кредитов), так и для банков (за счет увеличения объема выдачи кредитов при снижении надбавки на риск в стоимости кредитов). Также снижение доли проблемных кредитов положительно скажется на повышении эффективности банковского сектора в целом по стране.

Одними из особенностей финансовых данных являются значительный дисбаланс классов, наличие аномалий в данных и большая зависимость от данных, используемых при обучении. Современные алгоритмы машинного обучения могут работать с такими особенностями финансовых данных «по умолчанию», но есть универсальные методы, которые позволяют улучшить показатели качества моделей машинного обучения при прогнозировании дефолта заемщика. Данная статья направлена на изучение зависимостей показателей качества при прогнозировании дефолта заемщика от параметров методов, увеличивающих показатели качества классификации.

ОПИСАНИЕ НАБОРА ДАННЫХ

1. Bank Loan Defaulter Prediction (Hackathon)¹

¹ <https://www.kaggle.com/datasets/ankitkalauni/bank-loan-defaulter-prediction-hackathon?select=train.csv>

Набор данных содержит информацию, необходимую, чтобы предсказать, будет ли человек неплательщиком по кредиту. Набор данных содержит 67463 строки и 34 переменные. Доля положительного класса составила 0,09. В качестве положительного класса рассматриваются случаи дефолта заемщика. Классы информации в наборе данных:

- Информация о кредите (сумма кредита; сумма покупки; сумма, выплаченная инвестором; срок кредита; процентная ставка; тип кредита; тип заявки на кредит; уникальный статус листинга кредита (в ожидании, перенаправлен)).
- Информация о заемщике (класс заемщика по классификации банка; подкласс заемщика по классификации банка; номера партий для клиента; продолжительность работы на последнем месте; есть ли недвижимость; количество открытых счетов; признак кредитной линии; общее количество кредитных линий, доступных представителям кредитной линии; общий возобновляемый остаток кредита; используемая сумма кредита относительно общего возобновляемого баланса; отношение платежей по кредиту к доходу; максимальная сумма, которую заемщик может заимствовать в рамках всех своих открытых возобновляемых кредитных продуктов; общий баланс по всем счетам; общее количество процентов, полученных по настоящий момент; общее количество запросов на кредит за 6 месяцев).
- История просрочек заемщика (как долго клиент выплачивал регулярные ежемесячные платежи после зачисления в партию; общая сумма взысканных долгов за последние 12 месяцев, за исключением медицинских сборов; количество записей о публичных нарушениях; количество кредитов, по которым клиент допустил просрочку платежей; количество просрочек более 30 дней за 2 года).
- Проверки (общая сумма штрафа за просрочку платежа, полученная на сегодняшний день; сумма средств, возвращенных банку после списания кредита; стоимость услуг по взысканию долгов после их списания; общая сумма взысканных задолженностей; статус проверки).

Целевая переменная: статус кредита (0 – оплачен / 1 – дефолт).

СХЕМА ВАЛИДАЦИИ

Для каждого набора данных наблюдения разделялись методом кросс-валидации StratifiedShuffleSplit² на тренировочные (50 %) и тестовые (50 %) данные, и для каждого набора тренировочных данных 3 раза проводилось разделение на тренировочный и валидационный набор данных с помощью метода кросс-валидации kFold³ (20 % на валидационные данные, 80 % – данные для обучения).

ОПИСАНИЕ БАЗОВОЙ МОДЕЛИ МАШИННОГО ОБУЧЕНИЯ

Базовая модель машинного обучения в данной статье рассматривается как решение без улучшений, относительно которого будет измеряться эффективность предложенных методов. Для моделирования использовалась модель градиентного бустинга LightGBM, разработанная Microsoft. Модель градиентного бустинга представляет собой метод ансамблевого обучения, который объединяет несколько слабых алгоритмов, обычно деревьев решений

²Метод кросс-валидации StratifiedShuffleSplit – это метод, используемый для разделения данных на тренировочные и тестовые наборы с учетом стратификации. Это означает, что при разделении сохраняется пропорциональное соотношение классов в целевой переменной. Это важно для данных финансового сектора, так как для них характерен большой дисбаланс классов.

³Метод кросс-валидации kFold разбивает исходный набор данных на k равных подмножеств (фолдов). В каждом из k итераций одно из подмножеств используется в качестве тестового набора, а остальные (k-1) – для обучения модели. После каждой итерации вычисляется метрика качества.

небольшой глубины. На каждой итерации модели последовательно обучаются снижать ошибки прогнозов предыдущих моделей. Общая схема бустинга приведена на рисунке 1.




Рис. 1. Общая схема бустинга / **Fig. 1.** General boosting scheme

Установлены следующие гиперпараметры модели: количество решающих деревьев бустинга ('n_estimators') = 3000, шаг обучения ('learning_rate') = 0,03, максимальная глубина дерева бустинга ('max_depth') = 6, количество итераций обучения без увеличения показателей качества, после которых обучение остановится ('early_stopping_rounds') = 100, данные для валидации ('eval_set') = (X_val, y_val). После разбиения каждого набора данных на сплит и фолд на данных для обучения был обучен кодировщик категориальных переменных TargetEncoder⁴ из библиотеки category_encoders. Так как при обучении TargetEncoder мы использовали только данные для обучения, утечка данных не происходит. Далее преобразованы категориальные переменные валидационных и тестовых наборов данных X_val, X_test.

ПРИМЕНЕНИЕ МЕТОДА СНИЖЕНИЯ ДИСБАЛАНСА КЛАССОВ

В статье [2] Амаль Аль Али и др. проводят исследования, связанные с прогнозированием мошенничества с финансовой отчетностью. Лучшие результаты по сравнению с классическими моделями машинного обучения (логистическая регрессия, деревья решений, машины опорных векторов, AdaBoost и случайный лес) показывают модели на основе бустинга (XGBoost) с проведенными мероприятиями по снижению дисбаланса классов и автоматизированной настройкой гиперпараметров модели.

В нашей статье [3] методы снижения дисбаланса классов показали свою эффективность (метод RandomOverSampler) при классификации дефолта заемщика. Чтобы понять, как именно увеличение отношения количества наблюдений положительного класса к количе-

⁴TargetEncoder – метод кодирования категориальных переменных, при котором признаки заменяются смесью апостериорной вероятности цели с учетом конкретного категориального значения и априорной вероятности цели по всем обучающим данным.

ству наблюдений отрицательного класса (далее – отношение положительного класса к отрицательному) влияет на показатели качества классификации, в задаче классификации дефолта заемщика был задан шаг отношения положительного класса к отрицательному – 0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 0,7; 0,8; 0,9; 1. Далее после разделения данных на тренировочные, валидационные и тестовые к тренировочным данным применяется метод снижения дисбаланса RandomOverSampler, в рамках которого была проведена случайная выборка дополнительных наблюдений из данных для обучения путем дублирования наблюдений положительного класса до увеличения отношения положительного класса к отрицательному до уровня, установленного для соответствующего шага. После этого обучалась базовая модель классификации дефолта заемщика и замерялись показатели качества классификации.

ПРИМЕНЕНИЕ МЕТОДА ВЫДЕЛЕНИЯ АНОМАЛИЙ В ОТДЕЛЬНУЮ МОДЕЛЬ

В статье [4] авторы исследуют удаление выбросов, определенных разными методами выделения аномалий (LOF, CBLOF, IForest, and COPOD) совместно с методами корректировки дисбаланса. Это приносит улучшение показателей качества кредитного скоринга. В наших исследованиях вместо удаления выбросов мы обучаем отдельную модель прогнозирования дефолтов заемщиков, только на наблюдениях – выбросах.

Аномалии, присутствующие в данных, могут существенно изменять коэффициенты моделей ИИ и приводить к смещению модели ИИ. Классические модели ИИ (например, логистическая регрессия) чувствительны к аномалиям, и одна серьезная аномалия может значительно скорректировать уравнение регрессии. Ансамблевые модели на основе градиентного бустинга более устойчивы к аномалиям, но они также ухудшают свои показатели качества при наличии аномалий в данных. В данной статье мы рассмотрим автоматизированный подход к работе с аномалиями, который при применении в производственной среде должен быть дополнен экспертным анализом причин аномалий.

В нашей статье [5] с помощью модели Isolation Forest [6] наблюдения были разделены на 2 набора с нормальными и аномальными данными. Далее обучалось 2 модели ИИ, аналогичные базовым моделям, для нормальных и аномальных наблюдений. Когда приходят новые наблюдения, сначала применяется модель IsolationForest⁵, предсказывающая уровень аномалии, потом одна из моделей (для нормальных или для аномальных наблюдений) проводит прогнозирование. Обучение дополнительной модели для аномалий отдельно приводило к статистически значимому росту показателей качества при прогнозировании дефолта заемщика. В данной статье раскрываются результаты экспериментов, фиксирующие зависимости показателей качества моделей классификации от отношения положительного класса к отрицательному, которые обрабатываются дополнительной моделью ИИ для аномалий. Данный эксперимент был предпринят на основе прочтения статьи «Обзор методов обнаружения выбросов/аномалий в данных временных рядов» [7] и изучения LIME (Local Interpretable Model-agnostic Explanations) [8] – одной из моделей объяснимого искусственного интеллекта, в которой в локальной области строится простая интерпретируемая модель.

ПРИМЕНЕНИЕ МЕТОДА БАГГИНГА

Метод баггинга (bootstrap aggregating) [9] – это ансамблевый алгоритм, который обучает базовые классификаторы на случайной выборке с возвращением из набора данных для обучения и далее агрегирует прогнозы базовых моделей путем усреднения или выбора большинства го-

⁵Модель IsolationForest применяется как одна из моделей поиска аномалий. Исследования по определению наиболее подходящей модели поиска аномалий в контексте метода выделения аномалий в отдельную модель при решении задачи прогнозирования дефолта заемщика запланированы.

лосов. За счет усреднения большого количества прогнозов базовых классификаторов на разных подвыборках данных происходит снижение дисперсии и увеличение точности. Основным параметром настройки данного метода – это количество базовых классификаторов. Целесообразно увеличивать количество базовых классификаторов до момента, пока показатели качества не перестанут значительно улучшаться и не выйдут на плато (асимптоту). Данный метод вычислительно затратен. Общая схема баггинга приведена на рисунке 2.




Рис. 2. Общая схема баггинга / **Fig. 2.** General bagging scheme

Применение баггинга обусловлено успешным его применением в статье «Метод бэггинга для классификатора автоэнкодера с обучением для кредитного скоринга» [10]. Исследователи объединяют автоэнкодер с баггингом на финансовых данных. Данное исследование отличается от эксперимента в нашей статье тем, что мы используем бустинг в качестве базовой модели вместо автоэнкодера на базе нейросетей.

В статье [11] авторы предлагают гибридный метод для кредитного скоринга. Используют XGBoost в качестве базового обучающегося алгоритма, что обеспечивает прогноз с низким смещением. Для улучшения дисперсии используют баггинг. Экспериментальные результаты на австралийских, немецких, японских и тайваньских наборах данных показывают, что предлагаемое каскадное дерево решений с усилением методом баггинга обеспечивает более точный результат кредитного скоринга.

РАЗРАБОТКА ИНТЕГРАЛЬНОГО МЕТОДА ПРОГНОЗИРОВАНИЯ ДЕФОЛТА ЗАЕМЩИКА

Проведя анализ применения метода снижения дисбаланса классов, метода выделения аномалий в отдельную модель и метода баггинга, считаем целесообразным совместное применение данных методов и предлагаем интегральный метод прогнозирования дефолта заемщика (далее – интегральный метод).

На вход интегрального метода подаются набор данных X и целевая переменная y . Набор данных разделяется на данные для обучения, настройки и данные для проверки. Далее на данных для обучения обучается TargetEncoder и производится кодирование категориальных переменных.

После кодирования категориальных переменных обучается модель определения уровня аномалии. С помощью модели IsolationForest для всех наблюдений проводится прогнозирование уровня аномалии и определяется точка отсечения на нормальные и аномальные

наблюдения. Точка отсечения уровня аномалии является параметром для оптимизации. Далее данные для обучения, настройки и проверки разделяются на нормальные и аномальные.

Для каждой части данных (нормальные и аномальные) отдельно проводится применение метода снижения дисбаланса классов (RandomOverSampler) к данным для обучения. Отношение количества наблюдений положительного класса к количеству наблюдений отрицательного класса является параметром для оптимизации. Из данных для обучения после применения метода снижения дисбаланса классов проводится случайная выборка с возвращением данных для обучения необходимого количества базовых моделей на основе бустинга. Количество базовых моделей является оптимизируемым параметром в баггинге. Итоговый прогноз каждого наблюдения формируется как среднее значение вероятностей базовых моделей. Оптимизация проводилась путем перебора по сетке заранее определенных параметров оптимизации.

ОБСУЖДЕНИЕ

В данной статье рассмотрены методы, которые по результатам наших прошлых исследований показали значимое увеличение показателей качества при прогнозировании дефолта заемщика. С помощью дополнительных исследований мы фиксируем зависимости показателей качества классификации от настроечных параметров рассмотренных методов. Также ожидается, что после корректировки дисбаланса классов и метод выделения аномалий в отдельную модель, и метод баггинга будут показывать лучшие результаты за счет того, что на сбалансированных данных базовой модели будет проще фиксировать основные закономерности.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

Таблица 1. Зависимость показателей качества классификации дефолта заемщика от отношения количества наблюдений положительного класса к количеству наблюдений отрицательного класса

Table 1. Dependence of the quality indicators of borrower default classification on the ratio of the number of observations of the positive class to the number of observations of the negative class

Отношение количества наблюдений положительного класса к количеству наблюдений отрицательного класса	Средняя точность	Сбалансированная точность	Брайер скор	F1_score	Точность	Полнота	ROC_AUC
base	0,115	0,500	0,084	0	0	-	0,549
0,1	0,167	0,500	0,084	-	-	-	0,561
0,2	0,187	0,504	0,086	0,016	0,538	0,008	0,609
0,3	0,329	0,534	0,088	0,129	0,882	0,070	0,690
0,4	0,378	0,578	0,093	0,267	0,836	0,159	0,703
0,5	0,399	0,612	0,100	0,353	0,745	0,232	0,708
0,6	0,417	0,642	0,107	0,410	0,639	0,302	0,712
0,7	0,429	0,662	0,113	0,428	0,540	0,355	0,714
0,8	0,436	0,674	0,120	0,424	0,456	0,397	0,715
0,9	0,445	0,682	0,126	0,410	0,390	0,432	0,716
1	0,447	0,684	0,133	0,389	0,338	0,460	0,716
Рост показателя, ед.	0,332	0,184	0,049	0,428	0,882	0,460	0,167

Таблица 2. Зависимость показателей качества классификации дефолта заемщика от уровня аномалии для отнесения наблюдений в отдельную модель ИИ

Table 2. Dependence of the quality indicators of borrower default classification on the level of anomaly for assigning observations to a separate AI model

Уровень аномалии для отнесения наблюдений в отдельную модель	Средняя точность	Сбалансированная точность	Брайер скор	F1_score	Точность	Полнота	ROC_AUC
base	0,115	0,500	0,084	-	-	-	0,549
0,01	0,116	0,500	0,084	-	-	-	0,552
0,025	0,112	0,500	0,084	-	-	-	0,545
0,05	0,120	0,500	0,084	-	-	-	0,554
0,075	0,121	0,500	0,084	-	-	-	0,555
0,1	0,127	0,500	0,084	-	-	-	0,563
0,125	0,121	0,500	0,084	-	-	-	0,558
0,15	0,117	0,500	0,084	-	-	-	0,550
0,175	0,120	0,500	0,084	-	-	-	0,555
0,2	0,118	0,500	0,084	-	-	-	0,552
0,3	0,127	0,500	0,084	-	-	-	0,562
0,4	0,137	0,500	0,083	0,000	0,160	0,000	0,572
0,5	0,154	0,500	0,083	0,001	0,348	0,000	0,590
Рост показателя, ед.	0,039	0	0	0,001	0,348	0	0,041

Таблица 3. Зависимость показателей качества прогнозирования дефолта заемщика от количества базовых классификаторов при применении метода баггинга

Table 3. Dependence of the quality indicators of borrower default classification on the number of basic classifiers when using the bagging method

Количество базовых классификаторов	Средняя точность	Сбалансированная точность	Брайер скор	F1_score	Точность	Полнота	ROC AUC
base	0,115	0,500	0,084	-	-	-	0,549
2	0,118	0,500	0,084	-	-	-	0,553
5	0,127	0,500	0,084	-	-	-	0,565
10	0,134	0,500	0,084	-	-	-	0,576
20	0,139	0,500	0,084	-	-	-	0,585
25	0,141	0,500	0,084	-	-	-	0,586
30	0,142	0,500	0,084	-	-	-	0,589
35	0,142	0,500	0,084	-	-	-	0,590
40	0,143	0,500	0,084	-	-	-	0,592
50	0,145	0,500	0,084	-	-	-	0,594
Рост показателя, ед.	0,030	0	0	0	0	0	0,044

Таблица 4. Сравнение показателей качества интегрального метода прогнозирования дефолта заемщика с показателями качества базовой модели классификации дефолта заемщика

Table 4. Comparison of the quality indicators of the integral method for predicting borrower default with the quality indicators of the basic model for classifying borrower default

Показатель качества	Наименование метода		Рост
	базовый	интегральный	
Средняя точность	0,115	0,497	0,383
Сбалансированная точность	0,500	0,682	0,182
Брайер скор	0,084	0,070	-0,013
F1_score	0	0,509	0,509
Точность	0	0,792	0,792
Полнота	0	0,374	0,374
ROC_AUC	0,549	0,720	0,170

Выводы

С точки зрения важности показателей качества методов ИИ при решении задачи прогнозирования дефолта заемщика целесообразно рассматривать финансовые показатели, такие как прибыль или убыток от группы клиентов с определенной вероятностью дефолта заемщика. Так как эти данные не публикуются, то наиболее важным показателем качества считаем f1-score, так как позволяет поддерживать соотношение между точностью и полнотой при оптимизации моделей. Высокая точность модели показывает: если модель предсказала высокую вероятность дефолта, то действительно, скорее всего, будут финансовые потери. И при этом понятно, что если у модели ИИ низкая полнота, то модель определяет мало реальных дефолтов и необходимо улучшать качество модели. Таким образом, показатель качества классификации f1-score как среднегармоническое между точностью и полнотой наиболее связан с бизнес-результатами.

Брайер скор показывает, насколько хорошо откалибрована модель, то есть прогнозная вероятность дефолта соответствует фактической частоте дефолтов в группах со схожим прогнозом вероятности дефолта. Брайер скор не связан напрямую с бизнес-результатом.

В условиях сильного дисбаланса FPR может оставаться низким даже при большом количестве ложноположительных прогнозов из-за большого числа TN, что делает ROC AUC излишне оптимистичной. Показатели ROC_AUC могут быть достаточно высокими, но при этом точность (бизнес-результат скоринга) будет отрицательной.

Средняя точность – это среднее значение точности по всем возможным порогам точки отнесения к положительному классу классификации, что позволяет более полно оценить поведение модели при разных точках отсечения, но не связано с полнотой, в отличие от f1-score, где учитываются точность и полнота для одной точки отсечения, равной 0,5 по умолчанию.

Сбалансированная точность – как среднее арифметическое между точностью положительного и отрицательного класса. Не в полной мере учитывает дисбаланс, потому что доля положительного класса в задачах прогнозирования дефолта заемщиков часто составляет от 5 до 15 %, формула сбалансированной точности учитывает 50 % и увеличивает вклад в точность положительного класса (излишне оптимистична). Также данный параметр не учитывает полноту, а полнота показывает, насколько модель способна выделять из данных потенциальный дефолт (убытки).

Выводы по применению метода снижения дисбаланса классов

Увеличение доли положительного класса приводит к увеличению всех показателей качества. Оптимальные значения точности достигаются в диапазоне доли положительного класса от 0,1 до 0,3. Настройка классификации дефолта заемщика по точности может быть важна, если стоит задача минимально сократить продажи из-за отклонения заявок на кредит. Баланс между точностью и полнотой достигается (f1-score) в диапазоне доли положительного класса от 0,7 до 0,8. При применении в промышленной среде оптимальная точка определяется исходя из накопительной убыточности ограниченного классификатором дефолта заемщика сегмента заемщиков. Применение методов снижения дисбаланса классов является важным для классификации дефолта заемщика. Для корректной работы базовых классификаторов метод снижения дисбаланса классов необходимо применять до их обучения.

Выводы по применению метода выделения аномалий в отдельную модель

Увеличение уровня аномалий для отнесения наблюдений в отдельную модель имеет разные точки оптимума для разных наборов данных. Это указывает на разную зашумленность в разных наборах данных. При применении метода выделения аномалий в отдельную модель основной рост наблюдается у показателя качества точность. Обратите внимание на показатель точность. Метод выделения аномальных наблюдений в отдельную модель значительно повышает точность, но улучшение начинается только на больших уровнях аномалии для отнесения наблюдений в отдельную модель. Это может свидетельствовать о том, что разделение данных на нормальные и аномальные является частным случаем обучения разных базовых моделей на разных кластерах данных. Исследования по применению кластерного анализа для разделения данных и обучения разных базовых моделей для прогнозирования дефолта заемщика запланированы.

Выводы по применению метода баггинга

F1-score, точность и полнота равны нулю. Поэтому оценивать эффективность будем по ранжирующей способности (ROC_AUC) и средней точности. Если посмотреть на метод снижения дисбаланса классов, он позволяет повысить f1-score, точность и полноту и далее применить метод баггинга. Таким образом, метод баггинга должен применяться после применения остальных методов повышения показателей качества при прогнозировании дефолта заемщика.

Выводы по применению интегрального метода

Предложенный интегральный метод прогнозирования дефолта заемщика имеет показатели качества, существенно превышающие показатели качества отдельных лучших методов, так как существуют синергетические эффекты от совместного применения методов. Также был проведен поиск глобального оптимума параметров, определяющих архитектуру интегрального метода прогнозирования дефолта заемщика.

Однако абсолютные значения f1-score (0,509) и средней точности (0,497) остаются небольшими даже после применения интегрального метода. Основной вклад вносит низкая полнота. То есть методы не видят большую долю заемщиков с дефолтом. Следующие исследования на тему прогнозирования дефолта заемщика будут направлены на:

- эксперименты с пространством переменных, чтобы сформировать новую проекцию на данные и доставить дополнительную информацию о заемщиках в базовые модели (увеличить полноту);
- расширение перечня методов повышения качества прогнозирования дефолта заемщика;

- рассмотрение способов ускорения обучения и оптимизации настроечных параметров интегрального метода с минимальными потерями качества;
- увеличение перечня наборов данных для уверенной фиксации результатов.

ЗАКЛЮЧЕНИЕ

В ходе исследования был проведен анализ применения метода снижения дисбаланса классов, метода выделения аномалий в отдельную модель, метода баггинга и предложен интегральный метод прогнозирования дефолта заемщика. Предложенный интегральный метод прогнозирования дефолта заемщика имеет показатели качества, существенно превышающие показатели качества как базовой модели, так и каждого из рассматриваемых методов повышения качества прогнозирования дефолта заемщика. Таким образом, цели и задачи данного исследования достигнуты.

СПИСОК ЛИТЕРАТУРЫ / REFERENCES

1. Информационно-аналитический материал о развитии банковского сектора Российской Федерации в декабре 2024. [Электронный ресурс]. Режим доступа: https://www.cbr.ru/collection/collection/file/55056/razv_bs_24_12.pdf (дата обращения: 17.09.2025)

Information and analytical material on the development of the banking sector of the Russian Federation in December 2024. [Электронный ресурс]. Режим доступа: https://www.cbr.ru/collection/collection/file/55056/razv_bs_24_12.pdf (дата обращения: 17.09.2025). (In Russian)

2. Ali A.A., Khedr A.M., El-Bannany M., Kanakkayil S. A powerful predicting model for financial statement fraud based on optimized xgboost ensemble learning technique. *Applied Sciences*. 2023. Vol. 13. No. 4. P. 2272. DOI: 10.3390/app13042272

3. Константинов А. Ф., Дьяконова Л. П. Сравнительный анализ методов снижения дисбаланса классов при построении моделей машинного обучения в финансовом секторе // Известия Кабардино-Балкарского научного центра РАН. 2025. Т. 27. № 1. С. 143–151. DOI: 10.35330/1991-6639-2025-27-1-143-151

Konstantinov A.F., Dyakonova L.P. Comparative analysis of class imbalance reduction methods in building machine learning models in financial sector. *News of the Kabardino-Balkarian Scientific Center of RAS*. 2025. Vol. 27. No. 1. Pp. 143–151. DOI: 10.35330/1991-6639-2025-27-1-143-151. (In Russian)

4. Qian H., Zhang S., Wang B. et al. A comparative study on machine learning models combining with outlier detection and balanced sampling methods for credit scoring 2021. [Электронный ресурс]. Режим доступа: <https://arxiv.org/abs/2112.13196> (дата обращения: 01.09.2025). DOI: 10.48550/arXiv.2112.13196

5. Dyakonova L., Konstantinov A. Approaches to risk analysis in the financial sector based on machine learning and artificial intelligence methods / MPRA Paper. [Электронный ресурс]. Режим доступа: <https://mpra.ub.uni-muenchen.de/122941/> (дата обращения: 17.09.2025)

6. Liu F.T., Ting K.M., Zhou Z.H. Isolation forest. *IEEE Xplore*. 2008. Pp. 413–422. DOI: 10.1109/ICDM.2008.17

7. Blázquez-García A., Conde A., Mori U., Lozano J.A. A review on outlier/anomaly detection in time series data. [Электронный ресурс]. Режим доступа: <https://arxiv.org/abs/2002.04236> (дата обращения: 01.09.2025).

8. Ribeiro M.T., Singh S., Guestrin C. Why should I trust you? Explaining the predictions of any classifier. [Электронный ресурс]. Режим доступа: <https://arxiv.org/abs/1602.04938> (дата обращения: 01.09.2025).

9. Breiman L. Bagging predictors. *Machine Learning*. 1996. Vol. 24. No. 2. Pp. 123–140.
10. Abdoli M., Akbari M., Shahrabi J. Bagging supervised autoencoder classifier for credit scoring. *Preprint*. DOI: 10.48550/arXiv.2108.078
11. Zou Y., Gao C., Xia M., Pang C. Credit scoring based on a bagging-cascading boosted decision tree. *Intelligent Data Analysis*. 2022. Vol. 26. No. 6. Pp. 1557–1578. DOI: 10.3233/IDA-216228

Вклад авторов: все авторы сделали эквивалентный вклад в подготовку публикации. Авторы заявляют об отсутствии конфликта интересов.

Contribution of the authors: the authors contributed equally to this article. The authors declare no conflict of interest.

Финансирование. Исследование проведено без спонсорской поддержки.

Funding. The study was performed without external funding.

Информация об авторах

Константинов Алексей Федорович, аспирант кафедры информатики, Российский экономический университет имени Г. В. Плеханова;

115054, Россия, Москва, Стремянный переулок, 36;

konstantinovaf@gmail.com, ORCID: <https://orcid.org/0009-0000-9591-3301>, SPIN-код: 3088-3121

Дьяконова Людмила Павловна, канд. физ.-мат. наук, доцент, кафедра информатики, Российский экономический университет имени Г. В. Плеханова;

115054, Россия, Москва, Стремянный переулок, 36;

Dyakonova.LP@rea.ru, ORCID: <https://orcid.org/0000-0001-5229-8070>, SPIN-код: 2513-8831

Information about the authors

Alexey F. Konstantinov, Postgraduate Student, Department of Informatics, Plekhanov Russian University of Economics;

36 Stremyanny lane, Moscow, 115054, Russia;

konstantinovaf@gmail.com, ORCID: <https://orcid.org/0009-0000-9591-3301>, SPIN-code: 3088-3121

Lyudmila P. Dyakonova, Candidate of Physical and Mathematical Sciences, Associate Professor, Department of Informatics, Plekhanov Russian University of Economics;

36 Stremyanny lane, Moscow, 115054, Russia;

Dyakonova.LP@rea.ru, ORCID: <https://orcid.org/0000-0001-5229-8070>, SPIN-code: 2513-8831