

УДК 336.71

DOI 10.26118/2782-4586.2026.41.78.019

Мищенко Татьяна Леонидовна

Московский университет им. А.С. Грибоедова

Бельский Артем Евгеньевич

Московский университет им. А.С. Грибоедова

Шмендель Марк Евгеньевич

Московский университет им. А.С. Грибоедова

Модели машинного обучения для прогнозирования кредитного риска в банковской сфере

Аннотация. В статье рассматриваются особенности модели машинного обучения, которые помогают банкам и иным кредитным учреждениям более точно оценивать кредитный риск. Научная статья отражает проблемы классических методов обработки информации, которые в сегодняшних реалиях всё хуже справляются с растущими объёмами данных и быстрыми изменениями в поведении клиентов. Авторами статьи раскрывается вопрос: «Почему банки начали переходить к более гибким алгоритмам, и что мешает им использовать ИИ без ограничений». В работе представлены заключения по использованию современной модели машинного обучения, включающего в себя новое поколение инструментов управления кредитным риском. Данное направление позволяет банковскому сектору гибко адаптироваться к усложняющемуся финансовому пространству и быстро растущим требованиям рыночной системы. На основе исследований и практических примеров показано, какие модели применяются чаще всего и как они влияют на работу денежно-кредитного анализа. Также в статье обсуждаются требования регуляторов и основные трудности, которые возникают при внедрении сложных моделей. Кроме того, авторами подчёркиваются особенности и способы получения положительного результата, который достигается тогда, когда новые технологии сочетаются с прозрачными правилами использования цифровых технологий и понятной системой ведения контроля.

Ключевые слова: кредитный риск, финансовое поведение клиентов, традиционные скоринговые подходы, логистическая регрессия, градиентный бустинг, нейросети, регуляторные органы.

Mishchenko Tatyana Leonidovna

Moscow University named after A.S. Griboyedov

Belsky Artem Evgenievich

Moscow University named after A.S. Griboyedov

Shmendel Mark Evgenievich

Moscow University named after A.S. Griboyedov

Machine learning models for predicting credit risk in the banking sector

Abstract. The article discusses the features of a machine learning model that helps banks and other credit institutions to more accurately assess credit risk. The scientific article reflects the problems of classical information processing methods, which are increasingly unable to cope with the growing volume of data and rapid changes in customer behavior in today's reality. The authors of the article explore the question: "Why are banks starting to switch to more flexible algorithms, and what prevents them from using AI without restrictions?" The article presents conclusions on the use of a

modern machine learning model that includes a new generation of credit risk management tools. This area allows the banking sector to adapt flexibly to the increasingly complex financial environment and the rapidly growing demands of the market system. Based on research and practical examples, the article shows which models are most commonly used and how they affect the performance of monetary analysis.

Keywords: credit risk, customer financial behavior, traditional scoring approaches, logistic regression, gradient boosting, neural networks, regulatory authorities.

Введение.

Актуальность темы исследования обусловлена тем, что современная банковская система функционирует в условиях высокой неопределённости, где динамика экономических процессов, поведенческие особенности клиентов и технологические преобразования формируют непрерывно изменяющийся контекст. Кредитный риск, традиционно рассматриваемый как вероятность невыполнения заёмщиком своих обязательств, перестал быть величиной, поддающейся описанию стандартными статистическими методами. Финансовые рынки ускоряются, бизнес-модели диверсифицируются, а цифровизация создает сложные многомерные профили клиентов, в которых традиционные параметры — доход, занятость, долговая нагрузка, кредитная история — оказываются недостаточными для полноценного анализа.

Материалы и методы. При проведении исследования авторами были рассмотрены различные научные подходы к данному вопросу. Систематизация теоретических и практических взглядов таких ученых, как: Абрамов А. А., Евстигнеев Е. Н., Поляков П. В., Савин А. Ю. и других практиков позволили сделать заключение о научной значимости исследуемого вопроса. Научная значимость заключается в том, что современные модели в сфере кредитования основаны на оценке кредитоспособности заёмщика, анализе эффективного управления кредитным портфелем, оценке рисков и особенности использования современных технологий. Исходя из вышеизложенного, целью нашего исследования является проанализировать классические и современные инструменты управления кредитным риском и выявить эффективные модели машинного обучения для прогнозирования кредитного риска в банковской сфере.

Классические скоринговые методики на протяжении десятилетий обеспечивали банкам приемлемый уровень качества прогнозов, однако рост объемов данных и усложнение потребительского поведения перевели управление кредитным риском в новую плоскость. Банковская отрасль столкнулась с ситуацией, когда информация поступает в потоковом режиме, но её объём и разнообразие делают невозможным выявление закономерностей исключительно вручную или на основе ограниченных линейных моделей. На этом фоне модели машинного обучения постепенно стали рассматриваться как необходимый инструмент повышения точности, адаптивности и устойчивости риск-оценок.

На начальном этапе отношение к искусственному интеллекту в банковском секторе было сдержанным: присутствовали опасения относительно непрозрачности алгоритмов, сложности их интерпретации и соответствия регуляторным требованиям. Однако развитие методов объяснимости и накапливающиеся эмпирические результаты позволили рассматривать ИИ не как экспериментальную технологию, а как компонент зрелого риск-менеджмента.

За последние годы кредитный риск радикально изменился в своей структуре. Финансовое поведение клиентов всё чаще описывается через потоковые транзакции, цифровые следы, анализ поведения в онлайн-каналах и динамические паттерны потребления. Клиент перестаёт быть статичным объектом анализа: его финансовая активность формирует сложную, многослойную картину, где прошлое поведение не всегда надёжно предсказывает будущие

действия. К этому добавляются колебания макроэкономических условий, доступность различных механизмов перекредитования, развитие финтех-сервисов, предлагающих решения в пределах секунд, и постоянная трансформация моделей занятости и доходов [2].

Традиционные скоринговые подходы оказываются недостаточными в условиях высокой нелинейности и динамичности входных данных. Их ограниченная способность адаптироваться к новым паттернам и отсутствие механизма автоматического выявления сложных зависимостей снижает чувствительность таких моделей [3]. В результате банки вынуждены искать методы, способные интегрировать большое количество гетерогенных данных и выявлять скрытые закономерности в поведении заёмщиков.

На практике банковский сектор демонстрирует сочетание классических статистических моделей и алгоритмов машинного обучения. Логистическая регрессия остаётся фундаментальным инструментом для построения моделей вероятности дефолта (PD) благодаря своей стабильности, интерпретируемости и соответствию требованиям надзорных органов. Она служит своеобразной точкой отсчёта, с которой сравнивают новые методы.

Однако по мере усложнения данных именно нелинейные алгоритмы становятся предпочтительными. Деревья решений и ансамбли на их основе позволяют моделировать взаимодействия признаков, которые невозможно описать в линейной форме [3]. Особенно значимым оказался градиентный бустинг, зарекомендовавший себя как один из наиболее результативных инструментов табличного машинного обучения. Его разновидности — «XGBoost», «LightGBM», «CatBoost» — демонстрируют устойчивую точность и способность работать с большими, шумными и несбалансированными выборками [1]. Исследования подтверждают это преимущество. В частности, работы последних лет показывают, что модели градиентного бустинга в задачах кредитного скоринга нередко превосходят нейросетевые архитектуры, которые испытывают сложности в обработке табличных данных без значительной предобработки [9]. Тем не менее нейросети сохраняют ключевую роль в смежных задачах: обнаружении аномалий, анализе транзакционных графов, обработке текстов и моделировании поведенческих паттернов.

Отдельный вектор развития связан с генеративными моделями. Их применяют для расширения обучающих выборок, проведения стресс-тестов, ускорения аналитики, автоматизации интерпретаций и повышения прозрачности сложных решений [5]. Таким образом, современный ландшафт использует гибридную архитектуру: классические методы обеспечивают стабильность и соответствие стандартам, а ML-алгоритмы значительно увеличивают точность и адаптивность по всем элементам (таблица 1).

Таблица 1. Оценка моделей по составляющим элементам

Элемент	Классическая модель	ML-модель
Сложность данных	Низкая	Высокая
Инфраструктура	Минимальная	Требуется MLOps
Интерпретируемость	Отличная	Требуется ХАI
Адаптация к изменениям	Медленная	Быстрая
Чувствительность	Умеренная	Высокая
Обновление	Раз в год/два	Непрерывное

Экономические и финансовые институты уделяют значительное внимание анализу влияния машинного обучения на кредитование. Согласно выводам международных

организаций, таких как МВФ и Всемирный банк, использование ML-моделей позволяет повышать точность прогнозов особенно для заёмщиков с ограниченной кредитной историей. Это способствует финансовой инклюзии, обеспечивая доступ к кредитам тем, кто ранее был «невидим» для традиционных скоринговых систем [6].

Однако исследования подчёркивают и важные ограничения. Алгоритмы подвержены риску наследования исторических смещений в данных, что может привести к систематической дискриминации отдельных групп клиентов. Кроме того, сложность моделей усложняет процессы их валидации, мониторинга и объяснения. Научные работы также указывают на корреляцию между качеством данных и точностью моделей: ML не компенсирует недостатков данных, а наоборот усиливает последствия ошибок.

Регуляторные органы придерживаются взвешенной позиции по отношению к ML-моделям. Европейский центральный банк и Европейское банковское управление подчёркивают необходимость прозрачности, воспроизводимости и строгого контроля исполнения моделей [4]. Их рекомендации включают обязательное применение инструментов интерпретации, жесткие требования к качеству данных, а также расширенную документацию всех этапов разработки и эксплуатации моделей.

Базельский комитет рассматривает внедрение ML как фактор повышения эффективности моделей кредитного риска, но одновременно акцентирует внимание на операционных рисках, возникающих в результате усложнения процессов [8]. Особое значение приобретает мониторинг устойчивости моделей, механизмов обработки дрейфа данных и сценариев стресс-тестирования [4].

Регуляторы не препятствуют развитию ИИ, но выдвигают требования, которые делают внедрение новых методов частью комплексной институциональной трансформации. Банки должны обладать зрелой инфраструктурой, включающей автоматизированные pipelines, системы контроля качества данных, регулярные процедуры мониторинга и независимую валидацию.

Преимущества ML проявляются прежде всего в способности точнее дифференцировать риск, особенно в зонах неопределённости. Модели реагируют на слабые сигналы в данных: изменения транзакционного поведения, микропаттерны расходов, ранние признаки ухудшения финансового состояния. Это позволяет банкам принимать решения более адресно, оптимизировать портфель и снижать ожидаемые потери.

Инструменты объяснимости — SHAP, LIME и их аналоги — стали ключевым фактором успешного внедрения, переводя сложные модели на язык управленческих решений. Однако даже при наличии «explainable AI» сохраняются зоны непрозрачности, которые требуют возрастающей экспертизы со стороны специалистов.

К слабым сторонам ML относят их чувствительность к дрейфу данных, необходимость регулярного переобучения, риски злоупотребления из-за высокой автоматизации и необходимость мощной инфраструктуры [7]. Кроме того, модели могут формировать устойчивые ошибки, если обучены на данных с историческими перекосами [7]. Далее представлено сравнение жизненного цикла двух моделей оценки кредитного риска: классической и ML-модели (рис.1).

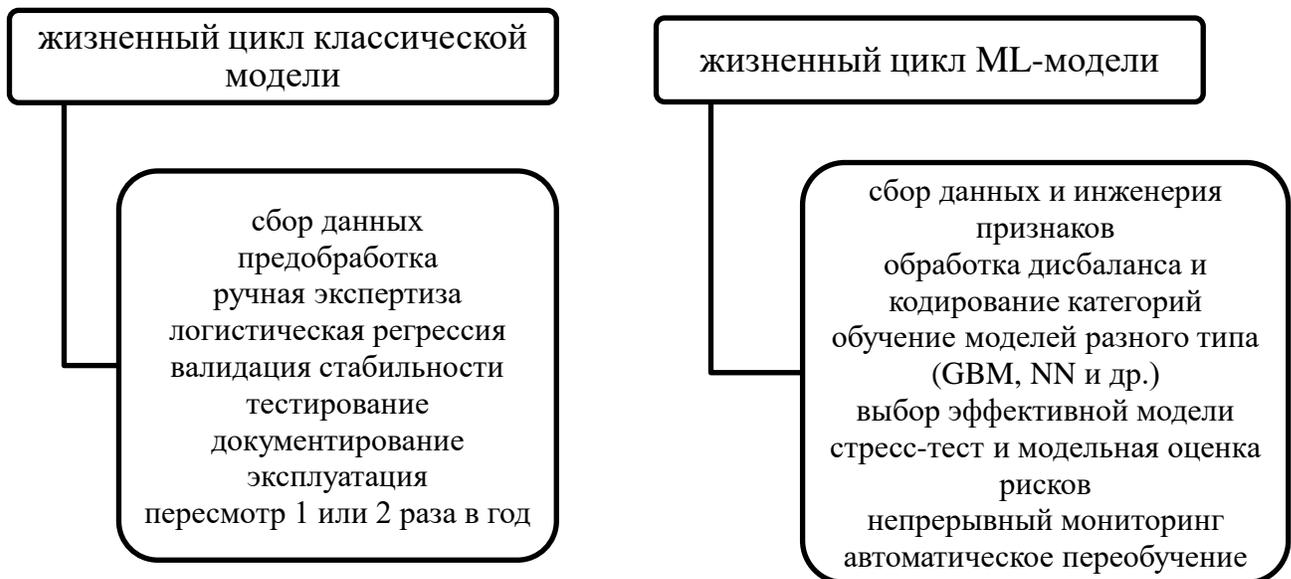


Рис.1 Сравнительная характеристика моделей

Современный анализ эффективности выходит за рамки простой точности прогноза. Банки оценивают влияние модели на ключевые показатели: снижение уровня дефолтов, улучшение распределения PD, оптимизацию капитала, повышение прибыльности сегментов, корректность ценообразования и устойчивость к кризисным сценариям. Значительное внимание уделяется стабильности работы в условиях рыночных и поведенческих изменений, а также способности модели сохранять предсказательную силу при трансформации входных данных.

Заключение. В процессе проведенного исследования нами определено, что важным направлением становится оценка справедливости решений. Банковские системы всё чаще включают процедуры оценки необоснованных различий между группами клиентов, а также механизмы объяснения решений в соответствии с нормами защиты прав потребителей. Модели машинного обучения сформировали новое поколение инструментов управления кредитным риском, позволяя банковскому сектору адаптироваться к усложняющемуся финансовому пространству. Их применение обеспечивает более глубокий анализ клиентского поведения, ускоряет обработку и интерпретацию данных, повышает точность решений и способствует развитию финансовой инклюзии.

Тем не менее, ML не является универсальным решением. Его внедрение требует зрелой IT-инфраструктуры, продуманной архитектуры данных, регулярного мониторинга, механизмов объяснимости и строгого соблюдения регуляторных норм. Банки должны учитывать этические аспекты, контролировать возможные алгоритмические смещения и обеспечивать справедливость принимаемых решений.

Использование ИИ в управлении кредитным риском может стать важным элементом устойчивого развития финансовой системы, если воспринять его не как замену человеческой экспертизе, а как мощный аналитический инструмент. Оптимальный результат достигается тогда, когда технологии и профессиональный опыт функционируют согласованно, формируя сбалансированную и адаптивную модель риск-менеджмента

Список источников

1. Абрамов А. А., Мельникова Т. Е. Применение методов машинного обучения в кредитном скоринге // Финансы и кредит. — 2021. — № 8. — С. 34–47.

2. Евстигнеев Е. Н. Большие данные и их роль в управлении кредитными рисками // Деньги и кредит. — 2020. — № 5. — С. 52–63.
3. Поляков П. В. Современные методы кредитного скоринга: от логистической регрессии к ансамблевым моделям // Банковское дело. — 2022. — № 4. — С. 11–21.
4. Банк России. Методические рекомендации по применению моделей машинного обучения при управлении рисками. — М.: Центральный банк Российской Федерации, 2021. — 48 с.
5. Савин А. Ю. Генеративные модели в банковской аналитике: возможности и ограничения // Прикладная информатика. — 2023. — Т. 18, № 2. — С. 90–103.
6. World Bank. Digital Credit Scoring and Financial Inclusion. — Washington, DC: World Bank Publications, 2020.
7. Гордеев И. Н. Алгоритмическая справедливость и риски дискриминации в кредитном скоринге // Экономическая политика. — 2022. — Т. 17, № 3. — С. 145–162.
8. Basel Committee on Banking Supervision. Principles for the Use of Artificial Intelligence Models in Banking. — Basel: BIS Publications, 2021. — 34 p.
9. Chang V., Abdulkareem K., Althubiti S. Credit Risk Prediction Using Machine Learning // *Electronics*. — 2024. — Vol. 13, No. 2. — P. 1–15.

Сведения об авторах

Мищенко Татьяна Леонидовна, канд. экон. наук, доцент кафедры аудита, финансов и кредита, Московский университет им. А.С. Грибоедова, Москва, Россия

Бельский Артем Евгеньевич, магистрант, Московский университет им. А.С. Грибоедова, Москва, Россия

Шмендель Марк Евгеньевич, магистрант, Московский университет им. А.С. Грибоедова, Москва, Россия

Information about the authors

Mishchenko Tatyana Leonidovna, Candidate of Economic Sciences, Associate Professor of the Department of Audit, Finance, and Credit, Moscow University named after A.S. Griboyedov, Moscow, Russia

Belsky Artem Evgenievich, Master's Student, Moscow University named after A.S. Griboyedov, Moscow, Russia

Shmendel Mark Evgenievich, Master's Student, Moscow University named after A.S. Griboyedov, Moscow, Russia