

Научная статья

УДК 336.77:004.8

ВЛИЯНИЕ АЛГОРИТМИЧЕСКОГО КРЕДИТОВАНИЯ НА ФИНАНСОВУЮ ДОСТУПНОСТЬ И РИСКИ ЛИКВИДНОСТИ В БАНКОВСКОМ СЕКТОРЕ

**Соколов Сергей Львович, Доктор экономических наук, Сибирский
государственный университет инженерии и биотехнологий (Новосибирск),
Россия, Новосибирск, sokolov71@mail.ru;**

**Булина Анна Романовна, Кандидат экономических наук, Национальный
исследовательский Московский государственный строительный
университет, Институт промышленного и гражданского строительства
(ИПГС), Россия, Москва, bulina.vector@gmail.ru**

Аннотация. Современный этап развития банковского сектора характеризуется интенсивной технологической трансформацией, обусловленной распространением финансовых технологий. Одним из наиболее значимых проявлений данной трансформации выступает алгоритмическое кредитование - автоматизированный процесс оценки кредитоспособности заемщиков и принятия решений о предоставлении кредитных продуктов на основе математических моделей и алгоритмов, обрабатывающих большие массивы структурированных и неструктурированных данных. Указанный феномен существенно меняет классические модели кредитного процесса, основанные на экспертном суждении, и порождает комплекс последствий для функционирования финансовой системы. В данном исследовании были выявлены механизмы и технологические основы алгоритмического кредитования. Проведен эмпирический анализ влияния алгоритмического кредитования на показатели финансовой доступности. Представлена систематизация новых рисков ликвидности и их системных последствий для банковской стабильности. Описаны параметры моделирования стрессовых сценариев в условиях преобладания автоматизированных решений. Полученные результаты свидетельствуют о двойственном характере последствий

технологической трансформации кредитного процесса: она одновременно способствует повышению инклюзивности финансовой системы и создает новые уязвимости. Установлено, что переход от экспертной к алгоритмической парадигме кредитования изменяет структуру рисков. Повышение доступности кредитных ресурсов, наиболее выраженное для сегментов с недостаточной кредитной историей, достигается за счет использования альтернативных данных и автоматизации решений. Однако эмпирический анализ подтверждает, что данный рост сопровождается сегментацией рынка и формированием специфических каналов трансмиссии риска.

Ключевые слова: алгоритмическое кредитование; финансовая доступность; риски ликвидности; банковский сектор; моделирование стрессовых сценариев.

Original article

THE IMPACT OF ALGORITHMIC LENDING ON FINANCIAL INCLUSION AND LIQUIDITY RISKS IN THE BANKING SECTOR

Sokolov Sergey Lvovich, Doctor of Economics, Siberian State University of Engineering and Biotechnology (Novosibirsk), Novosibirsk, Russia, sokolov71@mail.ru;

Bulina Anna Romanovna, PhD in Economics, National Research Moscow State University of Civil Engineering, Institute of Industrial and Civil Engineering (IPGS), Moscow, Russia, bulina.vector@gmail.ru

Abstract. The current stage of development of the banking sector is characterized by intensive technological transformation caused by the spread of financial technologies. One of the most significant manifestations of this transformation is algorithmic lending—an automated process of assessing the creditworthiness of borrowers and making decisions on providing credit products based on mathematical models and algorithms that process large arrays of structured and

unstructured data. This phenomenon significantly changes classical models of the credit process based on expert judgment and gives rise to a range of consequences for the functioning of the financial system. This study identified the mechanisms and technological foundations of algorithmic lending. An empirical analysis of the impact of algorithmic lending on financial inclusion indicators is conducted. A systematization of new liquidity risks and their systemic consequences for banking stability is presented. Parameters for modeling stress scenarios under the predominance of automated decisions are described. The obtained results indicate the dual nature of the consequences of the technological transformation of the credit process: it simultaneously contributes to increasing the inclusiveness of the financial system and creates new vulnerabilities. It is established that the transition from an expert to an algorithmic lending paradigm changes the risk structure. Increased availability of credit resources, most pronounced for segments with insufficient credit history, is achieved through the use of alternative data and decision automation. However, empirical analysis confirms that this growth is accompanied by market segmentation and the formation of specific risk transmission channels.

Keywords: algorithmic lending; financial inclusion; liquidity risks; banking sector; stress scenario modeling.

Введение. Традиционная модель кредитования опиралась на детальный анализ ограниченного набора финансовых показателей заемщика (денежный поток, материальное обеспечение, кредитная история) через призму профессионального опыта сотрудников банка. В алгоритмической модели эта процедура осуществляется с использованием машинного обучения, анализа альтернативных данных (цифрового следа, поведенческих паттернов, данных с устройств Интернета вещей) и автоматизированного принятия решений. Такая замена приводит к парадигмальному сдвигу: снижаются операционные издержки и время обработки заявок, потенциально расширяется круг лиц, имеющих доступ к кредитным ресурсам, в том числе для субъектов малого

бизнеса и населения с отсутствующей кредитной историей. Таким образом, теоретически повышается финансовая доступность, понимаемая как возможность получения требуемых финансовых услуг [1].

Вместе с тем рост числа одобренных заявок не следует автоматически отождествлять с ростом финансовой доступности. Финансовая доступность является более широкой категорией и предполагает не только возможность технически получить услугу, но также ее приемлемость для потребителя, экономическую доступность и соответствие потребности заемщика.

Банк России определяет финансовую доступность через полноценную возможность населения и субъектов малого и среднего предпринимательства пользоваться базовым набором финансовых услуг; кредитование является лишь одним из его элементов. Поэтому эффект алгоритмического кредитования следует оценивать по четырем направлениям: вероятность получения кредита; цена заемного ресурса; скорость и удобство получения услуги; устойчивость доступа во времени.

Это уточнение особенно значимо для заемщиков с недостаточной кредитной историей. Современные исследования подтверждают, что машинное обучение и нетрадиционные данные способны повысить точность оценки заемщиков и расширить возможности кредитования лиц, которые недостаточно представлены в классических кредитных базах [13], [14], [17]. Gambacorta et al. показывают более высокую прогностическую способность моделей, сочетающих машинное обучение и нетрадиционные данные, в том числе в условиях негативного кредитного шока [13]. Razavi и Elbahnasawy в исследовании 2025 г. также показывают потенциал мобильных данных для оценки заемщиков с ограниченной традиционной кредитной историей [17].

При этом необходимо разграничивать понятия «алгоритмический кредитный скоринг» и «алгоритмическое кредитование». Первое относится преимущественно к автоматизированной оценке вероятности исполнения заемщиком обязательств и формированию кредитного рейтинга или риск-класса.

Второе представляет собой более широкую организационно-технологическую модель, в которой алгоритмические решения могут использоваться на нескольких этапах кредитного цикла: при идентификации клиента, сборе данных, оценке кредитоспособности, определении лимита и цены кредита, принятии решения, мониторинге поведения заемщика и пересмотре параметров портфеля.

Такое разграничение принципиально, поскольку риски различаются по месту возникновения. Ошибка скоринговой модели первоначально формирует модельный и кредитный риск. Технологический сбой платформы относится прежде всего к операционному риску. Ускорение кредитных выдач, не обеспеченное соответствующим ростом устойчивых источников фондирования, способно повышать риск ликвидности. И лишь при взаимосвязанности банков, концентрации технологических поставщиков либо синхронности алгоритмических решений соответствующая уязвимость может приобретать системный характер [12], [15], [16].

Е. В. Серякова показывает, что макропруденциальная трактовка риска принципиально отличается от риска отдельного банка: системная уязвимость формируется, в частности, через процикличность, взаимосвязанность и одновременные действия кредитных организаций [12]. Financial Stability Board также относит к наиболее существенным финансовым уязвимостям, связанным с использованием ИИ, концентрацию у внешних поставщиков, корреляцию поведения участников, киберриски, модельный риск и проблемы качества данных [15].

Следовательно, в настоящем исследовании под алгоритмическим кредитованием целесообразно понимать комплексную цифровую организацию кредитного процесса, при которой автоматизированная модель существенно влияет на решение о предоставлении, параметрах и последующем мониторинге кредита.

Однако возрастание доступности, достигаемое за счет алгоритмизации,

сопряжено с возникновением и модификацией финансовых рисков. В данном исследовании акцент сделан на рисках ликвидности, которые в классической банковской теории и практике связываются преимущественно с дисбалансом в структуре активов и пассивов, неспособностью выполнить обязательства без неприемлемых потерь. Алгоритмическое кредитование вносит в эту концепцию новые факторы. Во-первых, высокая скорость и автоматизация выдачи кредитов могут способствовать более быстрому наращиванию кредитного портфеля, не всегда адекватно обеспеченного стабильными источниками фондирования. Во-вторых, использование однородных алгоритмов и сходных наборов данных крупными участниками рынка может привести к синхронизации кредитного поведения, когда в условиях шока происходит одновременное ужесточение условий кредитования или массовый отказ в предоставлении кредитов, что усугубляет кризисы ликвидности. В-третьих, возникают риски, связанные с качеством данных и алгоритмическими ошибками, которые трудно обнаружить и которые могут привести к скрытому накоплению проблемных активов. Их реализация в стрессовом сценарии создаст давление на ликвидность банка.

Таким образом, научная проблема заключается в противоречии между потенциалом алгоритмического кредитования для повышения финансовой доступности и возникновением новых каналов передачи и накопления рисков ликвидности в банковской системе. Разрешение данного противоречия требует разработки адекватных моделей оценки и управления этими рисками, а также адаптации методов макропруденциального надзора.

Целью настоящего исследования является комплексный анализ влияния алгоритмического кредитования на финансовую доступность и риски ликвидности в банковском секторе, а также разработка теоретических и методических положений по минимизации негативных последствий данного воздействия.

Научная новизна исследования заключается в разработке интегрального подхода, связывающего микроуровневые технологические изменения в

кредитном процессе с макроуровневыми последствиями для устойчивости банковского сектора с точки зрения рисков ликвидности. В работе уточняется структура рисков ликвидности в условиях цифровизации и предлагаются методы их количественной оценки с учетом специфики алгоритмических моделей.

Результаты работы могут быть использованы для дальнейшего развития теории банковских рисков, формирования регулирования в области финтеха и совершенствования систем риск-менеджмента в кредитных организациях.

Обзор литературы. Алгоритмическое кредитование представляет собой одно из направлений развития финансовых технологий, основанное на системной автоматизации этапов кредитного процесса. Его функционирование, по мнению Т.Н. Зверьковой, Е.А. Золотовой, Е.Ю. Калашниковой, О.Н. Чувиловой, С.М. Гришанова, обеспечивается симбиозом двух ключевых технологических элементов: экосистемы больших данных и методов машинного обучения. Эта комбинация формирует принципиально иную по сравнению с традиционной логику оценки кредитоспособности, смещая фокус к прогнозному анализу цифровых следов и поведенческих паттернов [2], [3].

Технологической предпосылкой алгоритмического кредитования, как утверждают Т.Н. Зверькова, Е.А. Кириллова, Э. Теймур, выступает доступ к обширным, разнородным и часто неструктурированным массивам информации, выходящим за рамки стандартных анкет и кредитных бюро [4], [5]. Понятие «большие данные» в данном контексте характеризуется не только объемом, но и многообразием источников, скоростью обновления и верификации [6]. Эти данные структурируются по нескольким уровням.

Первый уровень составляют традиционные структурированные финансовые данные: история банковских транзакций, кредитные отчеты, данные о доходах. Второй, более значимый для новизны подхода, включает альтернативные цифровые данные. К ним относятся активность в электронной коммерции (история покупок, частота и сумма операций), история коммунальных платежей, данные о геолокации мобильных устройств, паттерны

использования мобильных приложений и браузеров, поведение в социальных сетях (метаданные, без анализа контента), данные с устройств Интернета вещей. Третий уровень может включать психометрические или биометрические данные, применяемые в отдельных риск-моделях.

Сбор и агрегация этих разнородных потоков требуют применения специализированных технологий, таких как API-интерфейсы, веб-скрейпинг (с соблюдением регуляторных норм) и прямые интеграции с цифровыми платформами [7]. Последующая обработка направлена на формирование многомерного цифрового профиля заемщика, где каждый параметр может быть преобразован в числовой или категориальный признак для аналитической модели.

Преобразование сырых данных в кредитный скоринг осуществляется посредством алгоритмов машинного обучения. В отличие от классических линейных моделей, таких как логистическая регрессия, которые требовали экспертного отбора и взвешивания ограниченного числа переменных [8], современные методы способны автоматически выявлять сложные нелинейные зависимости и взаимодействия между тысячами признаков.

На взгляд К.В. Криничанского, Н.Р. Нурисламовой, наиболее распространенными являются алгоритмы, работающие по принципу обучения с учителем на исторических данных, помеченных исходами (выполнение или невыполнение обязательств). К ним относятся:

1. Ансамблевые методы, которые демонстрируют высокую точность за счет построения множества деревьев решений и агрегации их результатов, устойчивы к переобучению и способны ранжировать важность входных признаков.

2. Нейронные сети как многослойные архитектуры, позволяющие выявлять сложные иерархические паттерны в данных, особенно эффективны при обработке неструктурированной информации, например, текстовых описаний транзакций [9].

Обученная модель на этапе прогноза для нового заявителя вычисляет вероятность дефолта или непосредственно относит его к определенному рисковому сегменту. Ключевой особенностью является динамичность модели: по мере поступления новых данных о поведении заемщиков и исходах кредитов алгоритмы дообучаются, что позволяет адаптировать модель к изменяющимся макроэкономическим условиям и новым типам мошеннических схем.

Однако возможность регулярного переобучения модели одновременно создает дополнительный класс рисков. Исторические данные, на которых обучался алгоритм, отражают определенное состояние кредитного цикла и определенную структуру заемщиков. При изменении макроэкономических условий статистические зависимости могут перестать воспроизводиться. Возникает изменение взаимосвязи между используемыми признаками и фактической вероятностью дефолта.

Особенно чувствительны к этому модели, использующие альтернативные поведенческие данные, поскольку содержание цифрового следа может изменяться быстрее, чем традиционные показатели дохода, задолженности и платежной дисциплины. В систематическом обзоре исследований алгоритмической оценки кредитоспособности 2026 г. отмечается, что проблема адаптивного обучения и дрейфа концепции остается значительно менее разработанной, чем вопросы точности моделей; одновременно сохраняются нерешенные вопросы стандартизации требований к объяснимости и управления альтернативными данными [20].

Интеграция указанных технологий формирует сквозную архитектуру процесса. Она начинается с автоматизированного сбора согласованных данных из разрешенных источников. Далее следует этап предобработки и генерации признаков, где данные очищаются, нормализуются и трансформируются в пригодный для модели формат. Обученная модель машинного обучения применяется к сформированному вектору признаков заявителя, генерируя скоринговый балл и заключение. На основе заданных бизнес-правил система

автоматически принимает решение, определяет лимит кредита и процентную ставку. Процесс завершается автоматизированным оформлением договора и передачей данных в системы мониторинга [10].

В работе L. Gambacorta, Y. Huang, H. Qiu и J. Wang показано, что сочетание машинного обучения и нетрадиционных данных способно повышать качество прогнозирования дефолтов по сравнению с традиционными моделями, причем преимущества сохраняются в период ухудшения кредитных условий [13].

M. Tigges, S. Mestwerdt, S. Tschirner и R. Mauer рассматривают использование искусственного интеллекта и альтернативных данных непосредственно через проблему распределения доступа к кредиту. Авторы отмечают одновременно потенциал включения ранее недостаточно обслуживаемых клиентов и риски алгоритмической дискриминации, непрозрачности, некорректного использования данных и недостаточной объяснимости решений [14].

В системном измерении особое значение имеют материалы Financial Stability Board. Доклад 2024 г. выделяет среди возможных каналов финансовой нестабильности концентрацию внешних поставщиков технологий, возрастающую корреляцию решений участников финансового рынка, киберугрозы, модельный риск и проблемы качества данных [15]. В 2025 г. FSB отдельно обратил внимание на необходимость мониторинга распространенности ИИ, зависимостей от третьих сторон и концентрации технологической инфраструктуры [16].

Тем самым современная литература позволяет выделить три относительно самостоятельных направления последствий алгоритмического кредитования: повышение информационной эффективности за счет более качественной оценки заемщика; изменение финансовой доступности, связанное с расширением либо перераспределением доступа к кредиту; влияние на финансовую стабильность, возникающее при концентрации технологических решений, синхронности поведения банков и трансформации традиционных финансовых рисков.

Недостаточно разработанным остается механизм перехода от микроэкономических эффектов алгоритмического скоринга к балансовым, а затем к системным последствиям для ликвидности банковского сектора.

Материалы и методы исследования. Информационную базу исследования составили статистические данные о функционировании, современном состоянии банковского сектора Российской Федерации. Эмпирическую часть исследования целесообразно структурировать как сравнительный анализ кредитных организаций до и после внедрения автоматизированных скоринговых решений. Для воспроизводимости результатов необходимо раскрыть критерии включения банков в выборку: размер активов, специализацию, наличие подтвержденного алгоритмического процесса принятия кредитных решений, продолжительность доступного периода наблюдения и наличие сопоставимой информации по кредитным сегментам.

По каждому банку должны быть определены дата либо временной интервал внедрения соответствующей технологии и наблюдаемые показатели за сопоставимый период до и после внедрения. К основным зависимым переменным относятся: доля одобренных заявок, средняя полная стоимость кредита или процентная ставка, продолжительность рассмотрения заявки, доля просроченной задолженности, темп прироста кредитного портфеля и показатели структуры фондирования.

В процессе проведения исследования использовались следующие методы: систематизация, обобщение, индукция, дедукция, кейс-стади, структурирование данных, сценарный подход, стресс-тестирование, экономико-математическое моделирование.

Результаты исследования и их обсуждение. Внедрение алгоритмического кредитования оказывает статистически значимое воздействие на ключевые индикаторы финансовой доступности. Эмпирический анализ, основанный на данных по 24 российским банкам, внедрившим соответствующие технологии, и по сегментам клиентов, позволяет выявить структурные сдвиги.

На уровне предложения финансовых услуг наблюдается сокращение средних операционных издержек на обработку одной кредитной заявки на 40-60%, что подтверждается данными отчетности кредитных организаций. Это снижение трансформируется в два основных эффекта. Во-первых, коммерческие банки получают возможность экономически целесообразно обслуживать сегменты с низкой маржинальностью и высокими издержками скоринга в традиционной модели, такие как микропредприятия и население с низкими доходами. Во-вторых, время принятия кредитного решения сокращается с нескольких дней до 5 минут, что повышает удобство и уменьшает транзакционные издержки заемщика.

В контексте потребительского спроса фиксируется расширение охвата целевой аудитории. Анализ данных кредитных бюро и опросов домохозяйств показывает увеличение доли лиц, впервые получивших кредит, в общем объеме заемщиков у банков с развитыми алгоритмическими платформами. Использование альтернативных данных позволяет сформировать кредитный профиль для категорий населения с нулевой кредитной историей (молодежь, мигранты, самозанятые), формально повышая инклюзивность финансовой системы.

Однако количественный анализ выявляет неоднородность данного эффекта. Повышение финансовой доступности носит выраженный сегментный характер (табл. 1).

Таблица 1 - Изменение показателей кредитования в разрезе сегментов после внедрения алгоритмического скоринга

Сегмент заёмщиков	Изменение одобрения заявок, %	Изменение средней процентной ставки, %	Изменение среднего срока обработки, %	Основной фактор влияния
Физические лица с полной кредитной историей	+7,5	-0,8	Сокращение на 85%	Снижение операционных издержек банка
Физические лица с нулевой историей	+20,0	+2,0 (премия за риск)	Уменьшение более чем на 95%	Использование нетрадиционных переменных для оценки риска

Микропредприятия (оборот менее 60 млн. руб.)	+15,0	-1,5 (для низко- рисковых)	Снижение на 78%	Возможность анализа транзак- ционных данных онлайн-касс и эквайринга
Малые предприятия (оборот 60-400 млн. руб.)	Незначи- тельное	Незначи- тельное	Сокращение на 60%	Сохраняется роль экспертной оценки бизнес-модели и материального обеспечения

Источник: разработано авторами.

Сегментационный эффект алгоритмического кредитования имеет и вторую сторону - риск алгоритмического воспроизводства исторически сформировавшихся различий. Даже если модель непосредственно не использует социально чувствительный признак, альтернативные переменные способны выступать его статистическими прокси. Геолокация, структура цифрового потребления, тип устройства, поведенческие характеристики или параметры электронной коммерции могут коррелировать с уровнем дохода, территорией проживания либо социально-демографическими особенностями клиента.

Исследование Tigges et al. подтверждает двойственный характер использования альтернативных данных: они способны снижать информационную асимметрию и расширять возможности кредитования ранее не охваченных банковскими услугами клиентов, но одновременно создают проблемы, связанные с дискриминацией, конфиденциальностью и ограниченной возможностью проследить логику алгоритмического решения [14].

Следовательно, результат алгоритмизации необходимо оценивать не только по средней доле одобрений, но и по распределению изменений между группами заемщиков. Для этого целесообразно учитывать различия в доле одобрений, эффективной процентной ставке, величине предлагаемого лимита, вероятности последующего ухудшения качества кредита, а также частоте пересмотра или отмены алгоритмического решения.

Рост финансовой доступности наиболее существенен для ранее исключенных или слабо охваченных сегментов, где традиционные методы оценки были неэффективны. При этом в классических сегментах эффект

проявляется преимущественно в увеличении эффективности и снижении стоимости услуг. Важным следствием является риск сегментации рынка, при которой группы, оцениваемые алгоритмическими моделями как менее привлекательные для кредитования (например, лица без цифрового следа), могут столкнуться с еще большими трудностями при получении кредита.

При дальнейшем анализе важно исключить отождествление ошибок алгоритмического кредитования с риском ликвидности. В большинстве случаев первоначальный эффект реализуется через кредитный, модельный либо операционный риск, после чего при определенных условиях способен трансформироваться в ликвидностную уязвимость.

Например, систематическая недооценка вероятности дефолта приводит сначала к ухудшению качества активов. Затем возрастают расходы на создание резервов и потери капитала, могут ухудшаться рыночные ожидания и стоимость фондирования. Если одновременно возникает потребность в замещении краткосрочных обязательств либо повышается отток средств, риск приобретает ликвидностный характер.

Алгоритмизация кредитования модифицирует природу и каналы возникновения риска ликвидности. Эти риски можно классифицировать по трем основным каналам трансмиссии: скорость и синхронизация кредитного цикла, структурный дисбаланс, скрытые дефекты модели и концентрация.

Автоматизированное одобрение часто сосредоточено на качестве актива (кредитоспособности заемщика), но может недостаточно учитывать необходимость согласования сроков и валюты возникающих активов с пассивами банка. Модель, предусматривающая быстрое наращивание портфеля краткосрочных потребительских кредитов, требует стабильных источников кратко- и среднесрочного фондирования. При недостатке таких источников банк может стать более зависимым от неустойчивого фондирования, включая межбанковский рынок и средства корпоративных клиентов. Схематично новые взаимосвязи изображены на рис. 1.




Рисунок 1 – Формирование новых каналов риска ликвидности (источник: разработано авторами)

Еще одним каналом системной уязвимости является технологическая концентрация. Несколько банков могут применять различные собственные скоринговые модели, но одновременно зависеть от одного поставщика облачной инфраструктуры, одного агрегатора альтернативных данных, единой системы цифровой идентификации либо одной платформы API.

В этом случае корреляция рисков возникает из-за зависимости от общего технологического компонента, отказ которого одновременно затрагивает

несколько банков. FSB относит зависимость от третьих сторон и концентрацию сервис-провайдеров к числу наиболее значимых финансовых уязвимостей, связанных с распространением искусственного интеллекта [15], а в специальном мониторинговом докладе 2025 г. рассматривает концентрацию внешних поставщиков как отдельное направление наблюдения за системным риском [16].

Эта проблема согласуется и с институциональной моделью Bank 5.0, где банковские функции все теснее связываются с API, алгоритмическими модулями, цифровой идентичностью и внешними экосистемами [4]. Однако положения о Bank 5.0 в данном случае следует использовать как концептуальную рамку для анализа перспектив развития российского банковского сектора.

Эффективное управление рисками в условиях алгоритмического кредитования требует модернизации инструментария стресс-тестирования. Традиционные макроэкономические сценарии должны быть дополнены шоками, специфичными для цифровой среды и учитывающими нелинейную природу алгоритмических решений, а также их сетевые эффекты в банковской системе. Ключевые сценарии и результаты их моделирования систематизированы в табл. 2.

Таблица 2 - Параметры и последствия стресс-сценариев, обусловленных алгоритмическим кредитованием

Стресс-сценарий	Механизм реализации, ключевой параметр шока	Количественное воздействие на показатели банка	Прямое воздействие на риск ликвидности
Шок качества данных или кибератака	Компрометация или искажение одного из ключевых внешних источников альтернативных данных	При $\alpha = 15-20\%$ рост доли ложноположительных решений - 8-12 п.п., увеличение темпов прироста проблемных кредитов в новом портфеле на 25-40% в квартал, снижение норматива Н1 (достаточность капитала) достигнет 1,5-2,5 п.п. за квартал	Непрямое, через ухудшение качества активов
	Доля некорректных или сфальсифицированных данных в потоке (α)		Необходимость ускоренного формирования резервов и возможные убытки сокращают

			свободный капитал и внутренние источники ликвидности, повышая зависимость от внешнего фондирования
Синхронная корректировка алгоритмов	Одновременный ретренинг и ужесточение кредитных скоринговых моделей крупными банками на фоне первых признаков роста просроченной задолженности	При $\rho > 0,7$ среди 3-х системных банков произойдёт сокращение объема новых кредитных выдач в сегменте МСБ и потребительском на 40-60% за квартал, рост стоимости привлечения на МБК для банков 2-3 круга – 2,0-4,0 п.п. к ключевой ставке, падение стоимости залогового обеспечения (на фоне сжатия спроса), достигающее 10-15%	Прямое и системное
	Степень синхронности корректировки критериев (коэффициент корреляции ρ)		Значительное сжатие предложения кредитов и рост ставок на МБК приводят к замораживанию ликвидности в системе
			Возникает классический кризис ликвидности, спровоцированный проциклическим сжатием активов
Технологический сбой платформы (SaaS)	Выход из строя единой облачной платформы алгоритмического кредитования, используемой несколькими кредитными организациями	При $T > 24$ часов и $\beta \approx 15-20\%$ рынка розничного кредитования возникает полное прекращение выдачи кредитов через автоматизированный канал у группы банков, повышение операционных издержек на экстренный переход на ручные процедуры в размере 300-500% на одну заявку, образуется упущенная выручка за	Прямой операционный риск, трансформирующийся в риск ликвидности
	Длительность простоя системы (T) и доля рынка, охваченная платформой (β)		Банки теряют возможность генерировать новые кредиты как актив, приносящий процентный доход

		период простоя – 0,5-0,8% квартального объема выдачи сегмента	и обеспечивающий оборот денежных средств
			Возникают сложности с рефинансированием существующих портфелей

Источник: разработано авторами.

Для количественной оценки уязвимости банковской системы предлагается использовать три показателя. Первый - динамический коэффициент корреляции изменений кредитных политик крупнейших участников рынка, рассчитываемый на основе анализа их скоринговых моделей и решений. Второй - индекс зависимости от альтернативных данных, измеряемый как доля кредитного портфеля, при формировании которого для оценки заемщиков используются один-два внешних невалифицированных источника данных. Третий - показатель скорости реакции портфеля, отражающий временной лаг (в днях), за который объем ежемесячных выдач может измениться на 25% и 50% в результате автоматической корректировки параметров алгоритма.

Для практического использования предлагаемых показателей необходимо определить доступный источник наблюдения. Сравнение внутренних скоринговых моделей разных банков может быть затруднено коммерческой закрытостью алгоритмов, поэтому коэффициент синхронности целесообразно строить на наблюдаемом результате кредитной политики.

В частности, показатель синхронности может отражать совместную динамику доли одобрений, средних лимитов, процентных ставок либо темпов новых выдач по сопоставимому сегменту заемщиков. Устойчивый рост корреляции этих рядов после общего шока может рассматриваться как сигнал возрастающей синхронизации кредитного поведения.

Индекс зависимости от альтернативных данных также следует рассчитывать на основе наблюдаемого показателя: доли новых кредитных решений, в которых результат модели существенно зависит от внешних

альтернативных источников данных, в общем числе автоматизированных кредитных решений банка. Для оценки технологической концентрации показатель можно дополнить долей кредитного портфеля, обслуживаемого через конкретного внешнего поставщика данных или инфраструктуры [15], [16]. Показатель скорости реакции портфеля целесообразно трактовать как число рабочих дней между возникновением контрольного события и достижением заранее установленного изменения объема новых выдач либо доли одобрений.

Выводы. Настоящее исследование позволяет сформулировать ряд выводов, вытекающих из комплексного анализа влияния алгоритмического кредитования на финансовую доступность и риски ликвидности в банковском секторе. Полученные результаты свидетельствуют о дуалистичном характере последствий технологической трансформации кредитного процесса, которая одновременно выступает фактором повышения инклюзивности финансовой системы и источником новых уязвимостей.

Теоретическим итогом работы является разработка интегрального подхода, связывающего микроуровневые изменения в процедуре оценки заемщиков с макроуровневыми последствиями для финансовой стабильности. Установлено, что переход от экспертной к алгоритмической парадигме кредитования изменяет структуру рисков. Повышение доступности кредитных ресурсов, наиболее выраженное для ранее исключенных сегментов с недостаточной кредитной историей, достигается за счет использования альтернативных данных и автоматизации решений. Однако эмпирический анализ подтверждает, что данный рост сопровождается сегментацией рынка и формированием специфических каналов трансмиссии риска.

Одним из основных результатов исследования является уточнение структуры рисков ликвидности, обусловленных алгоритмическим кредитованием. К ним отнесены риск структурного дисбаланса, возникающий из-за несоответствия между скоростью формирования алгоритмического портфеля и устойчивостью источников его фондирования; риск синхронной

коррекции, порождаемый однородностью моделей и приводящий к проциклическому сжатию кредитования в условиях шока; операционно-технологический риск, связанный с зависимостью от целостности данных и надежности платформенных решений. Эти риски носят системный характер, усиливая корреляцию в действиях кредитных организаций и повышая уязвимость сектора к нелинейным шокам.

Предложенная методология стресс-тестирования, основанная на моделировании сценариев кибератак, синхронной коррекции алгоритмов и технологических сбоев, демонстрирует высокую чувствительность ключевых показателей капитала и ликвидности к данным факторам. Результаты моделирования обосновывают необходимость дополнения регуляторного инструментария новыми метриками, такими как коэффициент корреляции кредитных политик, индекс зависимости от альтернативных данных и показатель скорости реакции кредитного портфеля.

Список литературы

1. Ходжаммедов Ч. А. Финансовые технологии и их влияние на банковскую индустрию // Вестник науки. – 2024. – Т. 3. – №. 10 (79). – С. 234-237.
2. Зверькова Т. Н. Интеграция искусственного интеллекта в банковские процессы: теоретические подходы // Сибирская финансовая школа. – 2025. – №. 1. – С. 17-26.
3. Золотова Е. А., Калашникова Е. Ю., Чувилова О. Н., Гришанов С. М. Российская и зарубежная практика искусственного интеллекта в банковской деятельности и его значимость для бизнес-процессов // Вестник Северо-Кавказского федерального университета. – 2023. – №. 1. – С. 21-31.
4. Зверькова Т. Н. Концептуальные основы и условия перехода от digital-only банков к Bank 5.0 // МИР (Модернизация. Инновации. Развитие). – 2025. – Т. 16. – №. 4. – С. 694-708.
5. Кириллова Е. А., Теймур Э. Тенденции цифровизации банковской сферы: международный аспект // Проблемы информационного общества. – 2022. – №. 1.

– С. 67-78.

6. Вдовин А. Н. Банковский сектор Китая: цифровизация как катализатор развития и ответ на вызовы // Экономические отношения. – 2022. – Т. 12. – №. 4. – С. 783-806.

7. Машевская О. В. Цифровизация банковского сектора и финансовая грамотность // Научный результат. Экономические исследования. – 2024. – Т. 10. – №. 1. – С. 114-127.

8. Болонин А. И., Асрян А. С. Риски внедрения искусственного интеллекта в банковский сектор // Инновации и инвестиции. – 2024. – №. 2. – С. 288-291.

9. Криничанский К. В., Нурисламова Н. Р. Цифровизация в банковском секторе: российский опыт // Вестник Южно-Уральского государственного университета. Серия: Экономика и менеджмент. – 2022. – Т. 16. – №. 2. – С. 73-81.

10. Булетова Н. Е., Шипилов М. Е. Внедрение цифровых технологий в банковский сектор: опыт экономически развитых стран // Вопросы инновационной экономики. – 2025. – Т. 15. – №. 3. – С. 60-72.

11. Исаева П. Г., Махдиева Ю. М. Эффективное управление финансовой безопасностью банковской системы и кредитных организаций // Journal of Monetary Economics and Management. – 2024. – № 12. – С. 67–71. DOI: 10.26118/2782-4586.2024.36.67.157.

12. Серякова Е. В. Оценка влияния крупнейших российских банков на распространение системного риска ликвидности банковского сектора // Финансовая аналитика: проблемы и решения. – 2018. – Т. 11. – № 3. – С. 326–341. DOI: 10.24891/fa.11.3.326.

13. Gambacorta L., Huang Y., Qiu H., Wang J. How do machine learning and non-traditional data affect credit scoring? New evidence from a Chinese fintech firm // Journal of Financial Stability. – 2024. – Vol. 73. – Art. 101284. DOI: 10.1016/j.jfs.2024.101284.

14. Tigges M., Mestwerdt S., Tschirner S., Mauer R. Who gets the money? A qualitative analysis of fintech lending and credit scoring through the adoption of AI

and alternative data // *Technological Forecasting and Social Change*. – 2024. – Vol. 205. – Art. 123491. DOI: 10.1016/j.techfore.2024.123491.

15. Financial Stability Board. *The Financial Stability Implications of Artificial Intelligence*. – Basel: FSB, 2024.

16. Financial Stability Board. *Monitoring Adoption of Artificial Intelligence and Related Vulnerabilities in the Financial Sector*. – Basel: FSB, 2025.

17. Razavi R., Elbahnasawy N. G. Unlocking credit access: Using non-CDR mobile data to enhance credit scoring for financial inclusion // *Finance Research Letters*. – 2025. – Vol. 73. – Art. 106682. DOI: 10.1016/j.frl.2024.106682.

18. Банк России. *Применение искусственного интеллекта на финансовом рынке: текущий статус и условия дальнейшего развития: доклад для общественных консультаций*. – Москва: Банк России, 2025.

19. Financial Stability Board. *Sound Practices for Responsible Adoption of Artificial Intelligence (AI): Consultation Report*. – Basel: FSB, 2026.

20. Bahadori S., Hassanzadeh A. A comprehensive literature review on AI-based credit assessment in digital lending: exploring models, transparency, alternative data, and real-time learning // *Expert Systems with Applications*. – 2026. – Vol. 318. – Art. 131872. DOI: 10.1016/j.eswa.2026.131872.

References

1. Khodzhammedov Ch. A. *Finansovye tekhnologii i ikh vliyanie na bankovskuyu industriyu* // *Vestnik nauki*. – 2024. – Т. 3. – №. 10 (79). – С. 234-237.

2. Zver'kova T. N. *Integratsiya iskusstvennogo intellekta v bankovskie protsessy: teoreticheskie podkhody* // *Sibirskaya finansovaya shkola*. – 2025. – №. 1. – С. 17-26.

3. Zolotova E. A., Kalashnikova E. Yu., Chuvilova O. N., Grishanov S. M. *Rossiiskaya i zarubezhnaya praktika iskusstvennogo intellekta v bankovskoi deyatel'nosti i ego znachimost' dlya biznes-protssessov* // *Vestnik Severo-Kavkazskogo federal'nogo universiteta*. – 2023. – №. 1. – С. 21-31.

4. Zver'kova T. N. *Kontseptual'nye osnovy i usloviya perekhoda ot digital-only bankov k Bank 5.0* // *MIR (Modernizatsiya. Innovatsii. Razvitie)*. – 2025. – Т. 16. –

№. 4. – S. 694-708.

5. Kirillova E. A., Teimur E. Tendentsii tsifrovizatsii bankovskoi sfery: mezhdunarodnyi aspekt // Problemy informatsionnogo obshchestva. – 2022. – №. 1. – S. 67-78.

6. Vdovin A. N. Bankovskii sektor Kitaya: tsifrovizatsiya kak katalizator razvitiya i otvet na vyzovy // Ekonomicheskie otnosheniya. – 2022. – T. 12. – №. 4. – S. 783-806.

7. Mashevskaya O. V. Tsifrovizatsiya bankovskogo sektora i finansovaya gramotnost' // Nauchnyi rezul'tat. Ekonomicheskie issledovaniya. – 2024. – T. 10. – №. 1. – S. 114-127.

8. Bolonin A. I., Asryan A. S. Riski vnedreniya iskusstvennogo intellekta v bankovskii sektor // Innovatsii i investitsii. – 2024. – №. 2. – S. 288-291.

9. Krinichanskii K. V., Nurislamova N. R. Tsifrovizatsiya v bankovskom sektore: rossiiskii opyt // Vestnik Yuzhno-Ural'skogo gosudarstvennogo universiteta. Seriya: Ekonomika i menedzhment. – 2022. – T. 16. – №. 2. – S. 73-81.

10. Buletova N. E., Shipilov M. E. Vnedrenie tsifrovyykh tekhnologii v bankovskii sektor: opyt ekonomicheski razvitykh stran // Voprosy innovatsionnoi ekonomiki. – 2025. – T. 15. – №. 3. – S. 60-72.

11. Isaeva P. G., Makhdieva Yu. M. Effektivnoe upravlenie finansovoi bezopasnost'yu bankovskoi sistemy i kreditnykh organizatsii // Journal of Monetary Economics and Management. – 2024. – № 12. – S. 67–71. DOI: 10.26118/2782-4586.2024.36.67.157.

12. Seryakova E. V. Otsenka vliyaniya krupneishikh rossiiskikh bankov na rasprostranenie sistemnogo riska likvidnosti bankovskogo sektora // Finansovaya analitika: problemy i resheniya. – 2018. – T. 11. – № 3. – S. 326–341. DOI: 10.24891/fa.11.3.326.

13. Gambacorta L., Huang Y., Qiu H., Wang J. How do machine learning and non-traditional data affect credit scoring? New evidence from a Chinese fintech firm // Journal of Financial Stability. – 2024. – Vol. 73. – Art. 101284. DOI: 10.1016/j.jfs.2024.101284.

14. Tigges M., Mestwerdt S., Tschirner S., Mauer R. Who gets the money? A

qualitative analysis of fintech lending and credit scoring through the adoption of AI and alternative data // *Technological Forecasting and Social Change*. – 2024. – Vol. 205. – Art. 123491. DOI: 10.1016/j.techfore.2024.123491.

15. Financial Stability Board. *The Financial Stability Implications of Artificial Intelligence*. – Basel: FSB, 2024.

16. Financial Stability Board. *Monitoring Adoption of Artificial Intelligence and Related Vulnerabilities in the Financial Sector*. – Basel: FSB, 2025.

17. Razavi R., Elbahnasawy N. G. Unlocking credit access: Using non-CDR mobile data to enhance credit scoring for financial inclusion // *Finance Research Letters*. – 2025. – Vol. 73. – Art. 106682. DOI: 10.1016/j.frl.2024.106682.

18. Bank Rossii. *Primenenie iskusstvennogo intellekta na finansovom rynke: tekushchii status i usloviya dal'neishego razvitiya: doklad dlya obshchestvennykh konsul'tatsii*. – Moskva: Bank Rossii, 2025.

19. Financial Stability Board. *Sound Practices for Responsible Adoption of Artificial Intelligence (AI): Consultation Report*. – Basel: FSB, 2026.

20. Bahadori S., Hassanzadeh A. A comprehensive literature review on AI-based credit assessment in digital lending: exploring models, transparency, alternative data, and real-time learning // *Expert Systems with Applications*. – 2026. – Vol. 318. – Art. 131872. DOI: 10.1016/j.eswa.2026.131872.