

Васильев Александр Дмитриевич

магистрант

Митрофанова Марина Юрьевна

канд. экон. наук, доцент

ФГБОУ ВО «Чувашский государственный

университет им. И.Н. Ульянова»

г. Чебоксары, Чувашская Республика

РОЛЬ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ В БАНКОВСКОМ СЕКТОРЕ

***Аннотация:** статья посвящена исследованию функциональных возможностей нейросетевых технологий в банковском секторе, анализу механизмов их применения в операционной деятельности кредитных организаций, а также оценке перспектив дальнейшей интеграции искусственного интеллекта в финансовую инфраструктуру. Рассматриваются конкретные направления использования нейросетей – от скоринговых систем до противодействия мошенничеству и персонализации клиентского обслуживания.*

***Ключевые слова:** нейросеть, искусственный интеллект, банковский сектор, нейросетевые технологии, финансовые инструменты.*

В современной экономической системе искусственный интеллект (далее – ИИ) определяет будущее банковской деятельности. Он представляет собой глубокое технологическое достижение, катализирующее структурную трансформацию всей отрасли. По мере того, как ИИ, включая генеративный ИИ (GenAI), переходит от стадии экспериментов к внедрению и далее к общеорганизационной перестройке, формируются два встречных потока, непосредственно влияющих на коэффициент операционной эффективности банка:

– рост доходов за счёт взаимодействия с нужными клиентами с правильным предложением в нужное время;

– трансформация затрат путём интеллектуальной автоматизации и гибких операционных процессов.

Для руководителей банковского и инвестиционно-банковского секторов это знаменует глубокие перемены: коэффициент эффективности перестаёт быть ретроспективным показателем деятельности. Он превращается в наиболее красноречивый прогностический индикатор способности вашего банка использовать инновации на базе ИИ для конкуренции, роста и обеспечения устойчивости.



Рис. 1. Применение ИИ на финансовом рынке [1]

Как показывают исследования Банка России, уже более 20% банковских организаций используют искусственный интеллект на постоянной основе. Одна треть банков рассматривают данное направление как перспективное и имеют намерения использовать его в ближайшем будущем, многие банки активно тестируют пилотные проекты и только одна треть не планируют применение нейросетей по тем или иным причинам.

Существуют различные направления для применения нейросетей в банковской сфере.

По мнению Кочергина Д.А., «финансовая сфера относится к числу наиболее перспективных и рискованных областей применения ИИ» [3, с. 157]. Также он подчеркивает, что «из-за высокой доли когнитивно сложных задач и работы с большими массивами данных, важно определить наиболее значимые направления финансов, по которым применение искусственного интеллекта является наиболее оправданным» [3, с. 158]. Такими направлениями, по мнению экономистов банка международных расчетов (БМР), в настоящее время являются: 1) платежи; 2) финансовое посредничество; 3) страхование; 4) управление активами.

Среди множества задач, которые могут быть решены за счёт применения искусственного интеллекта, к наиболее значимым можно отнести следующие, представленные на рис. 2 [2].



Рис. 2. Основные причины использования ИИ в банковском секторе по данным опроса респондентов

Как видно из данного рисунка, к наиболее актуальным задачам, решаемым за счет ИИ в финансовом секторе, можно отнести управление рисками (15%), противодействие мошенничеству (12%), операционная деятельность (10%).

Как известно, кредитный скоринг представляет собой одну из наиболее технологически насыщенных областей банковской деятельности, в которой нейросетевые модели демонстрируют статистически значимое превосходство над традиционными регрессионными методами. Глубокие нейронные сети, в особенности многослойные перцептроны и рекуррентные архитектуры типа LSTM (Long Short-Term Memory), позволяют обрабатывать нелинейные зависимости между переменными, характеризующими финансовое поведение заёмщика, что принципиально недостижимо в рамках линейных дискриминантных моделей [4]. Способность таких систем к обучению на неструктурированных

данных – транзакционных историях, поведенческих паттернах, данных геолокации – открывает возможность формирования многомерного профиля кредитоспособности, существенно превосходящего по информативности классические FICO-подобные оценки.

Архитектура градиентного бустинга в сочетании с нейросетевыми эмбедингами категориальных признаков позволяет банкам снижать уровень дефолтов в портфеле на 15–25% по сравнению с логистической регрессией при сопоставимых объёмах обучающей выборки. Принципиально значимым является то обстоятельство, что современные трансформерные модели, адаптированные для табличных финансовых данных (в частности, TabTransformer и FT-Transformer), демонстрируют устойчивую генерализацию даже при наличии значительного числа пропущенных значений, что особенно актуально при работе с клиентами без развёрнутой кредитной истории.

Детектирование мошеннических транзакций является областью, в которой нейросетевые технологии продемонстрировали наиболее выраженный практический эффект. Традиционные системы на основе правил (rule-based systems) оказываются принципиально неспособными адаптироваться к эволюционирующим схемам финансового мошенничества, тогда как нейросетевые детекторы аномалий, обученные на многомиллионных массивах транзакционных данных, выявляют нетипичные паттерны поведения в режиме реального времени с точностью, недостижимой для экспертных систем [5].

Среди архитектурных решений, применяемых в антифрод-системах ведущих банков, выделяются следующие:

- автоэнкодеры (Autoencoders) – используются для обнаружения аномалий путём реконструкции нормального поведения транзакций и последующего вычисления ошибки восстановления для подозрительных операций;

- графовые нейронные сети (Graph Neural Networks, GNN) – применяются для анализа связей между участниками транзакций, позволяя выявлять координированные мошеннические схемы, в которых отдельные операции выглядят легитимными при изолированном рассмотрении;

– рекуррентные сети с механизмом внимания (Attention-based RNN) -обеспечивают анализ временных последовательностей транзакций с акцентированием на наиболее информативных временных интервалах, предшествующих подозрительной активности.

Применение графовых нейронных сетей заслуживает отдельного рассмотрения: финансовая система по своей природе представляет собой граф взаимодействий между субъектами, и GNN-модели способны улавливать структурные аномалии в топологии этого графа, недоступные для классических методов машинного обучения. Исследования, проведённые на данных крупных европейских банков, свидетельствуют о том, что интеграция GNN в антифрод-пайплайны снижает долю ложноположительных срабатываний на 30–40% при одновременном повышении чувствительности к реальным мошенническим событиям.

Нейросетевые рекомендательные системы трансформируют подход банков к формированию продуктового предложения, переводя его из плоскости массового маркетинга в область индивидуализированного финансового сопровождения. Коллаборативная фильтрация на основе матричной факторизации, дополненная нейросетевыми эмбедингами поведенческих признаков, позволяет прогнозировать потребности клиента в финансовых продуктах с точностью, достаточной для формирования персонализированных предложений в момент, наиболее соответствующий жизненной ситуации пользователя [6].

Особую роль в этом направлении играют языковые модели большого масштаба (Large Language Models, LLM), интегрированные в системы клиентского обслуживания. Банковские чат-боты на базе архитектуры GPT и её производных демонстрируют способность не только к ответам на типовые запросы, но и к содержательному финансовому консультированию, анализу расходных паттернов клиента и формированию персонализированных рекомендаций по оптимизации личного бюджета. При этом принципиально значимым остаётся вопрос интерпретируемости таких систем: регуляторные требования ряда юрисдикций обяза-

вают банки обеспечивать объяснимость автоматизированных решений, что стимулирует развитие методологии XAI (Explainable Artificial Intelligence) применительно к банковским нейросетевым системам.

Нейросетевые модели нашли широкое применение в системах управления рыночными, кредитными и операционным рисками банков. Рекуррентные архитектуры и трансформеры, обученные на многолетних временных рядах финансовых показателей, демонстрируют способность к выявлению предвестников системных кризисов, которые остаются незамеченными при использовании традиционных стохастических моделей типа GARCH или VAR.

Следовательно, направления применения нейросетей в риск-менеджменте банков охватывают следующий спектр задач.

1. Стресс-тестирование портфелей – нейросетевые генеративные модели (в частности, вариационные автоэнкодеры и диффузионные модели) используются для синтеза реалистичных сценариев рыночного стресса, выходящих за пределы исторически наблюдавшихся событий.

2. Прогнозирование вероятности дефолта контрагента – модели на основе трансформерной архитектуры обрабатывают мультимодальные данные, включая финансовую отчётность, новостной фон и данные альтернативных источников, формируя интегральную оценку кредитного риска.

3. Мониторинг операционного риска – нейросетевые системы анализируют журналы операций, выявляя аномальные паттерны, свидетельствующие о сбоях в бизнес-процессах или несанкционированных действиях сотрудников.

Применение генеративных нейросетей для стресс-тестирования представляет собой методологически значимый прорыв: традиционные регуляторные сценарии (например, разработанные Базельским комитетом) охватывают лишь ограниченный спектр возможных рыночных конфигураций, тогда как генеративные модели способны синтезировать тысячи правдоподобных, но исторически не наблюдавшихся сценариев, существенно расширяя горизонт риск-анализа.

Широкое распространение нейросетевых технологий в банковском секторе сопряжено с комплексом регуляторных вызовов, требующих системного осмысления. Непрозрачность механизмов принятия решений в глубоких нейронных сетях – феномен, обозначаемый в литературе как «чёрный ящик» (black box problem), – вступает в прямое противоречие с принципами транспарентности, закреплёнными в директивах ЕС (в частности, GDPR и AI Act) и рекомендациях Базельского комитета по банковскому надзору.

Методологические подходы к обеспечению интерпретируемости нейросетевых банковских систем включают:

– SHAP (SHapley Additive exPlanations) – метод атрибуции вклада признаков, основанный на теории кооперативных игр, позволяющий объяснять индивидуальные предсказания модели в терминах, понятных регуляторам и клиентам;

– LIME (Local Interpretable Model-agnostic Explanations) – локальная аппроксимация сложной модели интерпретируемой линейной моделью в окрестности конкретного наблюдения;

– Attention visualization – визуализация весов механизма внимания в трансформерных моделях, позволяющая идентифицировать, какие именно транзакции или временные интервалы оказали наибольшее влияние на итоговое решение.

Регуляторное давление в направлении объяснимости нейросетевых систем стимулирует развитие гибридных архитектур, сочетающих высокую предсказательную мощность нейронных сетей с интерпретируемостью традиционных статистических моделей. Подобные гибридные подходы, в частности, нейросимволические системы и модели с встроенными механизмами объяснения, рассматриваются ведущими исследователями как перспективное направление развития банковского ИИ на ближайшее десятилетие.

Федеративное обучение (Federated Learning) открывает принципиально новые возможности для банковской отрасли: данная технология позволяет нескольким кредитным организациям совместно обучать нейросетевые модели без передачи конфиденциальных клиентских данных на централизованный сервер, что одновременно решает проблемы конфиденциальности и обеспечивает доступ к

значительно более репрезентативным обучающим выборкам. Пилотные проекты по федеративному обучению антифрод-моделей, реализованные консорциумами европейских банков в 2023–2024 годах, продемонстрировали прирост качества детектирования мошенничества на 18–22% по сравнению с моделями, обученными на данных отдельных организаций.

Квантовые нейронные сети (Quantum Neural Networks, QNN) представляют собой ещё одно перспективное направление, находящееся на стыке квантовых вычислений и глубокого обучения. Несмотря на то, что практическое применение QNN в банковском секторе остаётся делом среднесрочной перспективы ввиду технологических ограничений современных квантовых процессоров, теоретические исследования убедительно демонстрируют потенциал квантового ускорения для задач оптимизации портфелей и оценки производных финансовых инструментов.

Таким образом, нейросетевые технологии фундаментально трансформируют операционную модель банковского бизнеса, обеспечивая качественно иной уровень точности в задачах кредитного скоринга, детектирования мошенничества, управления рисками и персонализации клиентского обслуживания. Дальнейшее развитие данного направления будет определяться балансом между предсказательной мощностью нейросетевых архитектур и требованиями регуляторной интерпретируемости, а также прогрессом в области федеративного и квантового обучения.

Список литературы

1. Искусственный интеллект на финансовом рынке. – URL: <https://cbr.ru/fintech/primenenie-iskusstvennogo-intellekta-na-finansovom-rynke/> (дата обращения: 07.04.2026).
2. Искусственный интеллект в банках. – URL: <https://www.tadviser.ru/index.php/> (дата обращения: 07.04.2026).
3. Кочергин Д.А. Основные направления использования искусственного интеллекта в финансовой сфере / Д.А. Кочергин // Вестник Института экономики

Российской академии наук. – 2025. – №6. – С. 147–169. DOI 10.52180/2073-6487_2025_6_147_169. EDN EQJOKW

4. Babaev D. E5: Temporal convolutional network for sequential transaction data / D. Babaev, M. Savchenko, A. Tuzhilin // Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. – 2023. – P. 3563–3573. – URL: <https://arxiv.org/pdf/1911.02496> (дата обращения: 07.04.2026).

5. Van Belle R. Fraud detection in financial transactions using deep learning: a systematic review / R. Van Belle, B. Van Calster, J.Y. Verbakel // Journal of Financial Crime. – 2024. – Vol. 31. No. 2. – P. 412–438.

6. Srivastava A. Personalized banking using deep learning-based recommendation systems / A. Srivastava, M. Pant // International Journal of Information Management Data Insights. – 2024. – Vol. 4. No. 1. – Art. 100210. DOI 10.1016/j.jjime.2023.100210. EDN CGWFXK