

УДК 336

DOI 10.26118/2782-4586.2025.75.72.029

Силенко Аркадий Николаевич

Национальный Исследовательский Ядерный Университет МИФИ

Туйгунов Артур Ильшатович

Национальный Исследовательский Ядерный Университет МИФИ

Теслюк Владислав Сергеевич

Национальный Исследовательский Ядерный Университет МИФИ

Сравнение эффективности традиционных и нейросетевых подходов в банковской практике

Аннотация. Статья посвящена сравнительному анализу традиционных и нейросетевых подходов в банковской аналитике. Рассмотрены ключевые задачи финансовых институтов, включая кредитный скоринг, прогнозирование оттока клиентов, выявление мошенничества и оценку кредитоспособности. Показаны преимущества и ограничения классических методов статистики и машинного обучения, а также современные возможности нейронных сетей — от полно связанных и рекуррентных до сверточных архитектур, автоэнкодеров и генеративных моделей. Особое внимание уделено практическим примерам применения искусственного интеллекта в международных и российских банках, а также анализу рисков и вызовов, связанных с автоматизацией кредитных решений, защитой данных и интерпретируемостью алгоритмов. На основе обзора обоснована необходимость гибридного подхода, сочетающего точность цифровых технологий с экспертной оценкой специалистов, что позволяет повысить эффективность кредитных процессов и укрепить конкурентные позиции банков.

Ключевые слова: банковская аналитика, кредитный скоринг, искусственный интеллект, нейронные сети, машинное обучение, антифрод, риск-менеджмент, цифровизация банков, интерпретируемость моделей, Big Data

Silenko Arkady Nikolaevich

National Research Nuclear University MEPhI

Tuigunov Artur Ilshatovich

National Research Nuclear University MEPhI

Teslyuk Vladislav Sergeevich

National Research Nuclear University MEPhI

Comparison of the effectiveness of traditional and neural network approaches in banking practice

Abstract. The article is devoted to a comparative analysis of traditional and neural network approaches in banking analytics. It examines key tasks of financial institutions, including credit scoring, customer churn prediction, fraud detection, and credit risk assessment. The advantages and limitations of classical statistical and machine learning methods are outlined, along with the modern capabilities of neural architectures — from multilayer perceptrons and recurrent networks to convolutional models, autoencoders, and generative adversarial networks. Special attention is paid to practical applications of artificial intelligence in both international and Russian banks, as well as to the challenges related to automation of credit decisions, data security, and model interpretability. Based on the review, the study substantiates the relevance of a hybrid approach that combines the accuracy of digital technologies with expert evaluation, thus enhancing credit processes and strengthening the competitive position of banks.

Keywords: banking analytics, credit scoring, artificial intelligence, neural networks, machine learning, fraud detection, risk management, digitalization of banking, model interpretability, Big Data

1. Введение

Банковский сектор находится в эпицентре технологической трансформации, вызванной стремительным развитием методов анализа данных и искусственного интеллекта. В условиях роста объёмов информации, усложнения клиентских профилей и повышения требований к управлению рисками финансовые институты всё чаще сталкиваются с необходимостью выбора между проверенными временем традиционными моделями и современными нейросетевыми подходами. Эта дилемма особенно актуальна в таких ключевых областях, как кредитный скоринг, выявление мошенничества, прогнозирование оттока клиентов и оценка кредитоспособности.

Несмотря на обширную литературу по отдельным методам машинного обучения, до сих пор недостаточно систематизированных обзоров, которые бы комплексно сопоставляли традиционные и нейросетевые подходы именно в банковской практике, с учётом не только точности моделей, но и их интерпретируемости, вычислительной сложности и реальной применимости.

Настоящая статья представляет собой аналитический обзор, направленный на восполнение этого пробела. В ней последовательно рассматриваются:

- основные традиционные методы, используемые в банковской аналитике, и их ограничения;
- современные нейросетевые архитектуры и их применение в решении типовых задач;
- практические кейсы внедрения от ведущих банков и платёжных систем;
- ключевые риски и вызовы, связанные с автоматизацией кредитных решений.

Обзор ориентирован на исследователей, аналитиков и специалистов в области финансовых технологий, стремящихся глубже понять эволюцию методов банковской аналитики и обоснованно подходить к выбору инструментов, которые обеспечивают баланс между точностью, прозрачностью и соответствием требованиям регуляторов.

2. Обзор традиционных подходов в банковской аналитике

В банковской практике традиционные подходы основываются на проверенных методах статистики и машинного обучения, отличающихся высокой интерпретируемостью и простотой реализации. Ниже приведён список ключевых классических методов, применяемых в финансовой аналитике:

- Логистическая регрессия - наиболее распространённый инструмент в задачах бинарной классификации, таких как кредитный скоринг. Позволяет оценить вероятность наступления события на основе набора признаков. Обеспечивает баланс между точностью, скоростью и понятностью [2];
- Линейная регрессия - используется для предсказания количественных показателей, например, суммы кредита, вероятного дохода клиента или объема транзакций. Предполагает линейную зависимость между переменными;
- LDA и QDA (Linear Discriminant Analysis – «линейный дискриминантный анализ» и Quadratic Discriminant Analysis - «квадричный дискриминантный анализ») - методы дискриминантного анализа, которые применяются для классификации клиентов на основе их признаков. Лучше работает при соблюдении предпосылок о нормальности распределения данных и равенстве ковариационных матриц [3];
- Решающие деревья (Decision Trees) - Используются для визуализации процесса принятия решений. Удобны при построении скоринговых правил, но склонны к переобучению на сложных выборках без регуляризации [4];
- Скоринговые карты (Scorecards) - формализованные системы оценки кредитоспособности, в которых каждому значению признака присваивается балл. Обеспечивают простоту применения и соответствие требованиям регуляторов.

Они используются для предварительной обработки данных, устранения мультиколлинеарности и повышения устойчивости моделей.

Для наглядности сравним традиционные подходы (табл. 1).

Таблица 1

Сравнение традиционных подходов

Метод	Достоинства	Недостатки
Логистическая регрессия	Высокая интерпретируемость коэффициентов, быстрое обучение и предсказание, устойчивость к переобучению на небольших выборках, соответствие регуляторным требованиям	Предполагает линейную зависимость между признаками и логикой вероятности, плохо улавливает сложные нелинейные взаимодействия без ручного инжиниринга признаков
Линейная регрессия	Проста реализации и интерпретации, эффективна при линейных зависимостях и нормально распределённых ошибках	Не подходит для задач классификации, чувствительна к выбросам и нарушению предпосылок (линейность, гомоскедастичность), не учитывает нелинейные паттерны
LDA/QDA	Эффективны при малом числе признаков и нормальном распределении данных, LDA особенно хорош при малых выборках	Сильно зависят от предположений о нормальности и (для LDA) равенстве ковариационных матриц, плохо работают с высокоразмерными или неструктурированными данными
Решающие деревья	Интуитивно понятная структура, не требуют масштабирования признаков, способны моделировать нелинейные зависимости и взаимодействия	Склонны к переобучению без регуляризации, нестабильны: небольшие изменения в данных могут привести к кардинально разным деревьям, менее точны по сравнению с ансамблями (например, градиентным бустингом)
Скоринговые карты	Максимальная прозрачность и объяснимость для клиента и регулятора, простота внедрения в бизнес-процессы, легко адаптируются под бизнес-правила	Требуют ручной калибровки и дискретизации признаков, ограниченная гибкость — не учитывают сложные зависимости между переменными, потенциально менее точны по сравнению с адаптивными моделями

Традиционные методы продолжают использоваться в следующих областях:

- Кредитный скоринг: логистическая регрессия и скоринговые карты остаются стандартом в большинстве розничных банков;
- Прогнозирование рисков: дискриминантный анализ и линейные модели применяются для оценки риска дефолта корпоративных клиентов;
- Анализ транзакций: простые деревья решений могут использоваться для фильтрации подозрительных операций по заранее заданным правилам;
- Оценка доходности: линейные модели применяются в прогнозах прибыли, маржи и других количественных метрик.

Несмотря на долгую историю использования, классические подходы имеют ряд ограничений:

- Линейность и упрощённые допущения - большинство моделей не справляются с нелинейными зависимостями и требуют соблюдения строгих статистических предпосылок;

- Ограниченнaя гибкость - такие модели плохо адаптируются к быстро меняющимся данным и нестандартным источникам информации;
- Низкая производительность на больших объемах и высокоразмерных данных - эффективность падает при работе с big data или неструктурированной информацией;
- Требования к качественной предобработке - необходима ручная обработка пропусков, выбросов и масштабирование признаков.

3. Современные нейросетевые подходы в банковской практике

Нейросетевые модели представляют собой адаптивные структуры, способные выявлять сложные нелинейные зависимости и обучаться на больших объемах разнородных данных. Их архитектуры варьируются в зависимости от задачи и типа данных.

В банковской практике используются следующие типы нейронных сетей:

- MLP (Multilayer Perceptrons – «полносвязные нейронные сети») - наиболее универсальный вариант для обработки табличных данных, применяются в задачах скоринга, прогнозирования поведения клиентов и оценки рисков [5];
- RNN и LSTM (Recurrent Neural Network – «рекуррентная нейронная сеть» и Long Short-Term Memory – «длинная краткосрочная память») - эффективно работают с временными рядами и последовательными данными, например, при анализе транзакций, прогнозировании денежных потоков или мониторинге клиентской активности [6];
- CNN (Convolutional Neural Network – «сверточные нейронные сети») - хоть и более характерны для работы с изображениями, также находят применение при обработке сетевых графов транзакций или визуальных данных (например, анализа чеков и документов) [7];
- Автоэнкодеры и вариационные автоэнкодеры - используются для выявления аномалий, сокращения размерности данных, генерации скрытых признаков [8].
- GAN (Generative Adversarial Networks – «генеративно-состязательные сети в области искусственного интеллекта ИИ») - применяются в симуляции транзакционных данных и создании synthetic data для тестирования моделей без утечки реальной информации [9].

Кроме того, растёт интерес к трансформерным архитектурам и графовым нейросетям, особенно в задачах обработки текстов (например, анализ заявок, жалоб) и построения сетей взаимодействий клиентов.

Для наглядности сравним нейросетевые подходы (табл. 2)

Таблица 2

Сравнение нейросетевых подходов

Метод	Достоинства	Недостатки
MLP	Хорошо работают с табличными данными, универсальны, относительно просты в реализации	Склонны к переобучению, хуже справляются с последовательными и структуризованными данными
RNN/LSTM	Подходят для временных рядов и последовательностей, учитывают динамику данных	Обучение медленное, возможны проблемы с длинными зависимостями, требуют много ресурсов
CNN	Отлично выявляют локальные применимы к транзакций и данным	Паттерны, графам и визуальным Менее эффективны для табличных и чисто временных данных

Автоэнкодеры и вариационные автоэнкодеры	Хороши для выявления аномалий и скрытых зависимостей, помогают сокращать размерность данных	Интерпретируемость низкая, могут терять важную информацию при восстановлении
GAN	Умеют генерировать <i>synthetic data</i> , что важно для тестирования моделей без раскрытия реальных данных	Трудны в обучении (нестабильность), возможны проблемы с качеством и достоверностью синтетических выборок

Применение нейросетей в банковской практике охватывает широкий спектр задач:

- Кредитный скоринг - MLP и градиентные бустинговые модели позволяют улучшить точность прогнозирования дефолтов за счет обработки большого количества признаков, включая поведенческие, социальные сети и транзакционную активность;
- Антифрод-системы - и LSTM и CNN способны анализировать последовательности операций в режиме реального времени, выявляя аномальные шаблоны, которые трудно зафиксировать с помощью правил или традиционных моделей;
- Прогнозирование оттока клиентов «Churn prediction» - нейросети учитывают, как историческое поведение клиента, так и скрытые зависимости, недоступные для интерпретации в классических моделях;
- Оценка платежеспособности и прогноз движения средств – RNN показывают высокую эффективность в моделировании денежного потока компаний и индивидуальных клиентов;
- Обработка текстовой информации - трансформеры и BERT-модели (Bidirectional Encoder Representations from Transformers), а именно двунаправленные представления кодировщика на основе трансформеров, которые применяются для анализа анкет, жалоб, контрактов и прочих неструктурированных текстов, усиливая работу отделов комплаенса и клиентской поддержки.

Реализация нейросетевых моделей в банковской инфраструктуре требует учета ряда технических факторов:

- Наличие качественных данных - модели требуют большого объема размеченной информации; при этом данные должны быть репрезентативными и актуальными;
- Обработка приватности и соответствие требованиям регуляторов - использование персональных данных требует соблюдения законов о защите информации (GDPR, ФЗ-152 и др.), что налагает ограничения на сбор и использование данных [1];
- Выбор архитектуры и гиперпараметров - необходима точная настройка моделей, подбор архитектуры и механизмов регуляризации для предотвращения переобучения;
- Инфраструктурные требования - нейросетевые модели требуют значительных вычислительных ресурсов и наличия архитектуры для их обучения.
- Интерпретируемость решений - для соответствия требованиям финансовых регуляторов активно используются методы post-hoc интерпретации, такие как SHAP, LIME, attention-механизмы, где:

SHAP (SHapley Additive exPlanations) - метод интерпретации, основанный на теории Шепли (кооперативные игры), оценивает вклад каждого признака в итоговое предсказание модели;

LIME (Local Interpretable Model-agnostic Explanations) - локально интерпретируемые объяснения для моделей любого типа: строит простую аппроксимирующую модель рядом с конкретным предсказанием, чтобы объяснить его;

Attention-механизмы - архитектурный приём в нейросетях, позволяющий модели «сфокусироваться» на наиболее важных частях входных данных при обработке текста, последовательностей или других структур.

4. Практические примеры внедрения в банковской сфере

Наиболее показательным примером интеграции современных и традиционных методов является опыт Альфа-Банка. Банк использует нейросетевые модели (в частности, полносвязные сети и ансамбли на основе градиентного бустинга) для повышения точности кредитного scoringа, анализа транзакционной активности и прогнозирования рисков. При этом решения принимаются не полностью автоматически: scoringовые оценки дополняются экспертной проверкой, особенно в спорных или нетипичных случаях. Обучение моделей ведётся на обезличенных данных из бюро кредитных историй, внутренних транзакций и поведенческих метрик, что позволяет учитывать как финансовую, так и поведенческую составляющую клиента.

Важно отметить, что даже при высокой эффективности ИИ-систем (например, сокращение времени одобрения заявок и снижение уровня дефолтов) банк сохраняет элементы классических подходов — в том числе scoringовые карты и статистические модели для сегментов с ограниченными данными. Такой гибридный подход обеспечивает баланс между прогностической точностью, интерпретируемостью и соответствием регуляторным требованиям.

5. Риски и стратегии оценки кредитных решений в эпоху ИИ

Современные банки всё чаще применяют гибридные модели оценки рисков, сочетающие количественные методы (статистические и ML-модели) с качественной экспертизой. Наиболее распространены три типа scoringа:

- application-scoring (оценка по заявке),
- behavioral-scoring (на основе поведения клиента)
- fraud-scoring (выявление мошенничества).

Хотя традиционные методы — такие как логистическая регрессия или scoringовые карты — остаются основой из-за их прозрачности, нейросетевые подходы позволяют повысить точность за счёт анализа больших и неструктурированных данных [10].

Однако масштабное внедрение ИИ сопряжено с рядом рисков. Ключевые из них:

- 1) Низкая интерпретируемость моделей, затрудняющая объяснение решений клиентам и регуляторам;
- 2) Угрозы информационной безопасности и утечки персональных данных;
- 3) Масштабирование ошибок: даже незначительные сбои в алгоритмах могут привести к массовым отказам надёжным заемщикам или, наоборот, к выдаче рискованных кредитов (например, ошибки в scoringовой системе Сбербанка привели к значительным финансовым потерям).

Поэтому эффективная стратегия кредитного анализа в условиях цифровизации предполагает не полную автоматизацию, а постоянный мониторинг, калибровку моделей и участие человека на критических этапах. Роль аналитика смещается от рутинного расчёта к интерпретации, аудиту алгоритмов и принятию нетривиальных решений — что подтверждает необходимость гибридного подхода.

Заключение

Современная банковская практика всё чаще демонстрирует не противостояние, а синергию традиционных и нейросетевых подходов к аналитике. Классические методы — такие, как логистическая регрессия, scoringовые карты и деревья решений — продолжают играть ключевую роль благодаря своей интерпретируемости, устойчивости и соответствуию регуляторным требованиям. В то же время нейросетевые и другие методы машинного обучения открывают новые возможности для повышения точности прогнозов, обработки больших и неструктурированных данных, а также выявления сложных, нелинейных зависимостей, недоступных для традиционных моделей.

Важно подчеркнуть: универсальной модели не существует — для каждого отдельного случая существует наиболее приемлемый подход, обеспечивающий наилучшее решение. Выбор между интерпретируемостью и точностью, между простотой внедрения и прогностической мощью должен основываться на специфике задачи, доступных данных, регуляторных ограничений и стратегических приоритетов банка. Например, в задачах кредитного скоринга для массового розничного сегмента может быть предпочтительна логистическая регрессия, тогда как для выявления сложных мошеннических схем в реальном времени — рекуррентные нейронные сети окажутся значительно эффективнее.

Интеграция этих подходов позволяет формировать гибкие и надёжные аналитические системы, в которых вычислительная мощь искусственного интеллекта усиливается экспертной оценкой специалистов. Такой гибридный подход не только повышает качество кредитных решений и снижает операционные риски, но и способствует укреплению конкурентных позиций банка на рынке.

Вместе с тем, масштабное внедрение ИИ требует особого внимания к сопутствующим вызовам: обеспечение информационной безопасности, защита персональных данных, предотвращение алгоритмической дискриминации и минимизация рисков, связанных с масштабированием ошибок. Не менее важно учитывать и социально-экономический контекст: жёсткие алгоритмы, ориентированные исключительно на минимизацию рисков, могут необоснованно ограничивать доступ к финансовым услугам для потенциально надёжных, но «нестандартных» заёмщиков.

Таким образом, оптимальная стратегия развития банковской аналитики заключается не в поиске единого «идеального» инструмента, а в создании сбалансированной экосистемы, где технологическая точность сочетается с гибкостью человеческого суждения. Будущее принадлежит моделям, которые не только «умны», но и прозрачны, справедливы и адаптивны — а их эффективная эксплуатация возможна только при активном участии квалифицированных аналитиков, способных критически оценивать работу алгоритмов и принимать взвешенные управленческие решения.

Список источников

1. Федеральный закон “О персональных данных” от 27.07.2006 N 152-ФЗ (последняя редакция) \ КонсультантПлюс [WWW Document], n.d. URL https://www.consultant.ru/document/cons_doc_LAW_61801/ (дата обращения 01.06.2025).
2. Dong, G., Lai, K.K., Yen, J., 2010. Credit scorecard based on logistic regression with random coefficients. Procedia Comput. Sci., ICCS 2010 1, 2463–2468. <https://doi.org/10.1016/j.procs.2010.04.278>
3. Ghojogh, B., Crowley, M., 2019. Linear and Quadratic Discriminant Analysis: Tutorial. <https://doi.org/10.48550/arXiv.1906.02590>
4. Dumitrescu, E., Hué, S., Hurlin, C., Tokpavi, S., 2022. Machine learning for credit scoring: Improving logistic regression with non-linear decision-tree effects. Eur. J. Oper. Res. 297, 1178–1192. <https://doi.org/10.1016/j.ejor.2021.06.053>
5. Blanco, A., Pino-Mejías, R., Lara, J., Rayo, S., 2013. Credit scoring models for the microfinance industry using neural networks: Evidence from Peru. Expert Syst. Appl. 40, 356–364. <https://doi.org/10.1016/j.eswa.2012.07.051>
6. Ala’raj, M., Abbod, M.F., Majdalawieh, M., 2021. Modelling customers credit card behaviour using bidirectional LSTM neural networks. J. Big Data 8, 69. <https://doi.org/10.1186/s40537-021-00461-7>
7. Agrawal, P., Chaudhary, D., Madaan, V., Zabrovskiy, A., Prodan, R., Kimovski, D., Timmerer, C., 2021. Automated bank cheque verification using image processing and deep learning methods. Multimed. Tools Appl. 80, 5319–5350. <https://doi.org/10.1007/s11042-020-09818-1>
8. Lin, T.-H., Jiang, J.-R., 2021. Credit Card Fraud Detection with Autoencoder and Probabilistic Random Forest. Mathematics 9, 2683. <https://doi.org/10.3390/math9212683>

9. Efimov, D., Xu, D., Kong, L., Nefedov, A., Anandakrishnan, A., 2020. Using generative adversarial networks to synthesize artificial financial datasets. <https://doi.org/10.48550/arXiv.2002.02271>

10. Ушанов, А.Е., 2024. Новые Технологии В Оценке Кредитоспособности Клиентов Банка: Плюсы И Минусы. Азимут Научных Исследований Экономика И Управление 13, 158–162

Сведения об авторах

Силенко Аркадий Николаевич, к.т.н., доцент кафедры управления бизнес-проектами факультета бизнес-информатики и управления комплексными системами НИЯУ МИФИ, г. Москва, Россия

Туйгунов Артур Ильшатович, аспирант, НИЯУ МИФИ, г. Москва, Россия

Теслюк Владислав Сергеевич, аспирант, НИЯУ МИФИ, г. Москва, Россия

Information about the author

Silenco Arkady Nikolaevich, Candidate of Technical Sciences, Associate Professor at the Department of Business Project Management, Faculty of Business Informatics and Complex Systems Management, National Research Nuclear University MEPhI, Moscow, Russia

Tuigunov Artur Ilshatovich, PhD Student, NRNU MEPhI, Moscow, Russia

Teslyuk Vladislav Sergeevich, PhD Student, NRNU MEPhI, Moscow, Russia