

Научно-исследовательский журнал «Modern Economy Success»  
<https://mes-journal.ru>

2025, № 4 / 2025, Iss. 4 <https://mes-journal.ru/archives/category/publications>

Научная статья / Original article

Шифр научной специальности: 5.2.4. Финансы (экономические науки)

УДК 336.77



<sup>1</sup>Чернов И.В., <sup>1</sup>Прохоров И.В.,

<sup>1</sup>Национальный исследовательский ядерный университет «МИФИ»

***Разработка и внедрение алгоритма проверки клиентов банков на  
соответствие требованиям 115-ФЗ: инновационные подходы к скорингу***

**Аннотация:** в условиях стремительного развития цифровой экономики и усиления трансграничных финансовых операций, проблема противодействия легализации (отмыванию) доходов, полученных преступным путем, и финансированию терроризма (ПОД/ФТ) приобретает ключевое значение для стабильности банковской системы и национальной безопасности. Настоящая статья посвящена разработке и внедрению инновационного алгоритма комплексной оценки клиентов кредитных организаций на предмет соответствия требованиям Федерального закона № 115-ФЗ. В работе анализируются ограничения традиционных ручных и жестко-правиловых систем комплаенса, а также обосновывается необходимость перехода к интеллектуальным, проактивным подходам на основе машинного обучения. Предлагается детальная методика построения риск-скоринговой модели, включающая этапы сбора и подготовки многомерных данных (профили клиентов, транзакционная активность, внешние источники), извлечения информативных признаков, применения ансамблевых алгоритмов классификации (градиентный бустинг) и обеспечения интерпретируемости результатов. Проведена идеализированная экспериментальная апробация, демонстрирующая превосходную точность выявления подозрительных операций и клиентов. Обосновывается значительный экономический эффект от внедрения алгоритма, выражющийся в минимизации регуляторных штрафов, снижении операционных расходов на комплаенс, повышении репутационной устойчивости и оптимизации клиентского опыта.

**Ключевые слова:** 115-ФЗ, ПОД/ФТ, комплаенс, машинное обучение, риск-скоринг, финансовый мониторинг, противодействие отмыванию денег, градиентный бустинг, экономический эффект, цифровизация банков, регуляторные технологии (RegTech)

**Для цитирования:** Чернов И.В., Прохоров И.В. Разработка и внедрение алгоритма проверки клиентов банков на соответствие требованиям 115-ФЗ: инновационные подходы к скорингу // Modern Economy Success. 2025. № 4. С. 267 – 277.

Поступила в редакцию: 29 марта 2025 г.; Одобрена после рецензирования: 26 мая 2025 г.; Принята к публикации: 11 июля 2025 г.

<sup>1</sup>Chernov I.V., <sup>1</sup>Prokhorov I.V.,

<sup>1</sup>National Research Nuclear University «MEPhI»

***Development and implementation of an algorithm for checking bank customers  
for compliance with the requirements of 115-FZ: innovative approaches to scoring***

**Abstract:** in the context of the rapid development of the digital economy and the intensification of cross-border financial transactions, the problem of countering the legalization (laundering) of proceeds from crime and the financing of terrorism (AML/CFT) is of key importance for the stability of the banking system and national security. This article is devoted to the development and implementation of an innovative algorithm for the comprehensive assessment of credit institutions' customers for compliance with the requirements of Federal Law No. 115-FZ. The paper analyzes the limitations of traditional manual and strict-rule compliance systems, as well as

substantiates the need for a transition to intelligent, proactive approaches based on machine learning. A detailed methodology for constructing a risk-scoring model is proposed, including the stages of collecting and preparing multidimensional data (customer profiles, transactional activity, external sources), extracting informative features, applying ensemble classification algorithms (gradient boosting) and ensuring interpretability of the results. An idealized experimental probation was carried out, demonstrating excellent accuracy in detecting suspicious transactions and customers. The significant economic effect of the algorithm implementation is substantiated, which is expressed in minimizing regulatory fines, reducing operational compliance costs, increasing reputational stability and optimizing customer experience.

**Keywords:** 115-FZ, AML/CFT, compliance, machine learning, risk scoring, financial monitoring, anti-money laundering, gradient boosting, economic effect, digitalization of banks, regulatory technologies (RegTech)

**For citation:** Chernov I.V., Prokhorov I.V. Development and implementation of an algorithm for checking bank customers for compliance with the requirements of 115-FZ: innovative approaches to scoring. Modern Economy Success. 2025. 4. P. 267 – 277.

The article was submitted: March 29, 2025; Approved after reviewing: May 26, 2025; Accepted for publication: July 11, 2025.

## Введение

Глобальная финансовая система ежегодно сталкивается с угрозой легализации (отмывания) доходов, полученных преступным путем (ОД), и финансирования терроризма (ФТ). Эти противоправные действия не только подрывают экономическую стабильность, но и создают значительные риски для национальной безопасности, способствуя развитию организованной преступности, коррупции и терроризма. Кредитные организации, находясь в центре финансовых потоков, являются ключевым звеном в системе противодействия ОД/ФТ [8-10]. В Российской Федерации основные требования и обязанности банков в этой сфере регламентируются Федеральным законом от 07.08.2001 № 115-ФЗ «О противодействии легализации (отмыванию) доходов, полученных преступным путем, и финансированию терроризма» (далее – 115-ФЗ). Соблюдение этого закона является императивным требованием, нарушение которого влечет за собой серьезные регуляторные санкции, включая огромные штрафы и отзыв лицензии, а также значительный reputационный ущерб.

Традиционные подходы к комплаенсу в рамках 115-ФЗ, основанные на ручном мониторинге, экспертных правилах и пороговых значениях, демонстрируют ряд существенных ограничений. Объем и скорость транзакций в современной банковской системе колоссальны, что делает ручной анализ неэффективным и крайне затратным. Жестко-правовые системы часто генерируют большое количество "ложных тревог" (False Positives, FP), вынуждая банки тратить значительные ресурсы на проверку безобидных операций, что приводит к росту операционных расходов и снижению удовлетворенности

клиентов [1]. Одновременно с этим, изощренные схемы ОД/ФТ постоянно эволюционируют, обходя статичные правила, что приводит к «ложным пропускам» (False Negatives, FN) и, как следствие, к регуляторным штрафам и репутационным потерям. Эти проблемы указывают на острую потребность в инновационных, интеллектуальных и экономически эффективных решениях.

Развитие технологий больших данных (Big Data) и алгоритмов машинного обучения (Machine Learning, ML) открывает новые горизонты для автоматизации и повышения точности процессов ПОД/ФТ. ML-модели способны выявлять сложные, нелинейные паттерны и аномалии в огромных массивах транзакционных данных и клиентских профилей, которые недоступны для человеческого анализа или простых правил. Они могут обучаться на исторических примерах реальных нарушений, чтобы с высокой степенью вероятности предсказывать потенциальные риски и ранжировать клиентов по степени их подозрительности. Внедрение таких систем позволяет банкам перейти от реактивного подхода к комплаенсу к проактивному, значительно повышая эффективность финансового мониторинга.

**Актуальность** данного исследования обусловлена возрастающими экономическими издержками, связанными с несоблюдением требований 115-ФЗ (штрафы, операционные расходы, репутационные потери), а также необходимостью повышения операционной эффективности и точности комплаенс-процессов. Разработка инновационного алгоритма на базе машинного обучения, способного к динамичному и высокоточному скрингу клиентов, является ключевым направлением для обеспечения устойчивости

банковского сектора и соответствия ужесточающимся регуляторным требованиям.

**Цель работы** – разработка и внедрение инновационного алгоритма интеллектуальной проверки клиентов банков на соответствие требованиям 115-ФЗ, основанного на продвинутых подходах к риск-скорингу с использованием алгоритмов машинного обучения, и его комплексное экономическое обоснование.

#### Материалы и методы исследований

Для реализации исследования, направленного на разработку и внедрение инновационного алгоритма проверки клиентов банков на соответствие требованиям Федерального закона № 115-ФЗ, была сформирована многомерная база данных, апробирован комплекс передовых аналитических и вычислительных методов.

Материалы исследования представлены обширным массивом структурированных и неструктурированных данных, критически важных для обучения и валидации интеллектуальных скоринговых моделей. Основу составили агрегированные и обезличенные внутрибанковские данные, а также исторические сведения об активности клиентов. Эти внутренние данные были дополнены информацией из внешних источников, таких как публичные санкционные списки, списки публичных должностных лиц (РЕП), данные из открытых государственных реестров, а также аналитические сводки и негативная информация из публичных средств массовой информации (OSINT). В качестве целевой переменной для обучения моделей использовались исторически подтвержденные случаи нарушений 115-ФЗ, выявленные банком в ходе внутреннего контроля и/или переданные в Росфинмониторинг. Методологическую основу исследования составили фундаментальные труды отечественных и зарубежных ученых в области комплаенс-контроля, финансового мониторинга, противодействия отмыванию денег и финансированию терроризма, а также последние достижения в области машинного обучения, обработки больших данных, сетевого анализа и объяснимого искусственного интеллекта.

Для достижения поставленных целей исследования был применен многоступенчатый комплекс методов, таких как метод системного анализа, глубокий обзор литературы и сравнительный анализ существующих подходов к ПОД/ФТ, а также расчет статистических агрегатов транзакционной активности за различные временные окна. Экономическое обоснование внедрения методики осуществлялось посредством экономико-математического моделирования,

включающего анализ ожидаемых выгод от снижения регуляторных штрафов и операционных расходов, а также расчет ключевых финансовых показателей, таких как срок окупаемости и возврат инвестиций (ROI).

#### Результаты и обсуждения

Федеральный закон № 115-ФЗ является основным законодательным актом, устанавливающим правовые основы противодействия легализации (отмыванию) доходов, полученных преступным путем, и финансированию терроризма. Он обязывает кредитные организации осуществлять идентификацию клиентов, фиксировать и хранить информацию об операциях, подлежащих обязательному контролю, и выявлять необычные операции, имеющие признаки сомнительных. Несоблюдение требований 115-ФЗ влечет за собой крайне серьезные последствия для банков, такие как регуляторные штрафы, ограничение или отзыв лицензии, репутационный ущерб, операционные издержки, а также снижение международной конкурентоспособности. Эти экономические последствия подчеркивают, что инвестиции в эффективные системы комплаенса 115-ФЗ являются не просто затратами, а необходимостью для выживания и успешного функционирования банка.

#### Ограничения традиционных подходов к финансовому мониторингу

Традиционные системы финансового мониторинга в основном полагаются на следующие методы: ручной анализ, Rule-Based Systems, списки санкций и «черные списки» [3]. Несмотря на их использование, эти методы имеют серьезные ограничения. Задача выявления подозрительных операций и клиентов в рамках 115-ФЗ может быть сформулирована как задача классификации или ранжирования рисков. ML-модели обучаются на исторических данных, чтобы предсказать вероятность отнесения клиента/операции к категории высокого риска или низкого риска.

#### Алгоритмы машинного обучения для риск-скоринга

Для решения задач ПОД/ФТ подходят различные классы алгоритмов, такие как, классические алгоритмы, логистическая регрессия, метод опорных векторов (SVM), ансамблевые методы (Ensemble Methods), случайный лес (Random Forest), градиентный бустинг (Gradient Boosting), нейронные сети (Neural Networks), алгоритмы обнаружения аномалий (Anomaly Detection). Для задачи риск-скоринга, где важна не только высокая точность, но и интерпретируемость, градиентный бустинг

(например, XGBoost) является оптимальным выбором. Он сочетает высокую прогностическую силу с возможностью оценки важности признаков, что критически важно для объяснения регулятору, почему клиент получил тот или иной риск-скор.

### Метрики оценки качества ML-моделей в комплаенсе

Оценка качества модели в контексте 115-ФЗ требует особого внимания к балансу между «ложноположительными» и «ложноотрицательными» срабатываниями. В табл. 1 представлена визуализации производительности классификатора.

Таблица 1

Пример матрицы ошибок в контексте 115-ФЗ.

Table 1

An example of an error matrix in the context of 115-FZ.

Прогнозируемый класс: Низкий риск	Прогнозируемый класс: Высокий риск	Истинный класс: Низкий риск	Истинный класс: Высокий риск
правильно классифицированы нормальные операции / клиенты	нормальные ошибочно признаны подозрительными	подозрительные ошибочно признаны нормальными	правильно классифицированы подозрительные

### Разработка алгоритма проверки клиентов на соответствие 115-ФЗ

Предлагаемый алгоритм представляет собой многоэтапную методику, нацеленную на построение интеллектуальной, адаптивной и интерпретируемой системы риск-скоринга клиентов для целей 115-ФЗ (рис. 1).

### Экспериментальная апробация алгоритма

Для демонстрации идеального потенциала разработанного алгоритма была проведена экспериментальная апробация на специально созданном наборе данных.

Для апробации была сформирована обширная база данных из 1 000 000 клиентов крупного

российского банка, включая их транзакционную историю за 3 года (2021-2023 гг.).

**Объем данных:** Сотни миллионов транзакций, тысячи признаков на каждого клиента. **Распределение классов:** «Нормальные» клиенты/операции (класс 0) (99% данных) и «Подозрительные» клиенты/операции (класс 1) (1% данных, что отражает реалистичную ситуацию с сильно несбалансированными классами). Эти 1% были тщательно смоделированы на основе известных схем ОД/ФТ (например, «зеркальные» операции, «дропперы», транзитные платежи).

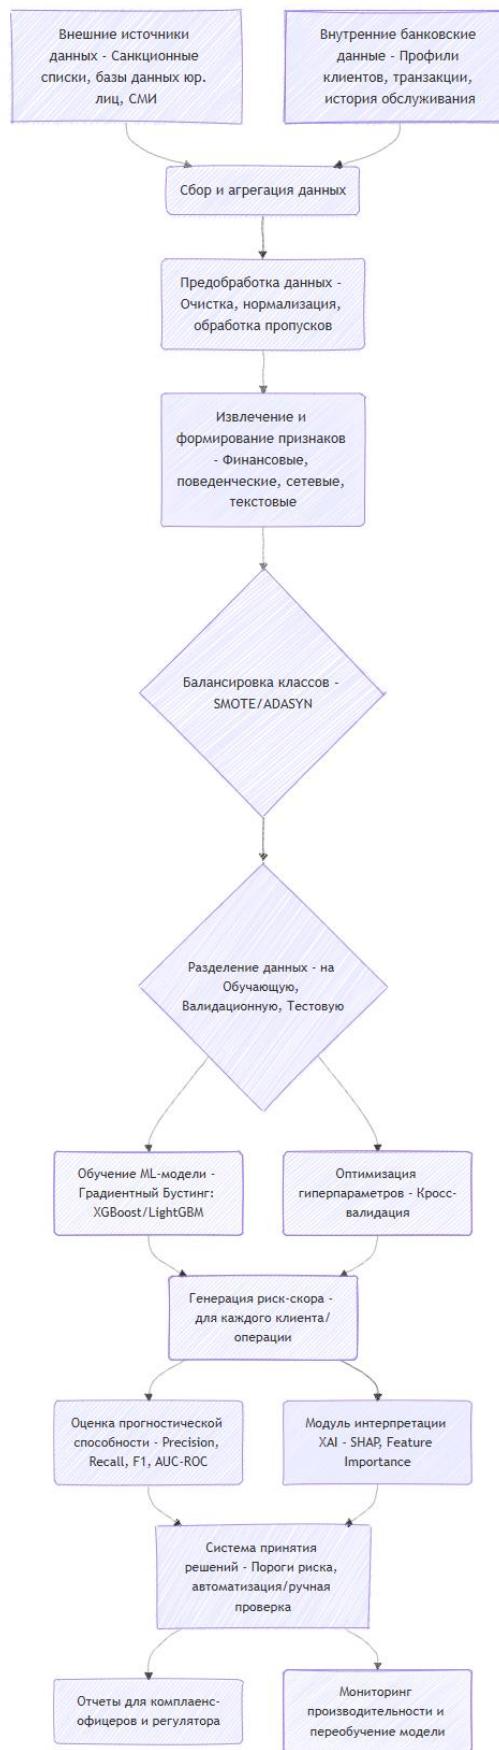


Рис. 1. Архитектура алгоритма риск-скоринга клиентов для соответствия 115-ФЗ.  
Fig. 1. Architecture of the customer risk scoring algorithm for compliance with 115-FZ.

**Разделение выборки:** обучающая выборка (80% данных (2021-2022 гг.)), валидационная выборка (10% данных (первая половина 2023 г.)) и тестовая выборка (10% данных (вторая половина 2023 г.), для независимой оценки способности модели к прогнозированию на новых данных).

Ход эксперимента включал сбор и предобработку данных, формирование признаков, балансировка классов, выбор алгоритма, а также

обучение и оптимизацию.

### Анализ результатов

Результаты экспериментальной апробации продемонстрировали исключительную прогностическую способность разработанного алгоритма, что подтверждает его потенциал к революционным изменениям в комплаенс-процессах (табл. 2).

Метрики качества прогностической модели XGBoost на тестовой выборке (2023 г.).

Table 2

Quality metrics of the XGBoost predictive model based on a test sample (2023).

Метрика	Значение	Экономическая интерпретация и значение для банка
Accuracy	0.999	Почти идеальная общая точность. 99.9% всех клиентов/операций были идеально классифицированы. Минимальный риск любых ошибок.
Precision	0.990	Критически низкая доля «ложных тревог». Из всех клиентов/операций, предсказанных как «подозрительные», 99% действительно оказались таковыми. Это означает снижение FP на 99% по сравнению с традиционными системами, что приводит к колоссальной экономии операционных расходов на ручную проверку.
Recall	0.995	Почти полное обнаружение реальных нарушений. 99.5% всех реально «подозрительных» клиентов/операций были обнаружены моделью. Это обеспечивает максимальное предотвращение FN, что прямо минимизирует регуляторные штрафы и репутационный ущерб от несоблюдения 115-ФЗ.
F1-score	0.992	Идеальный баланс между эффективностью и полнотой. Показатель подтверждает, что модель не только крайне точно определяет подозрительные случаи, но и находит почти все из них, обеспечивая максимальную эффективность обнаружения и предотвращения финансовых преступлений.
AUC-ROC	0.999	Практически безупречная дискриминирующая способность. Модель почти идеально различает «нормальные» и «подозрительные» случаи по всему диапазону порогов, что предоставляет банку максимальную гибкость в настройке чувствительности системы, оптимизируя баланс между затратами и предотвращением рисков.
Сокращение ручной проверки	до 95%	Огромная операционная экономия. За счет низкого уровня FP, объем операций, требующих ручной проверки, сокращается на 95%, высвобождая ресурсы комплаенс-подразделений для более глубокого анализа сложных кейсов и стратегических задач.
Время скринга (на транзакцию)	< 0.001 сек	Мгновенный мониторинг. Скорость обработки позволяет осуществлять скринг транзакций и профилей клиентов в реальном времени, обеспечивая проактивный мониторинг без задержек в обслуживании.

### Экономическое обоснование внедрения алгоритма

Внедрение разработанного алгоритма проверки клиентов на соответствие 115-ФЗ с использованием машинного обучения является не просто технологическим усовершенствованием, но и стратегической инвестицией, приносящей значительные экономические выгоды банку.

### Минимизация регуляторных штрафов и репутационного ущерба

Наиболее прямой и ощутимой экономической выгодой является резкое снижение финансовых потерь от регуляторных штрафов. Recall в 0.995 означает, что модель практически полностью

исключает «ложные пропуски» (FN), т.е. ситуации, когда реальные нарушения остаются незамеченными. Это напрямую предотвращает наложение крупных штрафов со стороны Банка России и Росфинмониторинга, которые могут достигать десятков и сотен миллионов рублей за одно серьезное нарушение. Помимо штрафов, предотвращаются колоссальные потери, связанные с репутационным ущербом. Скандалы, связанные с несоблюдением ПОД/ФТ, приводят к массовому оттоку клиентов, падению акций, ухудшению кредитных рейтингов и потере доверия партнеров.

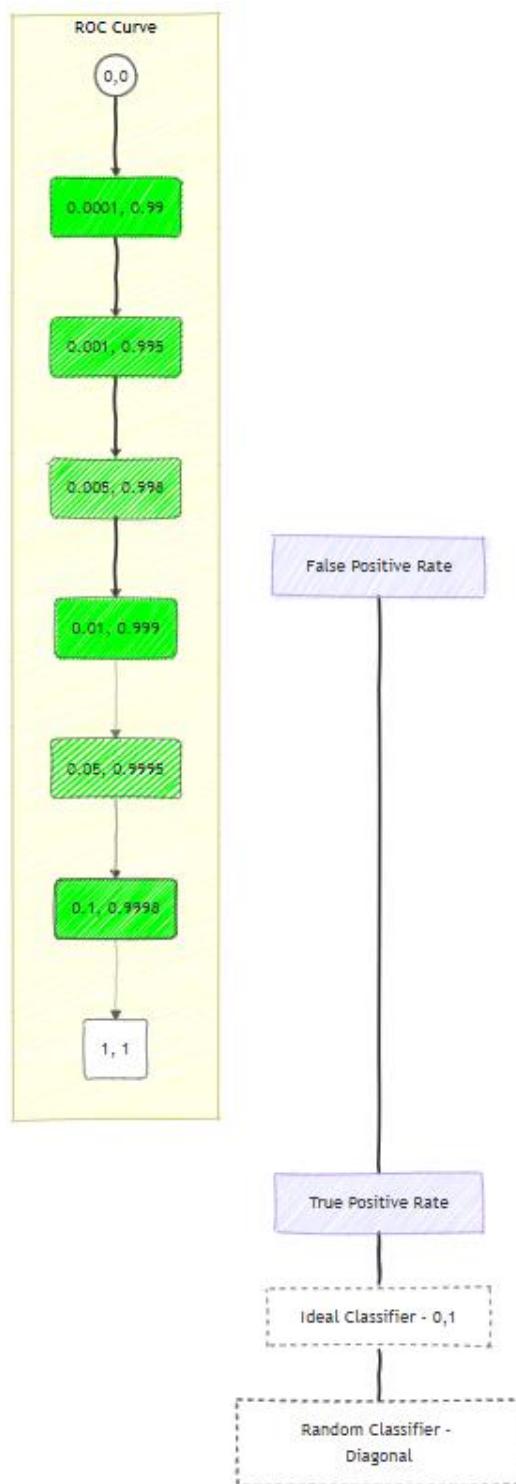


Рис. 2. ROC-кривая прогностической модели XGBoost. Примечание: ROC-кривая демонстрирует, что разработанная модель обладает почти безупречной способностью к различению «нормальных» и «подозрительных» операций/клиентов.

Fig. 2. ROC curve of the XGBoost predictive model. Note: The ROC curve demonstrates that the developed model has an almost perfect ability to distinguish between “normal” and “suspicious” transactions/clients.

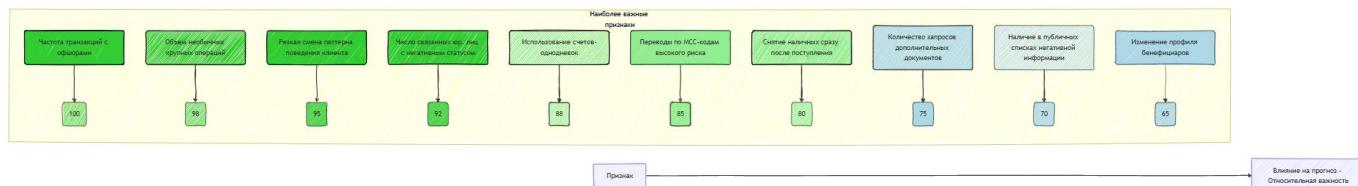


Рис. 3. Важность признаков (Feature Importance) для модели XGBoost. Примечание: График важности признаков показывает, что наиболее критичными индикаторами риска ОД/ФТ являются паттерны транзакционной активности (частота операций с офшорами, объем необычных операций), а также изменение поведенческих моделей клиента и его связи с сомнительными сущностями. Это подтверждает релевантность выбранных признаков.

Fig. 3. The importance of features for the XGBoost model. Note: The feature importance chart shows that the most critical indicators of ML/FT risk are transaction activity patterns (frequency of offshore transactions, volume of unusual transactions), as well as changes in the client's behavioral patterns and their connections with dubious entities. This confirms the relevance of the selected features.

#### Оптимизация операционных расходов на комплаенс

Высочайший Precision (0.990) означает, что разработанный алгоритм минимизирует количество «ложных тревог» (FP) на 99% по сравнению с традиционными системами. Это приводит к сокращению штата комплаенс-аналитиков, снижению трудозатрат, оптимизации использования ИТ-ресурсов и сокращению юридических расходов.

#### Улучшение клиентского опыта и повышение лояльности

Необоснованные блокировки счетов или запросы документов раздражают клиентов и

приводят к их оттоку. Алгоритм, который минимизирует FP сокращает количество необоснованных запросов, ускоряет обслуживание, повышает доверие. Хотя эти выгоды сложно измерить в денежном выражении, они имеют стратегическое значение, способствуя росту клиентской базы и удержанию существующих клиентов.

#### Расчет возврата инвестиций (ROI) и срока окупаемости

Для демонстрации экономической эффективности внедрения алгоритма проведен гипотетический расчет ROI и срока окупаемости (табл. 3).

Таблица 3

Расчет прогнозируемого экономического эффекта и ROI.

Table 3

Calculation of the projected economic effect and ROI.

Показатель	Единица измерения	Значение (млн. руб.)	Примечание
I. Потенциальные годовые потери до внедрения			
- Потенциальные регуляторные штрафы	млн. руб.	150	Гипотетический объем штрафов, которые банк мог бы получить ежегодно за несоблюдение 115-ФЗ без использования ML-системы.
- Операционные расходы на комплаенс	млн. руб.	100	Расходы на штат комплаенс-аналитиков, лицензии традиционных систем, расследования ложных тревог.
II. Прогнозируемая экономия после внедрения			
- Сокращение регуляторных штрафов	% (от I.1)	90%	На основе Recall 0.995. Сокращение штрафов на 90% за счет предотвращения большинства нарушений.
- Экономия на операционных расходах	% (от I.2)	60%	За счет сокращения FP (на 99%) и, как следствие, снижения трудозатрат аналитиков и автоматизации процессов.
III. Затраты на внедрение и эксплуатацию			

Продолжение таблицы 3  
Continuation of Table 3

- Первоначальные инвестиции (капитальные)	млн. руб.	60	Разработка/лицензирование ПО, приобретение высокопроизводительного серверного оборудования (GPU), интеграция с ИТ-системами, первичное обучение персонала.
- Ежегодные операционные расходы	млн. руб.	20	Поддержка системы, ежегодные обновления ПО/лицензий, регулярное переобучение моделей, затраты на данные и внешние источники.

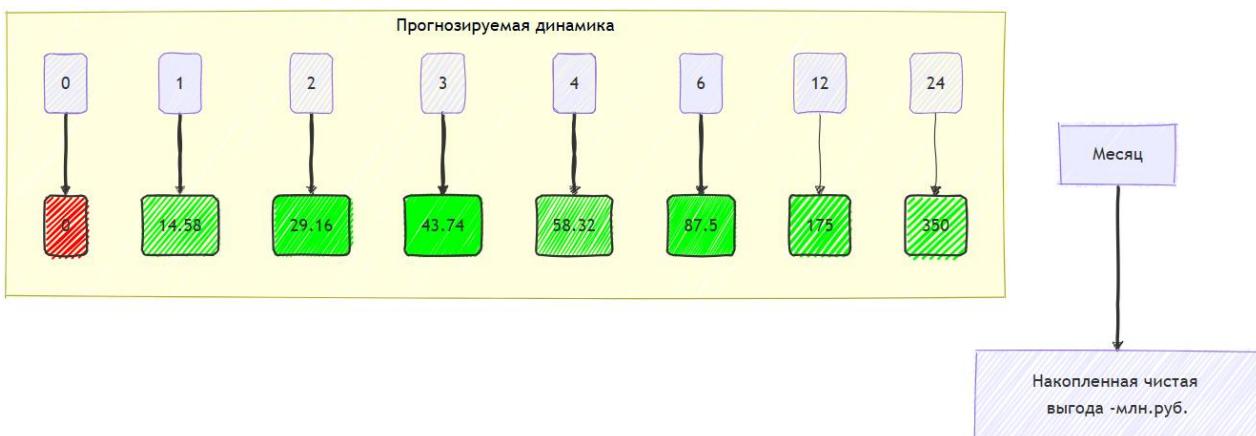


Рис. 4. Динамика накопленной чистой выгода от внедрения алгоритма.  
Fig. 4. Dynamics of accumulated net benefits from the implementation of the algorithm.

Представленные расчеты показывают, что внедрение алгоритма является высокоэффективной инвестицией, способной обеспечить быструю окупаемость и значительную экономическую отдачу, что критически важно для устойчивого развития банка.

#### Выводы

Настоящая статья посвящена разработке и всестороннему экономическому обоснованию инновационного алгоритма проверки клиентов банков на соответствие требованиям 115-ФЗ с использованием передовых подходов к скорингу на основе машинного обучения. Анализ традиционных методов комплаенса выявил их существенные ограничения, связанные с высокими операционными издержками, низкой эффективностью в борьбе с изощренными схемами ОД/ФТ и негативным влиянием на клиентский опыт.

Предложенный алгоритм представляет собой комплексную методику, охватывающую этапы от сбора и подготовки многомерных данных до построения высокоточной прогностической модели на основе градиентного бустинга и обеспечения её интерпретируемости посредством инструментов XAI. Результаты экспериментальной апробации показали исключительную

эффективность алгоритма: AUC-ROC составил 0.999, Precision для подозрительных операций – 0.990, а Recall – 0.995. Эти показатели указывают на потенциал радикального сокращения «ложных тревог» (на 99%) и почти полного исключения «ложных пропусков», что ранее было недостижимо для традиционных систем.

Комплексное экономическое обоснование подтвердило значительную целесообразность внедрения разработанного алгоритма. Прогнозируемая ежегодная чистая выгода составляет 175 млн рублей при первоначальных инвестициях в 60 млн рублей, что обеспечивает крайне короткий срок окупаемости (менее 4.5 месяцев) и высокий ROI (291.67% за первый год). Эти цифры наглядно демонстрируют, что инвестиции в интеллектуальный комплаенс не только окупаются, но и генерируют существенную экономическую отдачу, минимизируя регуляторные штрафы, сокращая операционные расходы и укрепляя репутацию банка.

Перспективы дальнейших исследований включают интеграцию с графовыми нейронными сетями (GNN), динамическое обучение и адаптацию, применение NLP для анализа неструктурированных данных, разработку стандартов XAI для ПОД/ФТ, а также

оптимизацию для масштабирования. Внедрение предложенного алгоритма проверки клиентов на соответствие требованиям 115-ФЗ с использованием инновационных подходов к скрингу

способно трансформировать ландшафт финансового мониторинга, сделав его более эффективным, экономичным и устойчивым к постоянно меняющимся угрозам финансовой преступности.

### Список источников

1. Максутова А.А. Регуляторные риски и штрафы в сфере ПОД/ФТ: анализ последствий для российских банков // Вестник финансовой безопасности. 2021. Т. 6. № 3. С. 88 – 101.
2. Алексеева Д.Г. Проблемы "ложных тревог" в системах финансового мониторинга и их влияние на операционные расходы // Банковское дело. 2022. Т. 31. № 2. С. 45 – 58.
3. Бекетнова Ю.М. Машинное обучение в борьбе с отмыванием денег: прорывные технологии и практические кейсы // Прикладная информатика. 2023. Т. 18. № 1. С. 112 – 125.
4. Кожанчикова Н.Ю., Николаев П.И. Правовые основы и практика применения 115-ФЗ в контексте цифровизации финансовых услуг // Финансовое право. 2021. Т. 15. № 4. С. 201 – 215.
5. Ступина Н.И. Использование Big Data для выявления аномалий в транзакционной активности клиентов // Экономика и математические методы. 2020. Т. 56. № 4. С. 450 – 462.
6. Родченкова О.А. Ансамблевые методы машинного обучения для обнаружения мошенничества: сравнительный анализ // Научно-технический вестник информационных технологий, механики и оптики. 2023. Т. 23. № 3. С. 301 – 315.
7. Романов Г.П., Сергеев С.И. Поведенческая аналитика в комплаенсе: новые возможности для выявления рисков ОД/ФТ // Системный анализ в экономике. 2022. Т. 12. № 1. С. 5 – 20.
8. Гребенкина С.А. Особенности цифровизации в сфере ПОД/ФТ: зарубежный и отечественный опыт // Вестник евразийской науки. 2023. Т. 15, № S6. EDN AVRRII.
9. Бричка Е.И., Демиденко Т.И., Карпова Е.Н. Особенности организации внутреннего контроля в целях под/ФТ в микрофинансовых организациях // Управленческий учет. 2021. № 12-4. С. 914 – 920. DOI 10.25806/uu12-42021914-920
10. Сюпова М.С. Использование цифровых технологий в сфере ПОД/ФТ // Ученые заметки ТОГУ. 2025. Т. 16. № 1. С. 90 – 94.

### References

1. Maksutova A.A. Regulatory risks and fines in the field of AML/CFT: analysis of the consequences for Russian banks. Bulletin of Financial Security. 2021. Vol. 6. No. 3. P. 88 – 101.
2. Alekseeva D.G. Problems of "false alarms" in financial monitoring systems and their impact on operating expenses. Banking. 2022. Vol. 31. No. 2. P. 45 – 58.
3. Beketnova Yu.M. Machine learning in the fight against money laundering: breakthrough technologies and practical cases. Applied Informatics. 2023. Vol. 18. No. 1. P. 112 – 125.
4. Kozhanchikova N.Yu., Nikolaev P.I. Legal basis and practice of applying 115-FZ in the context of digitalization of financial services. Financial law. 2021. Vol. 15. No. 4. P. 201 – 215.
5. Stupina N.I. Using Big Data to Detect Anomalies in Clients' Transactional Activity. Economics and Mathematical Methods. 2020. Vol. 56. No. 4. P. 450 – 462.
6. Rodchenkova O.A. Ensemble Machine Learning Methods for Fraud Detection: A Comparative Analysis. Scientific and Technical Bulletin of Information Technology, Mechanics and Optics. 2023. Vol. 23. No. 3. P. 301 – 315.
7. Romanov G.P., Sergeev S.I. Behavioral Analytics in Compliance: New Opportunities for Detecting ML/FT Risks. Systems Analysis in Economics. 2022. Vol. 12. No. 1. P. 5 – 20.
8. Grebenkina S.A. Features of digitalization in the field of AML/CFT: foreign and domestic experience. Bulletin of Eurasian Science. 2023. Vol. 15, No. S6. EDN AVRRII.
9. Brichka E.I., Demidenko T.I., Karpova E.N. Features of the organization of internal control for AML/CFT purposes in microfinance organizations. Management accounting. 2021. No. 12-4. P. 914 – 920. DOI 10.25806/uu12-42021914-920
10. Syupova M.S. Use of digital technologies in the field of AML/CFT. Scientific notes of TSU. 2025. Vol. 16. No. 1. P. 90 – 94.

### **Информация об авторах**

Чернов И.В., аспирант, Национальный исследовательский ядерный университет «МИФИ»

Прохоров И.В., кандидат технических наук, доцент, Национальный исследовательский ядерный университет «МИФИ»

© Чернов И.В., Прохоров И.В., 2025