

АНАЛИЗ ПРОБЛЕМЫ ВЫЯВЛЕНИЯ ПРОБЛЕМНЫХ ФИНАНСОВЫХ ТРАНЗАКЦИЙ И СОВРЕМЕННЫХ МЕТОДОВ ЕЕ РЕШЕНИЯ

Аннотация. Статья посвящена исследованию теоретических основ применения алгоритмов машинного обучения в выявлении проблемных финансовых транзакций в условиях цифровизации финансовой сферы. Анализируются особенности современных угроз, включая мошенничество, схемы отмывания денежных средств и нарушения санкционных требований, приводится характеристика ограничений традиционных систем финансового мониторинга и обосновывается необходимость перехода к интеллектуальным адаптивным моделям анализа. Автором аргументируется актуальность гибридных систем детекции, объединяющих преимущества табличных, поведенческих и графовых методов.

Ключевые слова: Ключевые слова: финансовый мониторинг, машинное обучение, финансовое мошенничество, отмывание денежных средств, графовые модели, адаптивные системы.

Стремительное развитие цифровых технологий, охватывающее практически все сферы финансовых услуг, привело к радикальному изменению характера взаимодействия между участниками финансовой системы. Массовое внедрение дистанционного банковского обслуживания, мобильных приложений, высокоскоростных платёжных сервисов, интеграция финансовых платформ и маркетплейсов создали условия, при которых количество, скорость и сложность финансовых транзакций увеличиваются экспоненциально. Вместе с повышением удобства клиентов была создана благоприятная среда для появления новых форм злоупотреблений, использующих уязвимости цифровой инфраструктуры. Проблемные финансовые транзакции – это мошеннические, связанные с отмыванием денежных средств или нарушающие санкционные ограничения. Они приобрели системный характер, существенно усложнив задачи финансового мониторинга. Их выявление требует переосмысления устоявшихся методов анализа и перехода от фиксированных экспертных правил к адаптивным алгоритмам, способным обучаться на данных и учитывать динамику поведения участников.

В условиях цифровизации характер проблемных финансовых транзакций становится более комплексным, что объясняется несколькими взаимосвязанными факторами. Во-первых, злоумышленники активно используют технические средства автоматизации, а также распределенные сетевые решения, позволяющие им проводить транзакции через виртуальные устройства, приватные каналы связи и подмененные цифровые отпечатки устройств. Во-вторых, наблюдается рост мошеннических схем, основанных на социальной инженерии, при которых преступники не просто подделывают данные, а целенаправленно воздействуют на пользователя, добиваясь добровольного совершения подозрительных операций. Это существенно усложняет задачу детекции, поскольку транзакции внешне полностью соответствуют привычному поведению клиента. В-третьих, схемы отмывания денег всё более ориентированы на создание многоуровневых структур переводов, пересекающих границы юрисдикций, банков и платёжных сервисов [8]. Выявление таких структур требует не анализа отдельных операций, а реконструкции цепочки транзакций, что традиционными средствами практически невозможно.

Существенную трудность представляет характер данных о транзакциях, которые поступают в системы финансового мониторинга. Такие данные обладают выраженной временной динамикой, неоднородностью распределения и высокой степенью асимметрии



классов. Проблемные операции формируют крайне малый процент от общего потока, что создаёт серьёзные сложности для алгоритмов классификации: они склонны уделять непропорционально малое внимание редким наблюдениям и «заглушать» слабые, но критически важные паттерны. При этом добросовестные клиенты демонстрируют изменчивое поведение: перемены места жительства, частые перемещения, изменения в стиле потребления, колебания финансовой активности, сезонные факторы. Все это делает невозможным использование жёстких пороговых условий, которые работали бы стабильно на протяжении длительного времени. К этому добавляется сетевой характер финансовых взаимодействий: одна операция зачастую не может служить достаточным индикатором подозрительности, поскольку важную роль играет контекст – связь между пользователями, устройствами, геолокациями, принимающими сторонами, а также временная последовательность событий. Лишь совокупность факторов позволяет судить о том, является ли операция частью незаконной схемы.

На протяжении десятилетий основным инструментом финансового мониторинга оставались rule-based системы, основанные на фиксированных правилах и экспертных сценариях. Такие системы формируются специалистами на основе опыта и анализа исторических инцидентов [1, 3]. Они предполагают наличие заранее прописанных условий, нарушение которых вызывает срабатывание. Однако современные тенденции развития финансовых злоупотреблений демонстрируют ограниченность подобного подхода. Первым важным недостатком rule-based систем является их неспособность выявлять новые, ранее неизвестные схемы. Правила отражают лишь известные закономерности. Вторым важным ограничением является высокий уровень ложных срабатываний. Такие системы часто подают сигналы, когда поведение клиентов является легитимным, но выглядит нетипичным с точки зрения жёсткого набора правил. Это приводит к перегрузке аналитиков и снижению оперативности реагирования на действительно опасные события. Третьим недостатком выступает неадаптивность таких моделей: изменение условий рынка, сезонные колебания активности, появление новых финансовых продуктов и платёжных механизмов приводят к устареванию существующих правил, что требует постоянного ручного обновления и растущих затрат.

На фоне усложнения финансовых потоков и повышения требований к качеству мониторинга методы машинного обучения становятся ключевым направлением развития аналитических систем. Использование машинного обучения позволяет перейти от статических правил к адаптивным механизмам анализа, способным самостоятельно выявлять закономерности, характерные для проблемных транзакций. Наиболее широко в банковской практике применяются классические алгоритмы контроля, такие как логистическая регрессия, деревья решений, случайный лес, а также различные модификации градиентного бустинга [7, 9]. Они демонстрируют высокую эффективность при анализе табличных данных, позволяют учитывать нелинейные зависимости и обладают приемлемой интерпретируемостью, что важно для соблюдения регуляторных требований. Однако такие модели ограничены в способности выявлять сложные взаимосвязи, которые характерны для многоступенчатых схем отмывания и координированного мошенничества.

Развитие технологий глубокого обучения стимулировало появление более сложных моделей, способных анализировать временные ряды транзакций, поведенческие особенности клиентов и скрытые зависимости. Нейронные сети позволяют выявлять тонкие аномалии в последовательности операций, формировать контекстные признаки и моделировать сценарии, которые трудно описать вручную. Однако при их применении возникают трудности с высокой чувствительностью к качеству данных [2, 6].

Одним из наиболее перспективных направлений стало применение графовых методов анализа транзакций, основанных на представлении финансовой системы в виде сети.



Графовые нейронные сети позволяют учитывать структуру взаимодействий между участниками, выявлять нетипичные соединения, анализировать локальные и глобальные свойства графа [4, 5]. В отличие от классических ML-моделей, графовые подходы способны обнаруживать схемы, в которых каждая отдельная транзакция выглядит привычной, но совокупность действий образует аномальную структуру. Графовые методы предоставляют аналитикам возможность изучать не только действия отдельного клиента, но и его связи с другими субъектами, что особенно важно при расследовании схем отмывания денег или обхода санкций, где ключевую роль играет сеть взаимодействий.

Несмотря на значительное развитие методов машинного обучения и графового анализа, остаётся целый ряд нерешённых задач. Среди них выделяется обеспечение интерпретируемости моделей, повышенная устойчивость к изменению данных во времени, а также создание гибридных систем, сочетающих преимущества разных подходов. Важную роль играет корректное формирование признаков, включающее табличные, поведенческие, временные и графовые характеристики. Недостаточная полнота признакового пространства может привести к снижению качества детекции, тогда как чрезмерная сложность модели усложняет ее внедрение и сопровождение. Баланс между точностью, прозрачностью и вычислительной эффективностью является одним из ключевых ориентиров современного развития интеллектуальных систем мониторинга.

Теоретический анализ показывает, что ни один из отдельных подходов не способен в полной мере обеспечить надежное выявление проблемных транзакций. Классические ML-алгоритмы хорошо работают на структурированных данных, но не учитывают сетевой контекст. Глубокие нейронные сети способны выявлять сложные зависимости, но создают проблемы интерпретации и устойчивости. Графовые модели эффективно анализируют структуру взаимодействий, но требуют специфических данных и значительных вычислительных ресурсов. Поэтому наиболее перспективным направлением становится построение комбинированных систем, объединяющих преимущества всех этих подходов. Такие системы позволяют комплексно анализировать транзакции на уровне отдельных признаков, временных последовательностей и графовых структур, что существенно повышает точность и устойчивость выявления проблемных операций.

Список литературы:

1. Митчелл Т. Машинное обучение. – М.: Издательство McGraw-Hill, 1999.
2. Мерфи К. Машинное обучение: вероятностный подход. – М.: Вильямс, 2015.
3. Фридман Дж., Хасти Т., Тибшirани Р. Основы статистического обучения. – М.: Springer, 2011.
4. Сюй К., Ху В., Лесковец Дж., Егерка С. «Насколько мощны графовые нейронные сети?» // Материалы Международной конференции по обучению представлений (ICLR). – 2019.
5. Чжан И., Сюй Ч. «Обнаружение мошенничества в онлайн-транзакциях: обзор методов машинного обучения» // Expert Systems with Applications. 2021.
6. Бывшева Е. А., Дроздов Д. С. Методы выявления аномалий в финансовых транзакциях // Финансовая аналитика. – 2020.
7. Киселёв А. Н. Отмывание денежных средств: современные тенденции и методы выявления. – М.: Юрайт, 2019.
8. Лапшин В. А. Применение машинного обучения в задачах противодействия мошенничеству // Прикладная информатика. – 2022.
9. Кипф Т., Веллинг М. «Полунадзорная классификация с использованием графовых сверточных сетей» // Материалы Международной конференции ICLR. – 2017.

