

Безопасность ИИ

Встреча рабочей группы

Управление информационной безопасности,
Ассоциация ФинТех

12 февраля 2025



01

Итоги работы за 2024 год



Результаты 2024

1. Сформирован перечень угроз информационной безопасности ИИ при разработке и применении ИИ в финтех-организациях.
2. Предложен классификатор угроз по этапам жизненного цикла решения на основе ИИ.
3. Разработан фреймворк ИБ ИИ для связки угроз и мер защиты (в формате технических мер, компетенций и процессов).
4. Сформирован набор компетенций в области безопасности ИИ для подразделений безопасности для минимизации угроз ИБ ИИ.

Индустриальный фреймворк по ИИ

Индустриальный фреймворк безопасного применения ИИ:

- Набор принципов, практик, подходов и методов для минимизации рисков и обеспечения безопасного применения решений на основе ИИ в финтехе.
- Включает в себя **технологические инструменты (Технологии), практики (Процессы) и компетенции (Люди).**

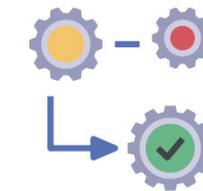
Для чего нужен фреймворк:

- консолидация лучшего опыта и практик по минимизации угроз ИБ ИИ.
- обеспечение диалога финтеха с технологическими организациями и разработчиками инструментов.
- систематизация подходов к анализу безопасности ИИ-решений.

Индустриальный фреймворк по ИИ. Как выстроен?



Индустриальный фреймворк по ИИ. Типы мер.



ПРОЦЕССЫ



ТЕХНОЛОГИИ



ПЕРСОНАЛ

- Внедрение дополнительных процессов проверки качества моделей
- Внедрение процессов контроля за тюнингом модели
- и т.д.
- Внедрение инструментов отслеживания вывода моделей
- Внедрение инструментов выявления галлюцинаций моделей
- и т.д.
- Повышение экспертизы сотрудника в определенной области
- Внедрение отдельных ролей в ИБ (например, промт-инженер)
- и т.д.

Индустриальный фреймворк по ИИ. Пример

| Домен | Угроза | Объект воздействия (данные, модель, инфраструктура) | Описание мер минимизации | Меры минимизации | | |
|---------------------|---------------------------------------|--|--|--|---|--|
| | | | | Люди | Технологии | Процессы |
| Обеспечение данными | Отсутствие классификации данных | Данные | <ol style="list-style-type: none"> 1. Внедрение многоуровневой системы классификации данных с четкими категориями, основанными на важности и конфиденциальности данных. 2. Обучение сотрудников на регулярной основе для повышения квалификации в правильной классификации данных. 3. Создание регламентов и автоматических инструментов для облегчения классификации новых данных в процессе их поступления. 4. Регулярный аудит классификации данных для выявления несоответствий и корректировки процесса. 5. Интеграция классификации данных в системы управления данными для автоматической сортировки по категориям. | <ol style="list-style-type: none"> 1. Специалисты по управлению данными и ML-инженеры, владеющие методологиями классификации и принципами защиты конфиденциальных данных. 2. Аналитики данных, способные правильно применять правила классификации к вновь поступающим наборам данных. 3. Офицеры по комплаенс, осуществляющие регулярный аудит и корректировку схем классификации. | <ol style="list-style-type: none"> 1. Системы DLP для контроля данных 2. Средства каталогизации данных для управления данными и тегами. 3. Инструменты для автоматизации классификации | <ol style="list-style-type: none"> 1. Пересмотр политик классификации данных в соответствии с требованиями бизнеса и регуляторов. 2. Обучение персонала принципам и практикам классификации данных. 3. Автоматизированные процедуры маркировки вновь поступающих данных и периодический аудит корректности меток. |
| | Использование данных низкого качества | Данные | <ol style="list-style-type: none"> 1. Внедрение автоматизированных систем очистки данных для выявления и исправления ошибок, пропусков или аномалий. 2. Проведение регулярных проверок и тестов качества данных перед их использованием в моделях ИИ. 3. Разработка стандартов качества данных и внедрение мониторинга для выявления несоответствий. 4. Обеспечение прозрачности источников данных с проверкой их достоверности перед их включением в обучение. 5. Создание резервных систем для хранения качественных данных, на которые можно ссылаться при возникновении проблем с основным источником. 6. Применение механизмов обратной связи для пользователей и партнеров, чтобы оперативно выявлять и устранять проблемы с качеством данных. | <ol style="list-style-type: none"> 1. Специалисты по качеству данных, владеющие методами очистки, валидации и нормализации данных. 2. ML-инженеры, способные интегрировать фильтры и проверки качества на этапе подготовки данных. 3. Аналитики и кураторы данных, ответственные за мониторинг и документирование источников данных | <ol style="list-style-type: none"> 1. Инструменты оценки качества данных 2. Средства очистки и нормализации данных 3. Инструменты мониторинга качества данных | <ol style="list-style-type: none"> 1. Внедрение стандартов качества данных и регулярный аудит источников. 2. Непрерывный мониторинг качества данных с уведомлениями при нарушениях критериев качества. 3. Процессы обратной связи от пользователей и партнеров для оперативного устранения проблем. |
| | Отсутствие версионирования данных | Данные | <ol style="list-style-type: none"> 1. Внедрение системы контроля версий данных с возможностью восстановления предыдущих версий и отслеживания всех изменений. 2. Автоматизация резервного копирования данных с разделением хранения разных версий для предотвращения потерь. 3. Введение строгих протоколов на внесение изменений в данные, автоматическим отслеживанием и документированием всех изменений. 4. Интеграция системы управления версиями данных с основными бизнес-процессами для своевременной реакции на возможные ошибки. 5. Регулярное тестирование систем версионирования на устойчивость и правильность работы. | <ol style="list-style-type: none"> 1. Специалисты по данным, владеющие системами контроля версий данных 2. MLOps-специалисты, умеющие настраивать процессы CI/CD с версионированием. 3. Специалисты ИБ, определяющие политики версионирования и хранения исторических наборов данных. | <ol style="list-style-type: none"> 1. Системы версионирования данных 2. Хранилища с поддержкой версионирования 3. Средства шифрования и цифровой подписи для отслеживания изменений данных | <ol style="list-style-type: none"> 1. Бэкап и проверка целостности версионных репозиторий. 2. Периодическое тестирование и валидация систем версионирования. |

02

Предложения на 2025 год



Предложения на 2025 год

1. Сформировать карту рисков ИБ ИИ для финтех-организаций.
2. Доработать фреймворк (расширить перечень мер защиты техническими мерами - инструментами, компетенциями сотрудников, процессами).
3. Сформировать базу MLSecOps инструментов и кейсов применения мер защиты ИИ на основе экспертизы участников АФТ (для развития центра компетенции АФТ по ИИ).

03

Формирование карты рисков



Формирование карты рисков. Для чего?

1. Выявление и классификация рисков

Определение ключевых рисков, связанных с использованием ИИ в финансовой сфере, в соответствии с требованиями нормативных актов.

2. Оценка уровня риска

Разработка количественных и качественных показателей для оценки вероятности возникновения и уровня воздействия выявленных рисков.

3. Приоритизация рисков

Визуализация рисков с учетом их значимости, позволяющая определить приоритеты для минимизации угроз.

4. Разработка мер управления рисками

Определение стратегий снижения рисков, включая меры контроля, мониторинга и реагирования.

5. Интеграция в процесс управления ИБ

Встраивание карты и матрицы рисков в общую систему управления информационной безопасностью организации.



Сформированная карта рисков в соотнесении с перечнем угроз ИБ ИИ даст возможность участникам АФТ повысить качество и скорость проведения оценки рисков за счет консолидированной экспертизы представителей отрасли.

Управление рисками ИБ

Зарубежные

- Стандарт ISO/IEC 27005 «Менеджмент риска информационной безопасности»
- NIST SP 800-37 Фреймворк управления рисками для ИС и организаций: жизненный цикл систем для обеспечения безопасности и конфиденциальности
- NIST SP 800-30 Руководство по проведению оценки риска
- NIST SP 800-53 Контроль безопасности и конфиденциальности в ИС и организациях

Отечественные

ГОСТ Р ИСО/МЭК 27005-2021:

Русскоязычная адаптация международного стандарта ISO/IEC 27005. Содержит описание процессов управления рисками информационной безопасности.

Специфические требования для финсектора:

- Положение Банка России № 716-П
- Рекомендации Банка России по применению подходов к оценке рисков

Виды операционного риска (по Положению Банка России № 716-П)

Риск информационной безопасности: угрозы, обусловленные недостатками в процессах обеспечения информационной безопасности, включая технологические мероприятия и программное обеспечение.

Риск информационных систем: отказы или нарушения функционирования информационных систем, а также несоответствие их функциональных возможностей потребностям кредитной организации.

Правовой риск: возникновение убытков вследствие несоблюдения кредитной организацией требований правовых актов, договорных обязательств, а также вследствие нарушения правовых норм, регулирующих деятельность кредитной организации.

Риск ошибок в управлении проектами: недостатки и нарушения в процессах управления проектной деятельностью, направленной на изменение систем функционирования и поддержания работоспособности кредитной организации.

Риск ошибок в управленческих процессах: недостатки и нарушения внутренних процессов, а также принятия решений по банковским операциям и внутрихозяйственной деятельности.

Риск ошибок в процессах внутреннего контроля: недостатки и нарушения системы внутреннего контроля, включая несоблюдение правил противодействия легализации доходов, полученных преступным путем, и финансированию терроризма.

Модельный риск: риск ошибок в процессах разработки, проверки, адаптации, приёмки и применения методик количественных и качественных моделей оценки активов, рисков и иных показателей, используемых при принятии управленческих решений.

Риск потерь средств клиентов и третьих лиц: вследствие нарушения кредитной организацией кодексов профессиональной этики, рыночных практик и правил поведения при продаже финансовых инструментов и услуг.

Операционный риск платежной системы: риск возникновения убытков или иных негативных последствий для участников платежной системы вследствие недостатков или ошибок в процессах, системах, человеческих действиях или внешних событиях, связанных с функционированием платежной системы.

Обработка рисков

Принятие.

Руководство берет на себя ответственность и принимает риски, инфраструктура организации продолжает функционировать.

Избегание.

Риск устраняется путем устранения причин его возникновения или существования.

Минимизация/Принятие мер.

В организации применяются компенсирующие организационные и технические меры для снижения влияния риска до допустимого уровня.

Разделение.

Стратегия подразумевает распределение угроз и ответственности между разными уровнями инфраструктуры — или привлечение третьей заинтересованной стороны для уменьшения влияния риска.

Передача.

Ответственность за реализацию и последствия риска полностью передается на сторону, способную обработать риск эффективнее. В качестве примера можно выделить страхование рисков или привлечение сторонних сервисов, например SOC.

Пример соотнесения угроз ИИ с рисками (в соотв. с Положением 716-П)

Злоупотребление доступом к финансовым данным

- **Риск информационной безопасности:** Несанкционированный доступ к данным из-за недостатков в защите информации.
- **Риск ошибок в процессах внутреннего контроля:** Недостаточная система внутреннего контроля может допустить злоупотребления.
- **Правовой риск:** Нарушение законодательства о защите данных (например, персональных данных) может повлечь юридические последствия.

Манипуляция рыночной информацией с помощью LLM

- **Риск информационной безопасности:** Использование генеративных моделей для манипуляций может угрожать целостности рыночной информации.
- **Риск потерь средств клиентов и третьих лиц:** Такие манипуляции могут повлиять на доверие клиентов и партнеров.
- **Правовой риск:** Нарушение законодательства о манипуляциях на рынке.

Галлюцинации (ошибки генеративных моделей)

- **Риск ошибок в управленческих процессах:** Использование ошибочных данных для принятия решений.
- **Риск информационных систем:** Некорректная работа алгоритмов может быть связана с недостатками в их реализации или интеграции.

Отсутствие разграничения прав доступа

- **Риск информационной безопасности:** Недостатки в разграничении доступа создают угрозы утечки данных.
- **Риск ошибок в процессах внутреннего контроля:** Проблемы с разграничением доступа указывают на слабости системы внутреннего контроля.
- **Риск ошибок в управленческих процессах:** Могут возникнуть ошибки в процессах, связанных с обеспечением безопасности данных.

Использование устаревших данных

- **Риск ошибок в управленческих процессах:** Ошибки при принятии решений из-за использования устаревшей информации.
- **Риск информационных систем:** Несвоевременное обновление данных может быть следствием недостатков в информационных системах.

Угроза безопасности цепочки поставок

- **Риск информационной безопасности:** Уязвимости в цепочке поставок могут быть использованы для компрометации информационных активов.
- **Риск нарушений операционной устойчивости:** Проблемы с поставщиками могут нарушить стабильность операций.
- **Правовой риск:** Несоответствие поставщиков регуляторным требованиям может привести к санкциям.

04

Формирование перечня мер защиты



Меры защиты в фреймворке ИБ ИИ

Для чего добавлять и детализировать меры защиты?

1. Идентификация новых угроз и средств защиты от них

Анализ актуальных атак на ИИ-системы, включая подмену данных, эксплуатацию уязвимостей моделей и атак на конфиденциальность.

2. Оценка применимости

Определение технологических решений, их совместимости с регуляторными требованиями и возможностью интеграции в финансовые ИИ-системы.

3. Создание методологии выбора решений

Разработка критериев и рекомендаций по применению технологических решений в зависимости от специфики ИИ-моделей, архитектур и уровней критичности данных.

Технические меры (пример)

Отсутствие классификации данных

Инструменты и меры:

1. Frameworks: Внедрение корпоративных политик классификации данных (например, выделение уровней: общедоступные, для внутреннего использования, конфиденциальные, строго конфиденциальные).
2. DLP-системы (Data Leak Prevention) — Обнаруживает и классифицирует конфиденциальные данные для предотвращения их несанкционированного распространения (утечку)
3. Интеграция с MDM (Master Data Management): Средства управления данными для централизованного контроля классификации.

Использование данных низкого качества

Инструменты и меры:

1. Data Quality Assessment Tools: Great Expectations, Soda, Tecton или другие решения для профилирования и валидации данных.
2. Автоматизированный мониторинг качества: Метрики качества (missing values, outliers) с триггерами оповещений при отклонениях.

Отсутствие версионирования данных

Инструменты и меры:

1. DVC (Data Version Control) или Git LFS для версионирования больших наборов данных.
2. MLflow Data Registry, LakeFS, Delta Lake для отслеживания версий в хранилищах данных.
3. Контрольные суммы (hash-суммы) для валидации неизменности версий.

Компетенции (пример)

| Роль | Компетенции: | Задачи: |
|--|--|---|
| Инженер по информационной безопасности | <ol style="list-style-type: none"> 1. Знание принципов сетевой и прикладной безопасности, протоколов шифрования. 2. Опыт работы с SIEM/SOAR, WAF, IAM-системами. 3. Навыки анализа уязвимостей, проведения пентестов, использования DLP и систем обнаружения аномалий. | <ol style="list-style-type: none"> 1. Настройка систем защиты API, управление доступами к данным и моделям. 2. Обнаружение и предотвращение кибератак (DDoS, отравление данных, проникновения). 3. Регулярный аудит конфигураций, обновление политики безопасности согласно текущим угрозам. |
| Специалист по управлению данными и качеством | <ol style="list-style-type: none"> 1. Понимание принципов классификации данных, требований к их качеству и правовых норм обработки 2. Опыт работы с инструментами профилирования данных, оценкой качества, DVC для версионирования. 3. Знание методологий очистки, нормализации, а также мониторинга целостности данных | <ol style="list-style-type: none"> 1. Разработка и внедрение стандартов качества данных, регулярная проверка на наличие пропусков, ошибок и устаревших данных. 2. Обеспечение соответствия данных регуляторным требованиям. 3. Введение механизмов классификации, валидации |
| MLSecOps-инженер | <ol style="list-style-type: none"> 1. Глубокое понимание CI/CD и DevOps-практик применительно к ML-моделям. 2. Знание инструментов контейнеризации и оркестрации. 3. Умение настраивать конвейеры обучения, тестирования и развертывания моделей с фокусом на безопасность. | <ol style="list-style-type: none"> 1. Автоматизация развёртывания моделей с учётом требований безопасности и регуляторных норм. 2. Настройка мониторинга производительности и стабильности моделей. 3. Регулярная проверка устойчивости конвейера к сбоям и угрозам |

Пример доработки фреймворка

| Угроза | Объект воздействия (данные, модель, инфраструктура) | Описание мер минимизации |
|---------------------------------|---|---|
| Отсутствие классификации данных | Данные | <ol style="list-style-type: none"> 1. Внедрение многоуровневой системы классификации данных с четкими категориями, основанными на важности и конфиденциальности данных. 2. Обучение сотрудников на регулярной основе для повышения квалификации в правильной классификации данных. 3. Создание регламентов и автоматических инструментов для облегчения классификации новых данных в процессе их поступления. 4. Регулярный аудит классификации данных для выявления несоответствий и корректировки процесса. 5. Интеграция классификации данных в системы управления данными для автоматической сортировки по категориям. |

| Меры минимизации | | |
|--|---|--|
| Люди | Технологии | Процессы |
| <ol style="list-style-type: none"> 1. Специалисты по управлению данными и ML-инженеры, владеющие методологиями классификации и принципами защиты конфиденциальных данных. 2. Аналитики данных, способные правильно применять правила классификации к вновь поступающим наборам данных. 3. Офицеры по комплаенс, осуществляющие регулярный аудит и корректировку схем классификации. | <ol style="list-style-type: none"> 1. Системы DLP для контроля данных 2. Средства каталогизации данных для управления данными и тегами. 3. Инструменты для автоматизации классификации 4. Инструмент 1 5. Инструмент 2 6. Инструмент 3 | <ol style="list-style-type: none"> 1. Пересмотр политик классификации данных в соответствии с требованиями бизнеса и регуляторов. 2. Обучение принципам и практикам классификации данных. 3. Автоматизированные процедуры маркировки вновь поступающих данных и периодический аудит корректности меток. |

05

Предложения от отрасли



Предложения к подходам к обеспечению ИБ ИИ

1. Направить от экспертов Ассоциации предложения в Банк России по подходам к обеспечению безопасности применения ИИ на финансовом рынке и формированию подходов по регулированию вопросов ИБ искусственного интеллекта в финансовом секторе, чтобы

- подчеркнуть актуальность данной темы для финансового и финтех-секторов,
- экспертам отрасли включиться на ранней стадии в процесс формирования практической составляющей методологии регулятора,
- предложить регулятору взвешенный подход между безопасностью и инновациями, подкрепленный практическими рекомендациями, проработанными на площадке АФТ.

2. Перечень предложений в виде письма направить в конце 1 квартала 2025 года.