



Проблема конфиденциальности данных в государственных информационных системах с использованием ИИ

Пермяков Руслан Анатольевич

Советник директора по инновациям



Критическая проблема



- Рост роли ГИС в жизни граждан
Государственные информационные системы стали основой предоставления услуг: медицина, образование, налогообложение, регистрация прав, социальная поддержка.
- Интеграция ИИ в ГИС
Применение ИИ-моделей для принятия решений, обработки больших данных и автоматизации государственных процессов увеличивает зависимость качества услуг от технологий.
- Расширение объема и детализации персональных данных
Современные ГИС аккумулируют не только идентификационные данные, но и поведенческую информацию, биометрию, финансовые и медицинские сведения.
- Уязвимость традиционных методов защиты
Классические меры, ориентированные на защиту статичных систем, становятся недостаточными в условиях динамических самообучающихся ИИ-моделей.
- Риски снижения доверия к государству
Утечки данных, ошибки автоматизированных решений и непрозрачность работы ИИ могут привести к потере доверия граждан к цифровым государственным сервисам.
- Необходимость обеспечения доверия к результатам работы ИИ
Требуется не только защищать инфраструктуру, но и гарантировать объяснимость, корректность и проверяемость решений, принимаемых на основе ИИ в государственных системах.



Как ИИ меняет цифровое государство.



- Автоматизация принятия решений
ИИ-системы участвуют в выдаче государственных услуг, валидации документов, выявлении несоответствий и рисков без непосредственного участия человека.
- Масштабная обработка персональных данных
ИИ позволяет анализировать большие объемы чувствительных данных, строить профили граждан, выявлять скрытые взаимосвязи между событиями и субъектами.
- Динамичность моделей и данных
ИИ-модели могут изменяться в процессе эксплуатации (самообучение, дообучение на новых данных), что затрудняет контроль, аудит и объяснение их поведения.
- Новые каналы утечки информации
Утечки могут происходить не только через классические механизмы (доступ, хранение), но и через поведение обученных моделей (например, утечки обучающих данных через ответы моделей).
- Усиление влияния ошибок данных
Неточности и искажения в исходных данных могут незаметно влиять на работу систем ИИ, приводя к ошибкам при принятии решений или к дискриминации граждан.
- Сложности обеспечения прозрачности и ответственности
Автоматизация решений без возможности их интерпретации снижает контроль государства за процессами и затрудняет обоснование законности действий перед гражданами.



Ключевые угрозы для ГИС с ИИ



- Угрозы конфиденциальности:
 - Утечки персональных данных через поведение ИИ-моделей;
 - Деанонимизация обезличенных данных;
 - Ошибки обобщения;
 - Атаки на модели;
 - Data poisoning.
- Угрозы целостности:
 - Ошибки и манипуляции в данных, используемых для обучения ИИ;
 - Нарушение целостности результатов работы моделей.
- Угрозы доступности:
 - Атаки на инфраструктуру ИИ в ГИС (DDoS, сбои моделей);
 - Недоступность ключевых сервисов из-за ошибок в автоматическом принятии решений.
- Угрозы достоверности:
 - Выдача недостоверных результатов ИИ-обработки;
 - Зависимость качества решений от скрытых смещений в данных.
- Угрозы управляемости:



Традиционные меры защиты в ГИС



- Защита конфиденциальности:
 - Обезличивание персональных данных
 - Контроль доступа к информации
 - Шифрование данных при хранении и передаче
- Защита целостности:
 - Контроль версий данных
 - Аудит изменений
 - Механизмы цифровых подписей
- Обеспечение доступности:
 - Резервное копирование и восстановление данных
 - Защита от DDoS-атак
 - Мониторинг состояния сервисов
- Поддержка достоверности:
 - Проверка источников данных
 - Верификация поступающих данных вручную или автоматизированно
- Управляемость систем:



Почему этих мер недостаточно



- По угрозам конфиденциальности:
 - Обезличивание больше не гарантирует анонимность: ИИ может восстанавливать личные данные через корреляции.
 - Шифрование защищает транспорт и хранение, но не предотвращает утечки через поведение моделей.
- По угрозам целостности:
 - Классические механизмы контроля версий не учитывают динамические изменения моделей ИИ при обучении на данных.
 - Возможны атаки через незаметные изменения обучающих выборок (data poisoning).
- По угрозам доступности:
 - Рост сложности ИИ-систем увеличивает уязвимость к новым типам атак, включая целевые атаки на алгоритмы.
- По угрозам достоверности:
 - Проверка источников данных не гарантирует достоверность выводов ИИ из-за возможных смещений в данных или переобучения.
- По угрозам управляемости:
 - Стандартные механизмы разграничения прав доступа не обеспечивают контроль над «внутренней логикой» самообучающихся систем.



Доверенная информационная система



- Защита конфиденциальности:
 - Применение дифференциальной приватности и технологий защиты данных на этапе обучения ИИ.
 - Обязательное тестирование устойчивости обезличивания к деанонимизации.
- Защита целостности:
 - Контроль целостности не только данных, но и моделей ИИ после обучения.
 - Методы выявления атак на данные обучения (data poisoning detection).
- Обеспечение доступности:
 - Защита устойчивости ИИ-сервисов к новым типам атак (например, adversarial attacks).
 - Дублирование критических моделей и процедур отката.
- Поддержка достоверности:
 - Обязательная проверка моделей на наличие скрытых смещений и ошибок (bias & fairness testing).
 - Постоянная валидация результатов ИИ на актуальных данных.
- Управляемость систем:
 - Интерпретируемость и объяснимость решений ИИ (Explainable AI).
 - Прозрачность процессов обучения и функционирования моделей.
 - Полный аудит цепочки обработки данных и моделей.



Новые требования к безопасности



- Защита конфиденциальности:
 - Применение дифференциальной приватности и технологий защиты данных на этапе обучения ИИ.
 - Обязательное тестирование устойчивости обезличивания к деанонимизации.
- Защита целостности:
 - Контроль целостности не только данных, но и моделей ИИ после обучения.
 - Методы выявления атак на данные обучения (data poisoning detection).
- Обеспечение доступности:
 - Защита устойчивости ИИ-сервисов к новым типам атак (например, adversarial attacks).
 - Дублирование критических моделей и процедур отката.
- Поддержка достоверности:
 - Обязательная проверка моделей на наличие скрытых смещений и ошибок (bias & fairness testing).
 - Постоянная валидация результатов ИИ на актуальных данных.
- Управляемость систем:
 - Интерпретируемость и объяснимость решений ИИ (Explainable AI).
 - Прозрачность процессов обучения и функционирования моделей.
 - Полный аудит цепочки обработки данных и моделей.



Доверенная информационная система



Доверенная ИС отвечает на вопрос:

- «Почему можно доверять её работе и результатам?»

Ключевые компоненты:

- Прозрачность
- Обоснованность
- Защита ПД
- Проверяемость решений ИИ



Практические меры для доверия к ГИС с

ИИ

Сертификация моделей ИИ

Проведение формальных проверок корректности моделей и тестирование на устойчивость к атакам, включая проверки на утечки обучающих данных и манипуляции.

- Тестирование и проверка процедур обезличивания
Обязательная оценка качества анонимизации данных с использованием специализированных методов анализа риска деанонимизации.
- Интеграция технологий Privacy-Enhancing Technologies (PETs)
Применение дифференциальной приватности, федеративного обучения, гомоморфного шифрования для защиты данных на всех этапах их обработки.
- Аудит данных и процессов обучения
Ведение полных журналов событий, контроль источников данных, отслеживание изменений в обучающих выборках и контроль среды обучения.
- Повышение интерпретируемости моделей (Explainable AI)
Разработка и использование моделей, обеспечивающих понятное объяснение принимаемых решений для администраторов и пользователей.
- Разработка и соблюдение стандартов доверенного ИИ
Введение обязательных требований к прозрачности, обоснованности и контролируемости систем с ИИ в государственных информационных системах.
- Управление жизненным циклом моделей
Регулярное переобучение, тестирование и ревизия моделей ИИ в процессе их эксплуатации для предотвращения деградации качества и устойчивости.





Основные проблемы сегодня



- **Отсутствие стандартов доверенного ИИ для государственных информационных систем**
Нет утвержденных требований к прозрачности, объяснимости, устойчивости и безопасности моделей ИИ в ГИС.
- **Недостаточная защищенность обезличенных данных**
Обезличивание выполняется по старым методикам, которые не учитывают современные угрозы деанонимизации с помощью ИИ.
- **Сложности контроля за моделями ИИ в процессе эксплуатации**
Отсутствие процедур аудита, мониторинга деградации качества моделей и выявления скрытых отклонений.
- **Дефицит компетенций в области приватности и безопасности ИИ**
Недостаточное количество специалистов, способных сочетать знания в области информационной безопасности, ИИ и защиты персональных данных.
- **Рост зависимости от закрытых и непрозрачных технологий**
Использование коммерческих ИИ-решений без полного контроля над архитектурой и данными увеличивает риски для безопасности ГИС.
- **Баланс между эффективностью ИИ и защитой конфиденциальности**
Давление на максимизацию эффективности ИИ-моделей часто приводит к ослаблению мер защиты данных и снижению прозрачности.



Куда двигаться дальше



- Стандарты тестирования доверия
- Новые методы обезличивания
- Интеграция с технологиями гарантированной защиты данных
- Междисциплинарные команды



Спасибо за внимание.

Пермяков Руслан Анатольевич

+7(913)916-21-56, , @pransk

Институт вычислительной математики и математической геофизики Сибирского отделения РАН