



АССОЦИАЦИЯ
БОЛЬШИХ ДАННЫХ

ТЕСТИРОВАНИЕ МЕТОДОВ ЗАЩИТЫ ИНФОРМАЦИИ

ВЫЧИСЛИТЕЛЬНЫЕ ЭКСПЕРИМЕНТЫ ДЛЯ ТЕСТ-КЕЙСОВ
«УТЕЧКА БАНКОВСКОЙ ИНФОРМАЦИИ» И «МАРКЕТИНГОВОЕ КАСАНИЕ»

H

F

Labs

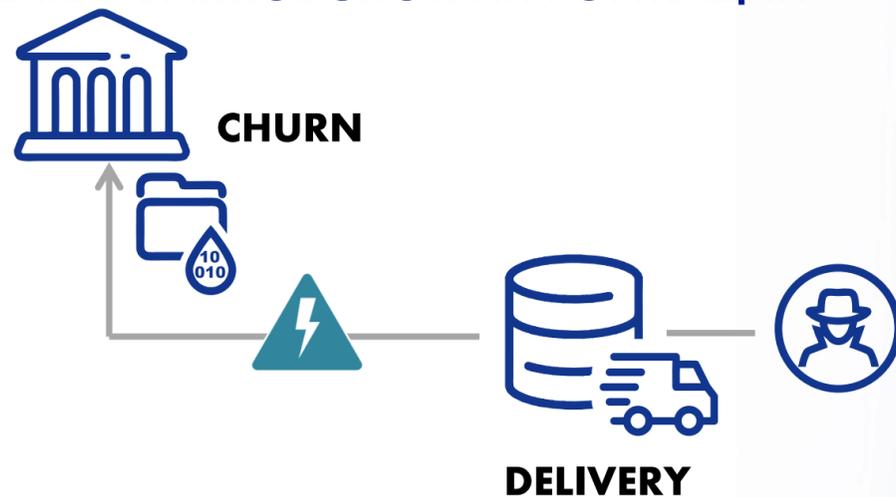
ПРЕДПОСЫЛКИ

Ассоциация Больших Данных совместно с **HFLabs** провела серию численных экспериментов по отработке риск-методики в реальных задачах обработки данных с включениями персональной информации.

HFLABS владеет востребованным продуктом «**МАСКИРОВЩИК**», предназначенным для маскирования данных и внесения шума на основе заготовленных справочников и собственной библиотеки алгоритмов.

В рамках тестирования специалисты Ассоциации подготовили тестовые наборы данных, которые затем были обработаны МАСКИРОВЩИКОМ и протестированы в рамках риск-модели Ассоциации. Такое тестирование включало в себя построение поверхностей атак, оценку риска различными способами, оценку качества, проведение итераций по балансировке качества и защищенности.

КЕЙС А: УТЕЧКА БАНКОВСКОЙ ИНФОРМАЦИИ



КЕЙС В: МАРКЕТИНГОВОЕ КАСАНИЕ



Целями тестирования были проверка модели риска данных с учетом работы МАСКИРОВЩИКА и разработка эталонных методов защиты конфиденциальной информации в рамках выделенных сценариев взаимодействия.

КЛЮЧЕВЫЕ ВОПРОСЫ

1
Как связаны k-anonymity
(характеристика набора данных)
и риски атак (характеристика
кибербезопасности)?

2
Как эффективно оценить риски
утечки информации с учетом
внешних источников?

3
Существуют ли простые
методы пересечения
данных без раскрытия
конфиденциальных
идентификаторов?

4
Как различные виды защиты влияют на
обобщенную модель информационной
утечки при работе с несколькими
источниками данных?

РИСК-МЕТОДИКА АССОЦИИ БОЛЬШИХ ДАННЫХ

КАСКАДНАЯ МОДЕЛЬ РИСКА

$$R_{total} = \sum_{i=1}^n \left(P(R_i) \cdot I(R_i) \cdot \prod_{j=1}^{i-1} P(R_j | R_{j-1}) \right) \Rightarrow P_{total} = P_{контекст} \times P_{данные}$$

Модель риска данных существенно зависит от класса методов защиты информации. Ассоциация построила фреймворк, выделяющий 6 классов для методов защиты, позволяющих рассматривать широкий спектр задач защиты конфиденциальности данных

КЛАССЫ МЕТОДОВ ЗАЩИТЫ

МЕТОДЫ ЗАЩИТЫ ДАННЫХ



✓ **Модель контекстных рисков**
Contextual Risk Assessment Model

$$P_{контекстные\ риски} = \frac{\sum_{j=1}^n \omega_j K_j}{\sum_{j=1}^n \omega_j}$$

РИСК-МОДЕЛЬ ПЕРСОНАЛЬНЫХ ДАННЫХ

Модель коммуникации

Модель угроз

Модель воздействия

АТАКИ



k-Anonymity Model
(l-diversity, t-Closeness)

$$P_{риски\ данных} = \frac{k}{\langle \bar{E} \rangle}$$



Модель псевдонимизации
Resource-Based Risk Model

$$P_{риски\ данных} = \frac{k}{\langle r|R \rangle}$$

$$P_{data} = w_1 \times P_{snglout} + w_2 \times P_{link} + w_3 \times P_{inf}$$

Выделение
Singling Out

$$P_{diff} = 1 - e^{-\epsilon}$$

Модель информационной утечки
Composite Risk Model
for Data Leakage

Связывание
Linkage

$$P_{link} = \frac{\sum_{i=1}^S \gamma_i}{N}$$

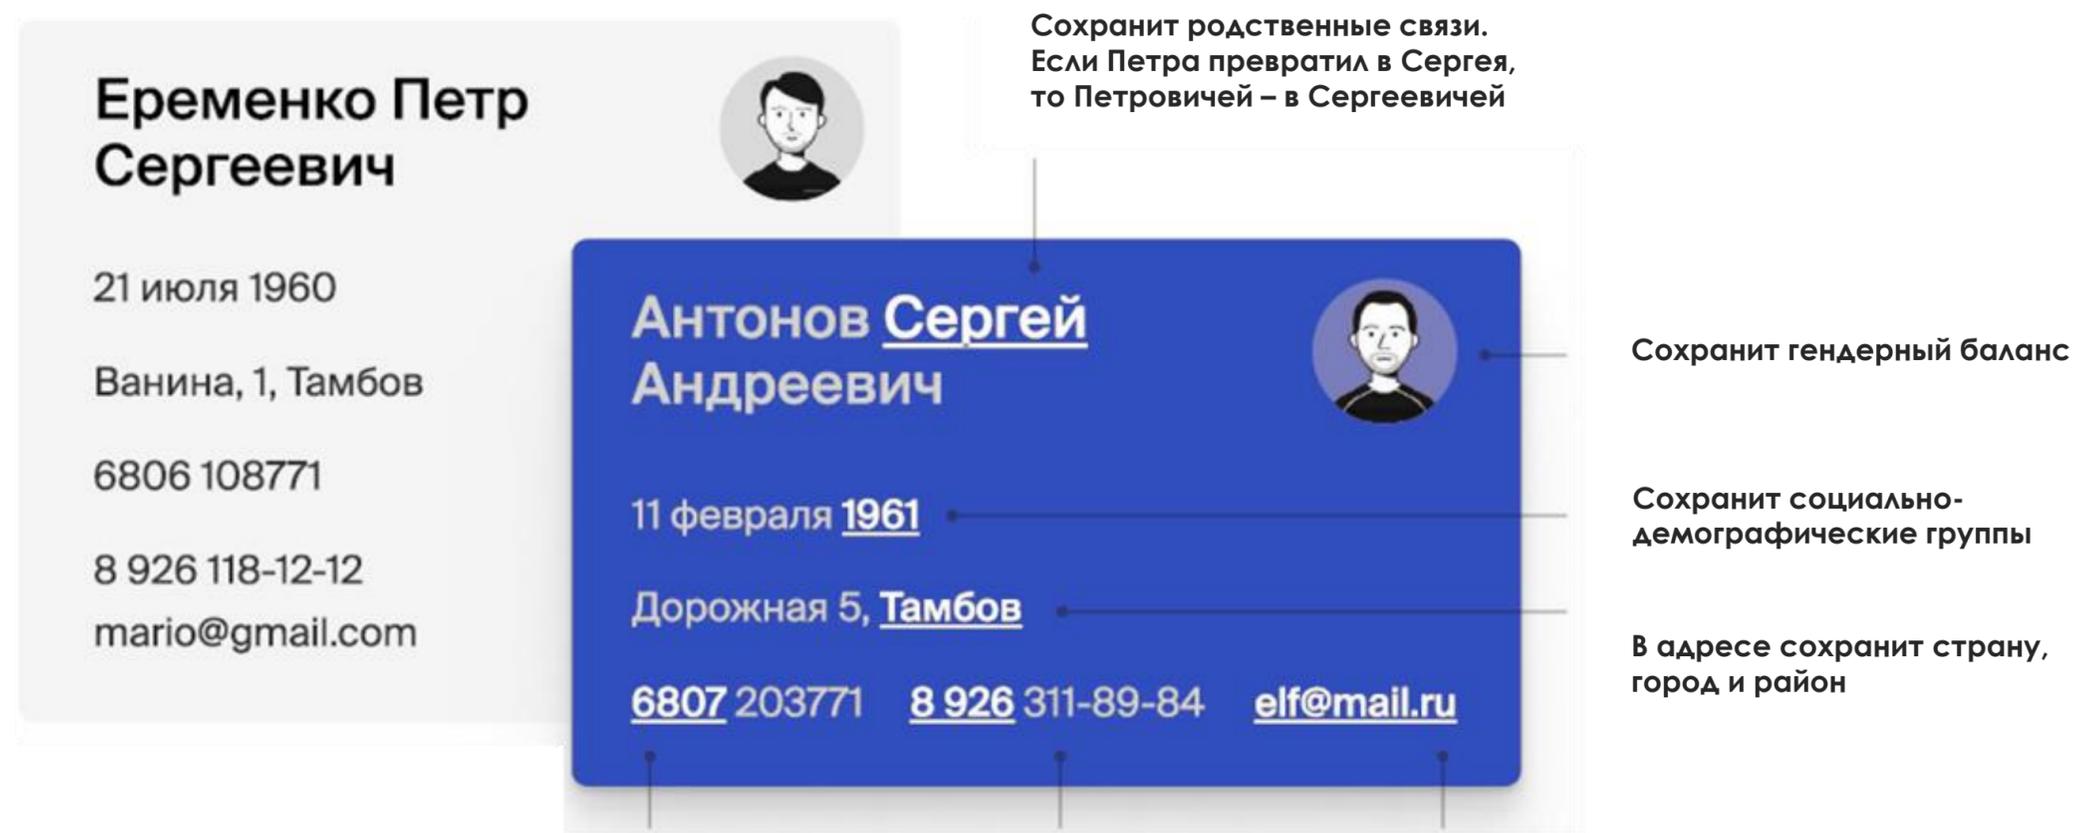
Вывод
Inference

$$P_{inf} = 1 - \frac{H(D')}{H(D)}$$

«МАСКИРОВЩИК». ПРОДУКТ ДЛЯ ОБЕЗЛИЧИВАНИЯ ДАННЫХ ОТ HFLABS

Физлица

КАК РАБОТАЕТ «МАСКИРОВЩИК»



H F Labs

Серию паспорта привяжет к году рождения, чтобы она прошла форматно-логический контроль

Оставит оператора и страну для номера телефона

Принимает домены электронных почт: рабочие, личные, одноразовые такими и останутся

«МАСКИРОВЩИК». ПРОДУКТ ДЛЯ ОБЕЗЛИЧИВАНИЯ ДАННЫХ ОТ HFLABS

Полезно и безопасно

- Безопасно обезличивает данные, путем случайных замен с учетом гибко настраиваемых правил.
- Сохранение структуры, семантической значимости и смысла.
Валидные данные, которые можно продолжать использовать в аналитике, тестировании, построении моделей.
- Консистентность при последовательном или параллельном обезличивании нескольких стендов. Для качества интеграционного тестирования.
- 19 лет опыт в качестве данных.
Раньше только стандартизировали, теперь и маскируем.
Под капотом те же уникальные алгоритмы.
Понимаем какие характеристики качества данных действительно важны.



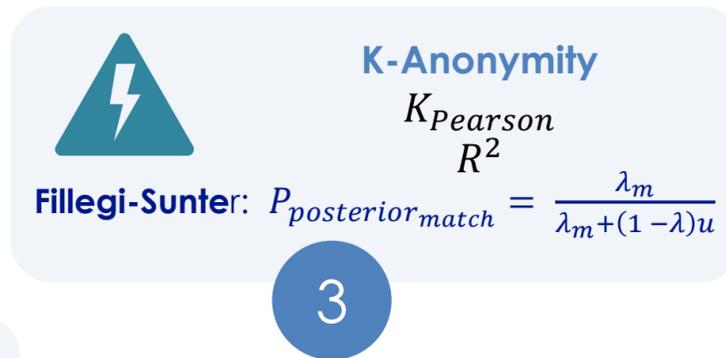
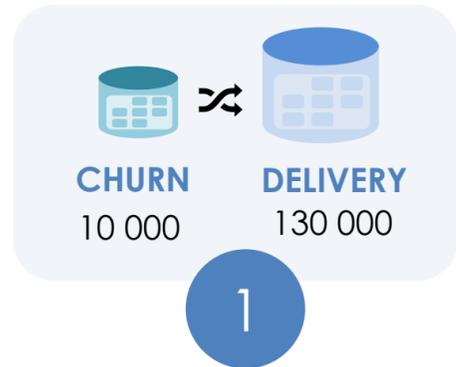
Удобно

- Горизонтальное и вертикальное масштабирование
- Возможность использования как отдельных сервисов, так и встроенного ETL
- Можно маскировать срезы данных по условию. В том числе инкремент.
- Поддержка различных источников и типов данных
- Возможность настройки алгоритмов маскирования в зависимости от бизнес сценария. В том числе кастомизация под уникальный запрос.
- Совместимость с другими системами посредством API

КЕЙС 1: УТЕЧКА БАНКОВСКОЙ ИНФОРМАЦИИ

Цель кейса - протестировать АТАКУ СВЯЗЫВАНИЯ обезличенного банковского набора с ранее утекшим набором интернет-доставки

ОСНОВНЫЕ ПОДХОДЫ:

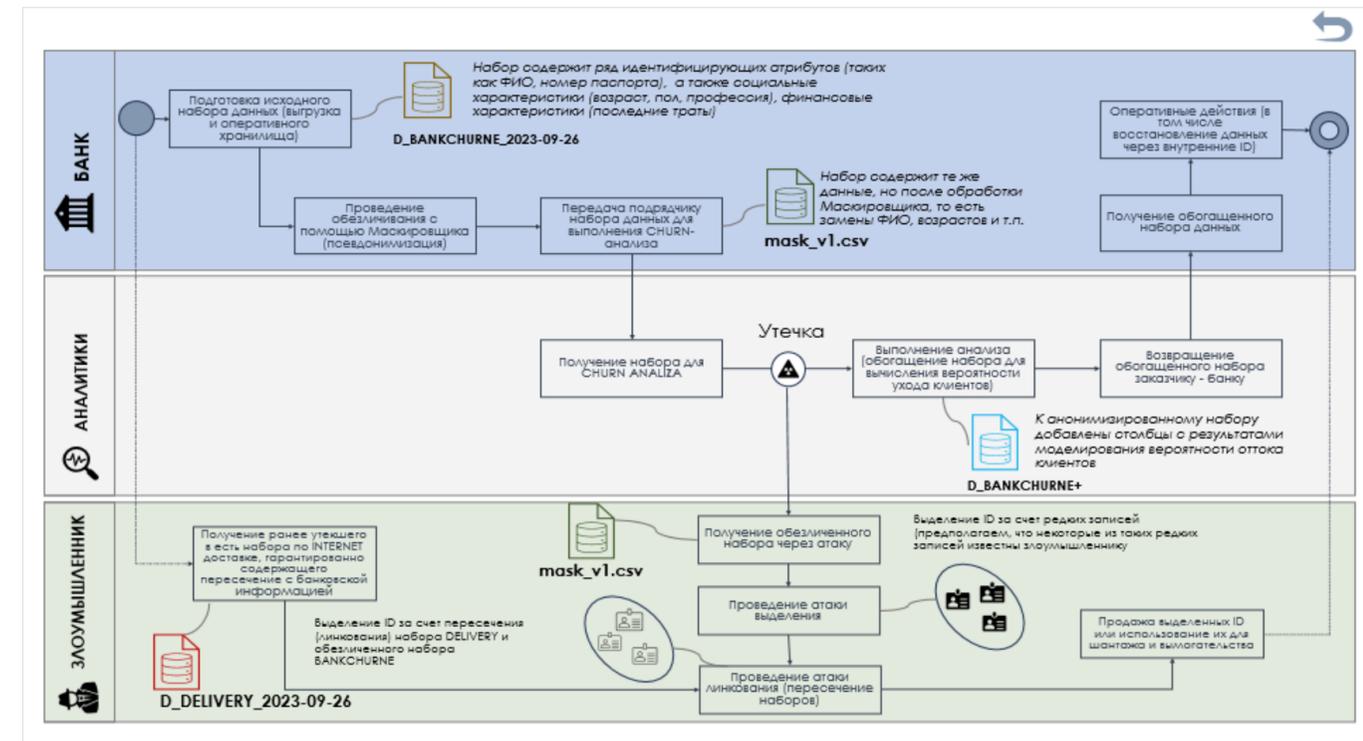


МЕТОДЫ:

- Обезличивание данных с помощью продукта "МАСКИРОВЩИК".
- Анализ качества через корреляцию Пирсона и метрики R²
- Симуляция атак по методу Fellegi-Sunter для вероятностного анализа риска.
- Оценка риска с использованием различных метрик (доверительный интервал Уилсона).

ПОЛУЧЕННЫЕ РЕЗУЛЬТАТЫ:

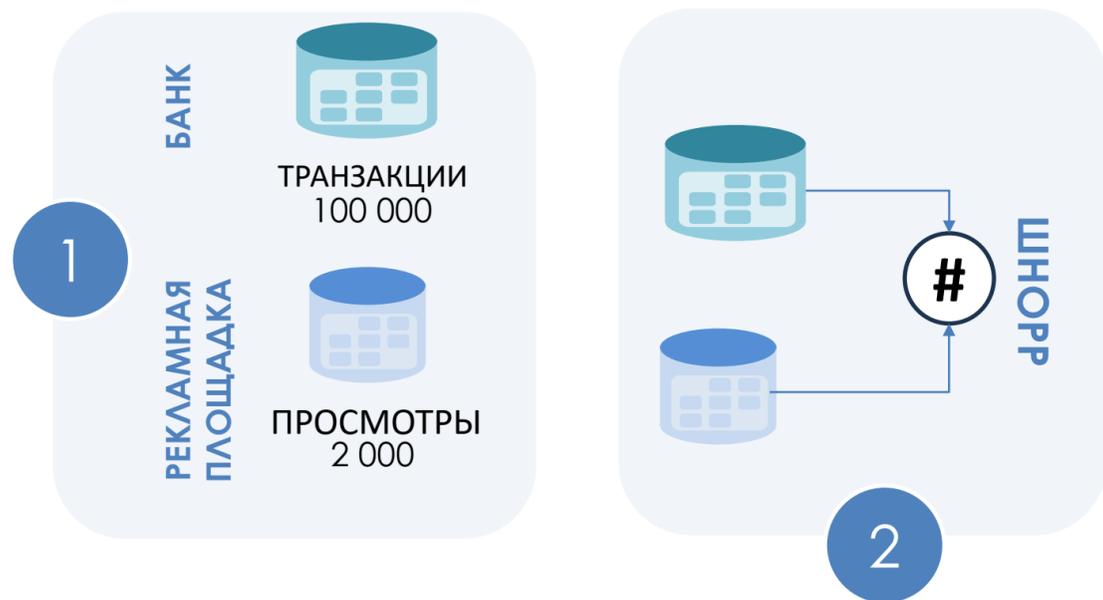
- Значительное **снижение риска повторной идентификации** данных после обезличивания.
- **Высокая корреляция** между исходными и обезличенными данными, что подтверждает их полезность для аналитики.
- Успешная **адаптация методики для различных сценариев атак** и защиты данных.



КЕЙС 2: МАРКЕТИНГОВОЕ КАСАНИЕ

Цель кейса - моделирование конфиденциального объединения данных рекламной площадки и набора с банковскими транзакциями для оценки эффективности рекламной кампании.

ОСНОВНЫЕ ПОДХОДЫ:



ИНФОРМАЦИОННАЯ УТЕЧКА (Выделение, Линкование, Вывод)

$K_{Pearson}$
KS-статистика
 R^2

CVPL: кластерно – векторная атака

$$\approx sim(c_i, c_j) = \frac{1}{|c_i| \cdot |c_j|} \sum_{x_p \in c_i} \sum_{x_q \in c_j} dist(x_p, x_q)$$

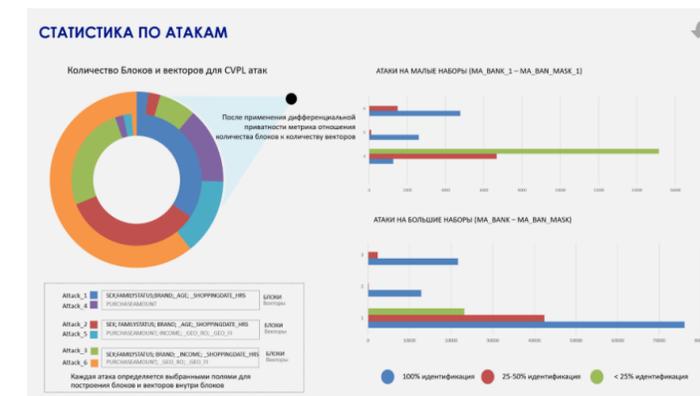
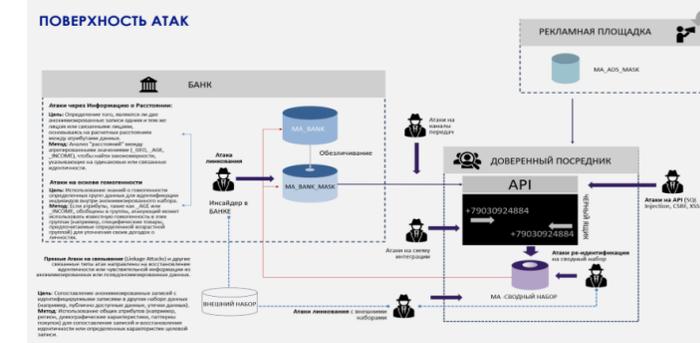
3

МЕТОДЫ:

- Обезличивание данных с помощью продукта "МАСКИРОВЩИК".
- Симуляция атак по методу CVPL.
- Анализ качества через корреляцию Пирсона, статистику Колмогорова-Смирнова и метрики R^2
- Оценка риска с использованием модели «УТЕЧКА ИНФОРМАЦИИ»

ПОЛУЧЕННЫЕ РЕЗУЛЬТАТЫ:

- Успешное **объединение** данных рекламной площадки и банка **без утечки** персональной информации.
- Обучение модели на обезличенных данных показало **высокую точность** прогнозирования конверсии.
- Значительное снижение рисков утечки данных при сохранении их полезности для маркетингового анализа (**дифференциальная конфиденциальность**).
- **CVPL** позволяет оценить максимальную вероятность атаки с использованием **любых доступных наборов данных**



АЛГОРИТМЫ И ПОДХОДЫ

В рамках численных экспериментов были использованы оригинальные подходы и алгоритмы:

ИНТЕГРАЦИЯ ПО МЕТОДУ ШНОРРА

- Использование протоколов доказательства с нулевым разглашением (Zero-Knowledge Proof, ZKP) для конфиденциального объединения данных.
- Протокол Шнорра обеспечивает доказательство принадлежности данных без раскрытия самих данных. Обеспечивает высокий уровень конфиденциальности и минимизацию риска утечки данных при объединении информации.
- Альтернатива более тяжелому методу PSI (Private Set Intersection), обеспечивая высокую безопасность при меньших ресурсных затратах.

CVPL (CLUSTER-VECTOR PCA LINKAGE)

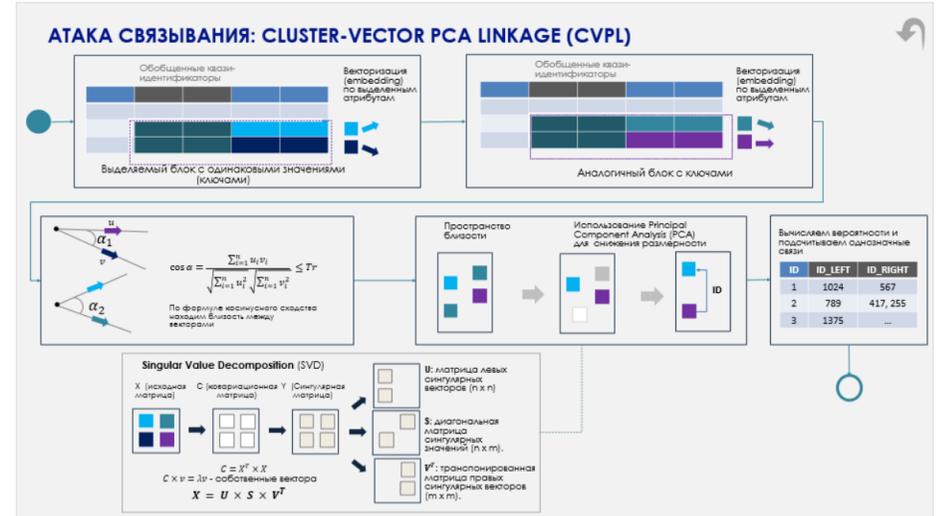
- Использование кластеризации данных и метода главных компонент (PCA) для уменьшения размерности данных.
- Векторизация данных для создания кластеров с последующим сравнением векторов внутри каждого кластера.
- Симуляция атак на обезличенные данные для оценки устойчивости к повторной идентификации.
- Позволяет выявить потенциальные уязвимости в схемах обезличивания и оптимизировать методы защиты

РИСК-МОДЕЛЬ "УТЕЧКА ИНФОРМАЦИИ"

- Оценка риска утечки информации при работе с методами защиты конфиденциальных данных. Расширяет классическую модель k-anonymity и дает возможность применения для работы со связанными наборами (например, синтетическими данными).
- Три ключевых аспекта рисков (три составляющих):
 - **Выделение** (Singling Out): Вероятность уникальной идентификации записи.
 - **Связывание** (Linkability): Возможность связывания записей из разных наборов данных.
 - **Вывод** (Inference): Возможность угадывания неизвестных атрибутов.
- Использование доверительных интервалов для оценки рисков на основе статистического метода Уилсона.

Преимущества:

- Полный охват различных аспектов риска утечки информации.
- Применение модели для различных сценариев анализа и защиты данных.



МОДЕЛЬ УТЕЧКИ ИНФОРМАЦИИ

Модель оценивает риск утечки конфиденциальной информации из синтетических данных, а также вероятность идентификации или восстановления исходных данных из синтетического набора данных. Утечка относится к возможности извлечения конфиденциальной информации о реальных данных или людях из синтетических данных.

Риск утечки информации можно оценить, рассмотрев три ключевых аспекта (Giomli Matteo, 2022):

Выделение (Singling Out) - оценка вероятности того, что в исходном наборе данных существует уникальная запись с определенной комбинацией атрибутов.

Связывание (Linkability risk) относится к возможности связывать записи, принадлежащие одному и тому же лицу или группе лиц, в исходном и синтетическом наборах.

Вывод (Inference): Возможность угадывать неизвестные атрибуты исходной записи данных из объединенных (синтетических) данных.

ОБЩЕЕ УРАВНЕНИЕ РИСКА: $R_{total} = W_1 \times R_{singout} + W_2 \times R_{link} + W_3 \times R_{inf}$

Здесь w_1, w_2, w_3 - веса, которые могут быть приняты равными первому приближению ($w_1 \approx 0.3333$)

Каждый из трех вкладов будет оцениваться на основе интервала баллов Вильсона, статистического метода определения доверительного интервала доли в биномиальном распределении W :

$$WI = \left[\hat{p} + \frac{z_{\alpha/2}^2}{2n} - z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n} + \frac{z_{\alpha/2}^2}{4n^2}}, \hat{p} + \frac{z_{\alpha/2}^2}{2n} + z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n} + \frac{z_{\alpha/2}^2}{4n^2}} \right]$$

Здесь:

- \hat{p} - Наблюдаемая доля выборки
- n - Объем выборки
- $z_{\alpha/2}$ - Квантиль стандартного распределения для уровня достоверности (1- α): соответствует точке на стандартной нормальной кривой, в которой область под кривой под этой точкой соответствует требуемому уровню достоверности.

Интервал доверительной вероятности Вильсона предоставляет диапазон значений, в котором истинное значение риска может быть найдено с заданной степенью достоверности, и для большинства задач приемлемо выбрать среднюю точку.

Для расчетов $R_{singout}$ and R_{link} доля успеха выбирается естественным образом как уникальное количество элементов синтетического множества, сопоставленных с исходным набором (выделением) или внешним набором (Linkability). В качестве риска умозаключения можно принять приведенную энтропию:

$$\hat{p} = NE(a_j) = \frac{H(a_j)}{\log_2 4} = -\frac{1}{2} \sum_{i=1}^n p_i \log_2 p_i$$

ПОКАЗАТЕЛИ НА ИСХОДНЫХ АЛГОРИТМАХ ДО РАСШИРЕНИЯ ФУНКЦИОНАЛА



Качество и польза

Pearson Coefficient	0.9	Уровень корреляции высокий, набор данных после обезличивания сохраняет свои характеристики
KS-статистика 1	0.01	Минимальные различия между распределениями
KS-статистика 2	0.27	Низкий показатель, демонстрирующий близость наборов
KL-дивергенция 1	2.77	Умеренное изменение
KL-дивергенция 2	0.23	Очень близкое распределение
R^2 детерминация	0.55	Приемлемый результат (выше 50%)
R^2 детерминация	0.99	Очень точное соответствие данных



Безопасность

Уровень комплексной модели риска R_{total}	0.4	Относительная устойчивость
--	-----	-----------------------------------

Данные достаточно защищены, но есть потенциал для улучшения

Без учета контекста обработки

АДАПТАЦИЯ ПАРАМЕТРОВ МАСКИРОВАНИЯ С УЧЕТОМ РЕКОМЕНДАЦИЙ

Схемы обезличивания:



ПОДАВЛЕНИЕ ПРЯМЫХ ИДЕНТИФИКАТОРОВ

Удаление или замена прямых идентификаторов, для предотвращения непосредственной идентификации лиц

Основной сценарий



РАНДОМИЗАЦИЯ И РАЗМЫТИЕ С ПЕРЕМЕННЫМ РАДИУСОМ

Усложняет идентификацию отдельных пользователей

Применялось для дат рождения



ДИФФЕРЕНЦИАЛЬНАЯ ПРИВАТНОСТЬ

Квази-идентификаторы групп, введение шума. Предотвращает идентификацию даже при наличии дополнительной информации

Не применялось ранее

Расширен функционал сценариев маскирования:

1

Размытие для большего набора типов данных.

2

Дифференциальная приватность

Замены через справочники с квази-идентификаторами групп, объединяющие данные с учетом приоритетных характеристик



Понимаем влияние выбранных сценариев на баланс качества и безопасности



Можем рекомендовать оптимальный выбор модели маскирования для конкретного бизнес сценария, с учетом существующих контекстных рисков и среды

ПОКАЗАТЕЛИ ПОСЛЕ ПРИМЕНЕНИЯ РЕКОМЕНДАЦИЙ



Качество и польза

Pearson Coefficient	0.8	- 0.1	Уровень корреляции снизился, но все еще остается высоким
KS-статистика 1	0.09	+ 0.08	Статистика ухудшилась, но незначительно
KS-статистика 2	1.7	+ 1.43	Увеличение разницы между распределениями
KL-дивергенция 1	2.85	+ 0.08	Расстояние между наборами увеличилось
KL-дивергенция 2	1.17	+ 0.94	Для защищенного варианта показатель ожидаемо вырос
R^2 детерминация	0.24	- 0.31	Для обновленной модели низкое значение
R^2 детерминация	0.83	- 0.16	На защищенных данных незначительное снижение



Безопасность

Уровень комплексной модели риска R_{total}

0.01

Риск значительно снижен

С учетом продвинутых техник атак, при теоретическом пороге риска не более 0.1

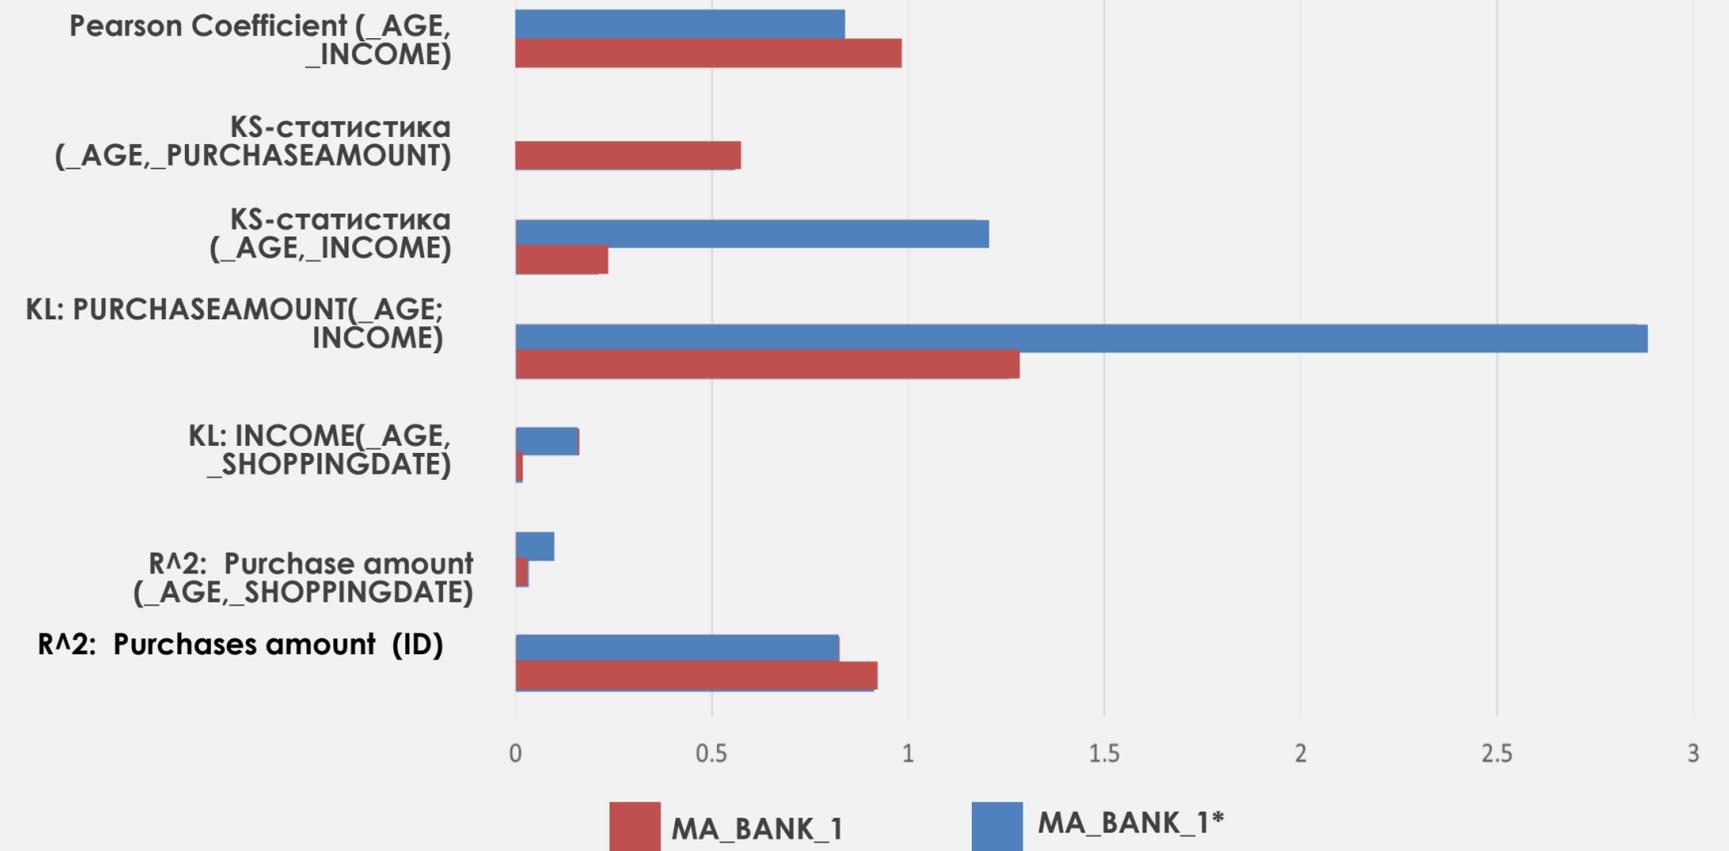
Без учета контекста обработки

ИЗМЕНЕНИЯ КАЧЕСТВА ПОСЛЕ ПРИМЕНЕНИЯ ДИФФЕРЕНЦИАЛЬНОЙ ПРИВАТНОСТИ



Качество незначительно упало при существенном росте безопасности

КАЧЕСТВО (ПОЛЕЗНОСТЬ) ПРОТИВ ПРИВАТНОСТИ



РЕЗУЛЬТАТЫ КЕЙСА

Применение мер защиты незначительно снизило качество данных, как по метрикам, так и по целевым бизнес-характеристикам. Ожидаемое соотношение – при увеличении шума снижаются метрики риска, включая риски атак (растет степень защиты), но также снижается качество)

Бизнес-метрики:

$$\text{Conversion Rate} = \left(\frac{\text{Number of Conversions}}{\text{Total Number of Interactions}} \right) \times 100\%$$

	КАЧЕСТВО ДАННЫХ	БЕЗОПАСНОСТЬ	БИЗНЕС-МЕТРИКА
ПРЯМАЯ ОБРАБОТКА	100%	0%	7%
ЗАЩИЩЕННАЯ ОБРАБОТКА	86%	99.98%	5%



РАСШИРЕНИЕ ФУНКЦИОНАЛЬНЫХ ВОЗМОЖНОСТЕЙ «МАСКИРОВЩИКА»

ИСХОДНО:

Алгоритмы, сохраняющие больше смысловых характеристик.

Стандартизация и умный анализ, сохранение качества и распределения.

Данные максимально полезны для аналитики.

Дополнительные алгоритмы для гибкой настройки соотношения качества и безопасности:

УПРОЩЕННЫЕ АЛГОРИТМЫ БЕЗ СТАНДАРТИЗАЦИИ

Усложняют обратную идентификацию.
Сохраняют меньше характеристик либо только формат.

Увеличение скорости от 30% до 2000% относительно исходных в зависимости от типа данных

АЛГОРИТМЫ С РАСШИРЕНИЕМ СХЕМЫ ОБЕЗЛИЧИВАНИЯ

(дифференциальная приватность и прочее).
Сохраняют меньше детальных характеристик для аналитики.

Снижение скорости в пределах 7% относительно исходных

ПЛАНЫ РАЗВИТИЯ

1

 Преднастроенные рекомендации по выбору набора алгоритмов маскирования

Возможность выбора и настройки схемы обработки

2

 Поиск чувствительной информации и маскирование данных в файлах и свободном тексте

Учитываем контекст сценария использования данных:

РАСПОЛОЖЕНИЕ

- во внутреннем контуре/ выкладываются вовне

ДОСТУП

- только сотрудники / внешние подрядчики

СЦЕНАРИЙ РАБОТЫ С ДАННЫМИ

- Обмен данными со сторонними организациями
- Отправка данных в chatGpt и другие внешние системы
- Интеграционное тестирование внутри контура

УРОВЕНЬ СОХРАНЕНИЯ КАЧЕСТВА И СМЫСЛА ДЛЯ КОНКРЕТНОГО ТИПА ДАННЫХ

- Выделение групповых характеристик, приоритетных для аналитики
- Выделение данных, где достаточно сохранить только формат

МАСКИРОВАНИЕ ДОКУМЕНТОВ РАЗЛИЧНЫХ ТИПОВ С СОХРАНЕНИЕМ ФОРМАТИРОВАНИЯ

СЦЕНАРИИ РАБОТЫ С CHATGPT, СОХРАНЯЮЩИЕ КОНТЕКСТ ПРИ ЗАМЕНАХ В ДИАЛОГЕ

ОТВЕТЫ НА ПОСТАВЛЕННЫЕ ВОПРОСЫ

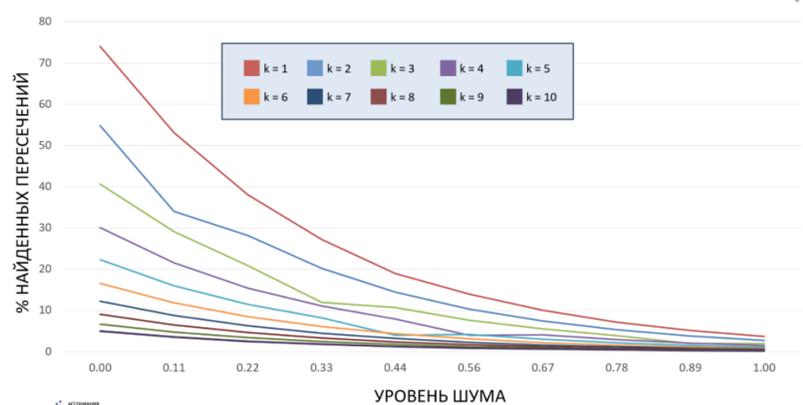


1. K-ANONYMITY / LINKAGE SUCCESS

Модель k-anonymity может успешно применяться в случае единственного источника данных. С возрастанием k вероятность повторной идентификации падает, однако, **возможность атак связывания хотя и уменьшается, но медленнее чем рост k.**

Вывод: В сложных случаях взаимодействия рекомендуется моделировать атаки связывания и включать их в оценку рисков

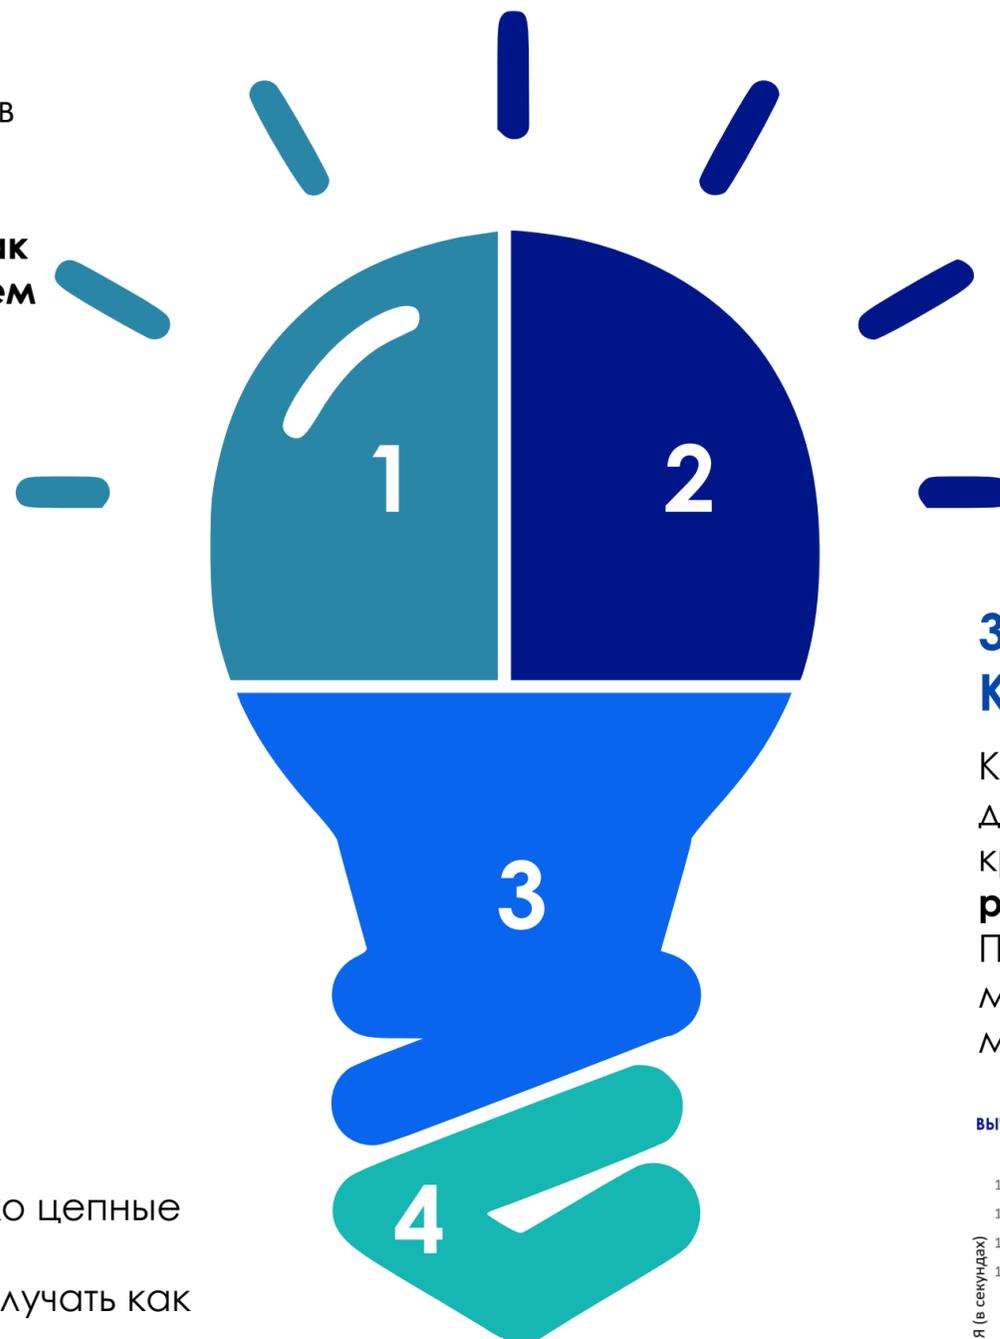
K-ANONYMITY/LINKAGE ATTACKS



4. РИСК МОДЕЛЬ:

Модель ИНФОРМАЦИОННОЙ УТЕЧКИ представляет обобщенную риск-модель, учитывающую не только цепные (каскадные) эффекты, но и кумулятивные угрозы. Применение доверенных интервалов позволяет получать как оценки сверху, так и снизу для рисков работы с конфиденциальной информацией.

$$P_{data} = w_1 \cdot \hat{P}_{singl} + w_2 \cdot \hat{P}_{linkage} + w_3 \cdot \hat{P}_{inher}$$



2. ОЦЕНКА РИСКОВ ПЕРЕСЕЧЕНИЯ

Оценка рисков пересечения данных с внешними источниками может производиться на основе сравнения защищенного набора информации и исходного набора: такое сравнение дает **оценку сверху (максимальный риск) по отношению к "неизвестным утечкам"**

3. СЛОЖНОСТЬ КОНФИДЕНЦИАЛЬНЫХ ПЕРЕСЕЧЕНИЙ

Конфиденциальные методы вычислений (такие как PS3I) дают высокую надежность за счет использования сложных криптографических техник. В тоже время они **сложны в реализации** и тяжело обобщаются на многих участников. Перспективным направлением является использование методов "с нулевым доказательством" (ZKP), таких как метод Шнорра

ВЫЧИСЛИТЕЛЬНАЯ СЛОЖНОСТЬ ПО ШНОРРУ



РЕЗУЛЬТАТЫ ТЕСТИРОВАНИЯ

- 1. ЭФФЕКТИВНОСТЬ РИСК-МОДЕЛИ:** Риск-модель доказала свою работоспособность. Для увеличения точности прогнозирования и оценки публикуемых данных необходимо использовать симуляции атак, которые углубляют понимание рисков повторной идентификации за счет учета рисков выделения и связывания.
- 2. ЗАЩИТА ДАННЫХ МАСКИРОВЩИКОМ:** Продукт HF Labs "МАСКИРОВЩИК" успешно применен для обезличивания данных, сохраняя их значимость для аналитики. Обезличенные данные показали высокую устойчивость к атакам и минимальный риск повторной идентификации.
- 3. МЕТОДИКА БЕЗОПАСНОЙ ИНТЕГРАЦИИ:** Протокол Шнорра продемонстрировал высокую эффективность в конфиденциальном объединении данных. Использование схем PSI и TEE обеспечило высокий уровень безопасности при интеграции данных.
- 4. УЧЕТ КОНТЕКСТНЫХ РИСКОВ:** Модель безопасности не может существовать в отрыве от контекстных рисков. Дополнительные факторы, такие как композитные риски, могут быть учтены с помощью аппроксимации полиномиальными функциями, что позволит учитывать большее количество косвенных влияний на безопасность, чем это возможно при прямой факторизации риска.

ОСНОВНЫЕ ВЫВОДЫ



Риски обработки клиентских данных могут (и должны) быть измерены для **конкретного бизнес-кейса**



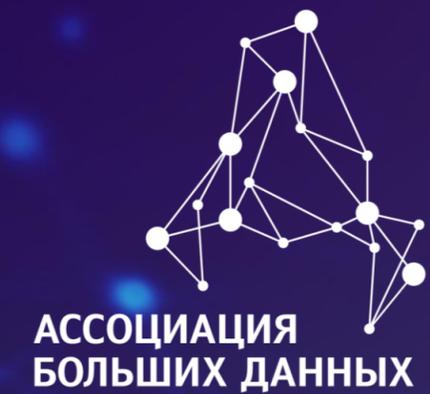
Существуют техники и технологии снижения риска реидентификации **до околонулевых значений** даже **при использовании дополнительной информации**



Использование технологий повышения конфиденциальности лежит **в «серой» зоне** нормативного регулирования, не успевающего за их развитием

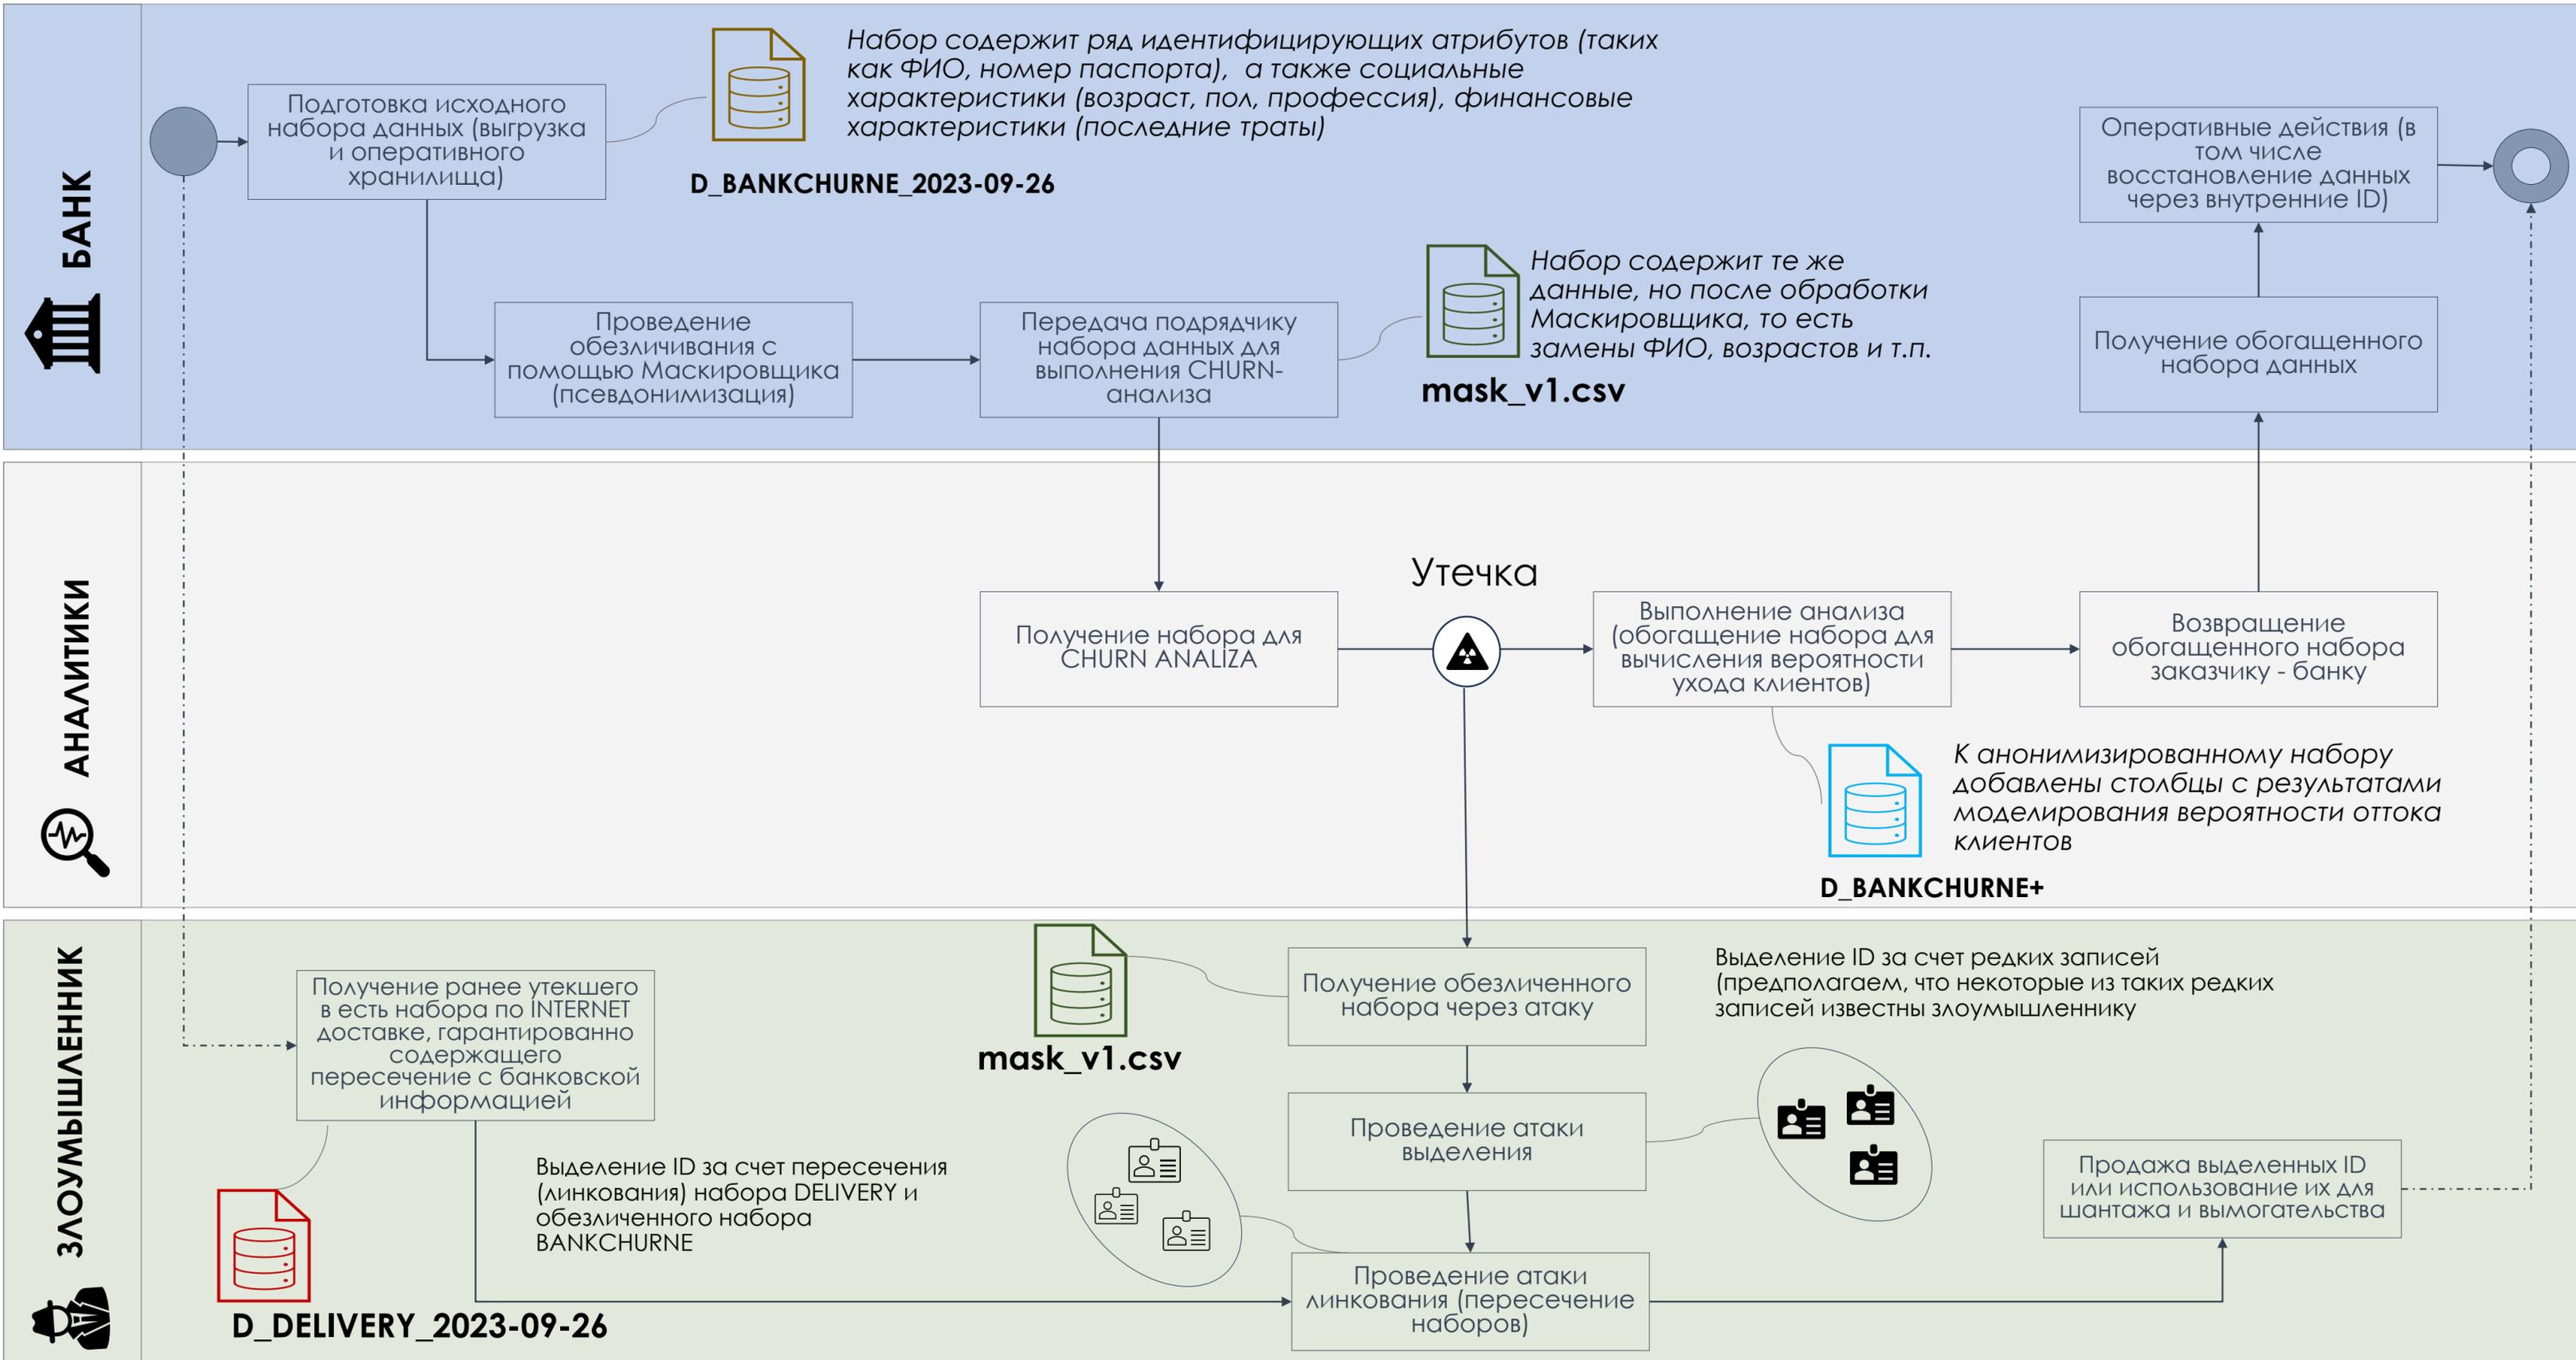


Закрепление модели оценки рисков будет способствовать **быстрому внедрению технологий на данных** при сохранении должного уровня конфиденциальности

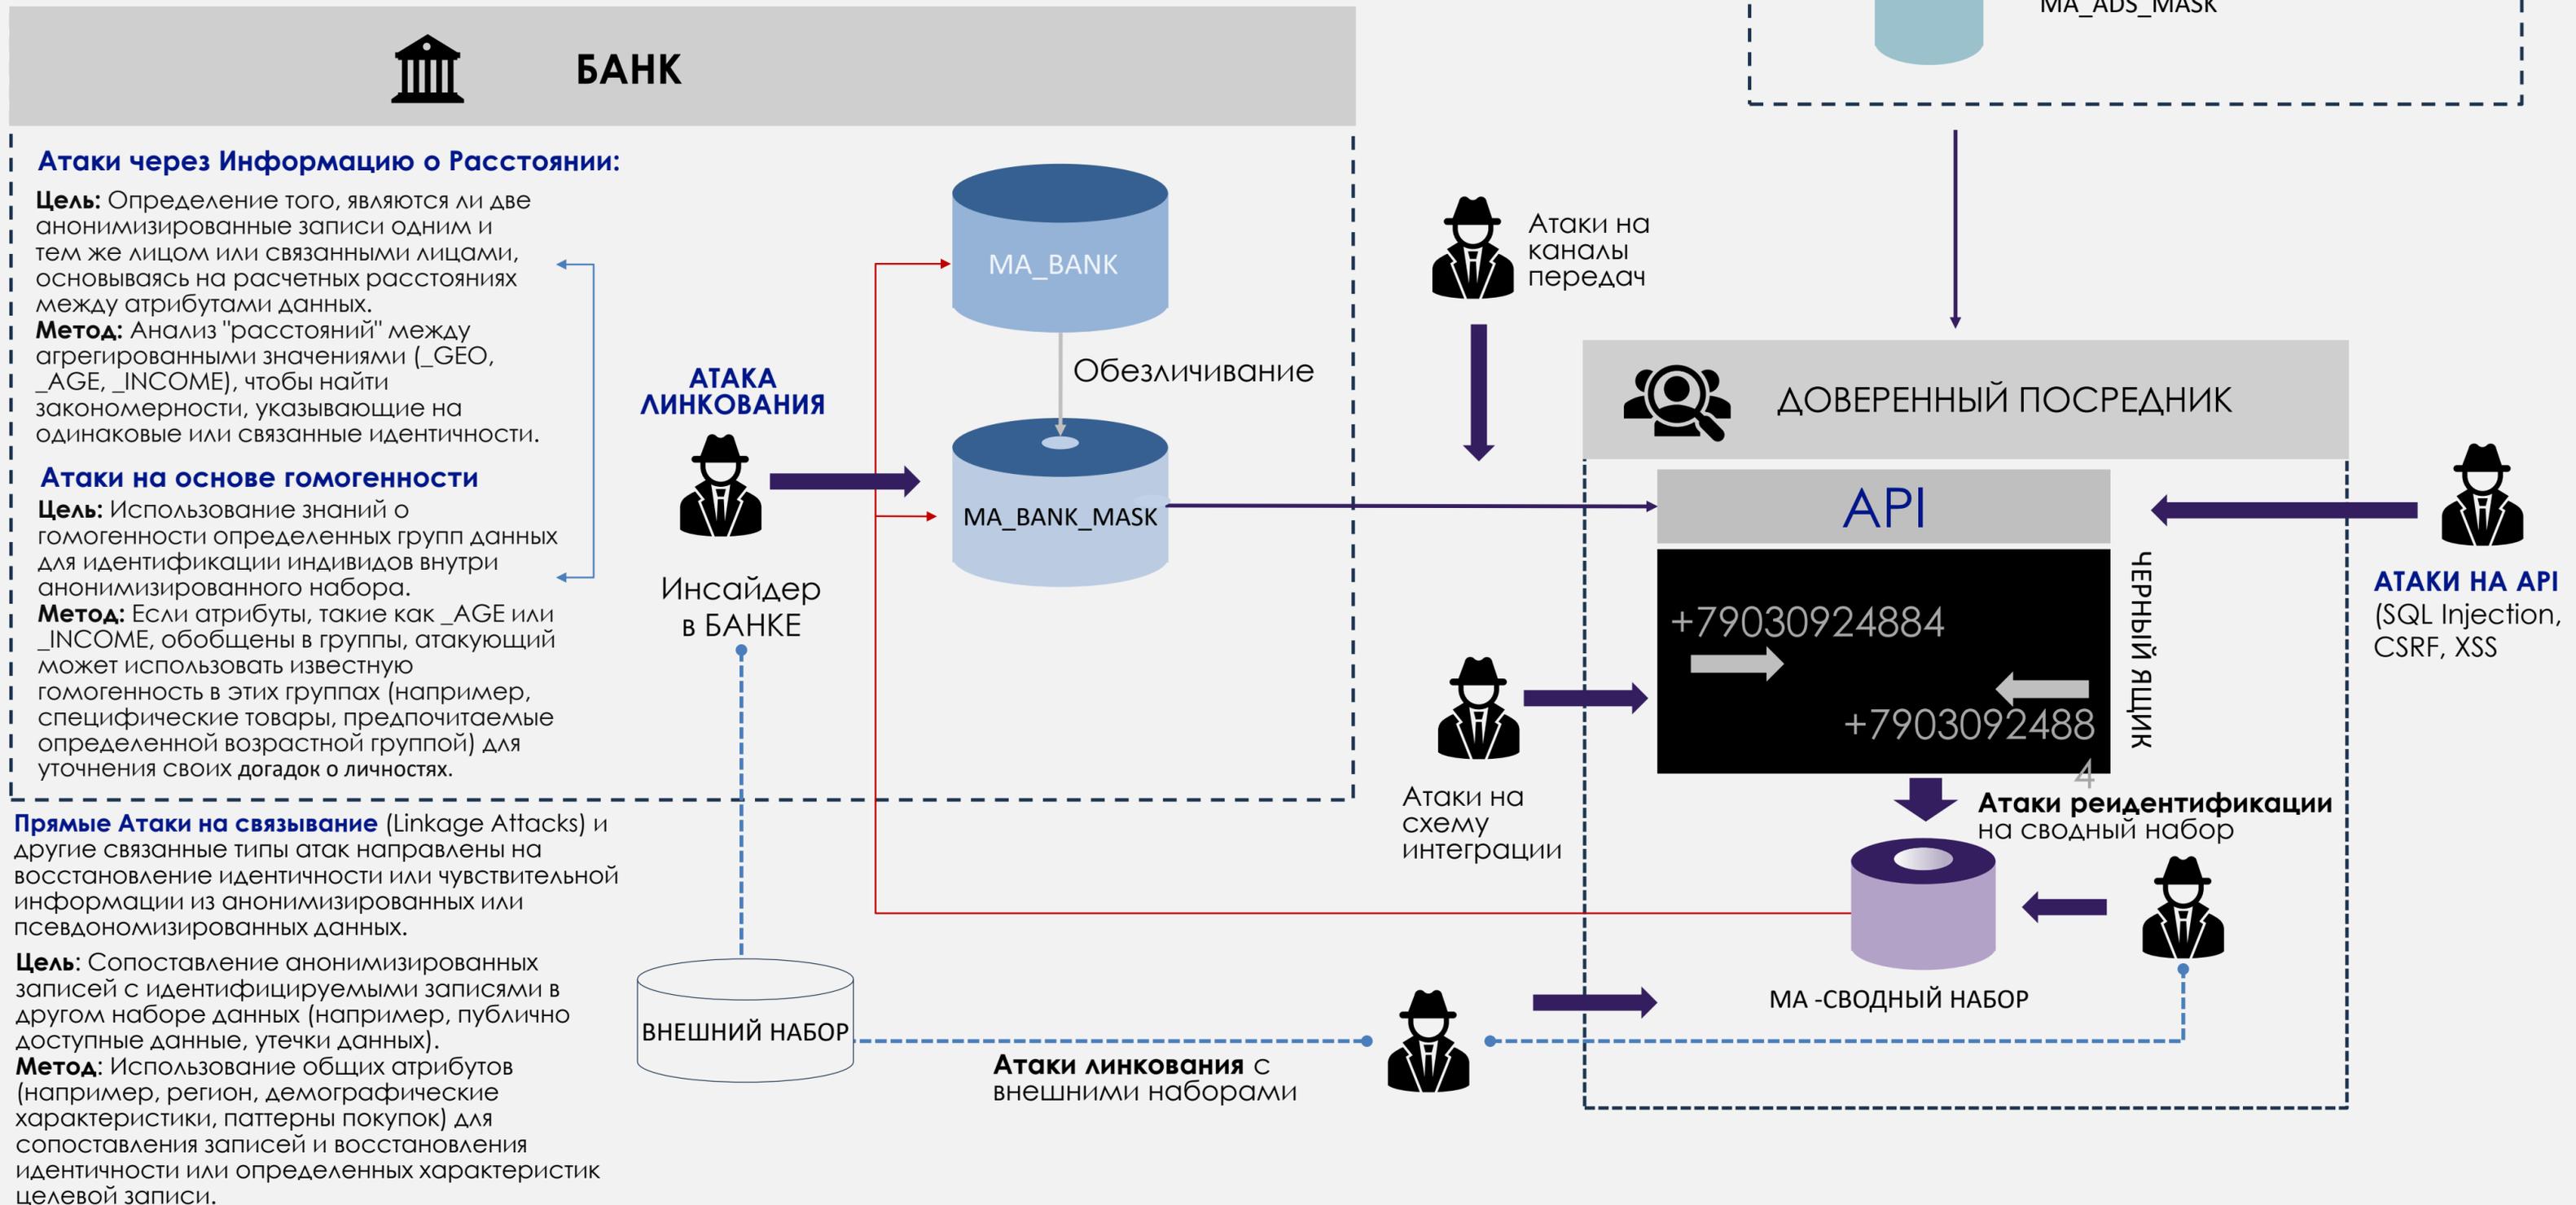


СПАСИБО ЗА ВНИМАНИЕ!

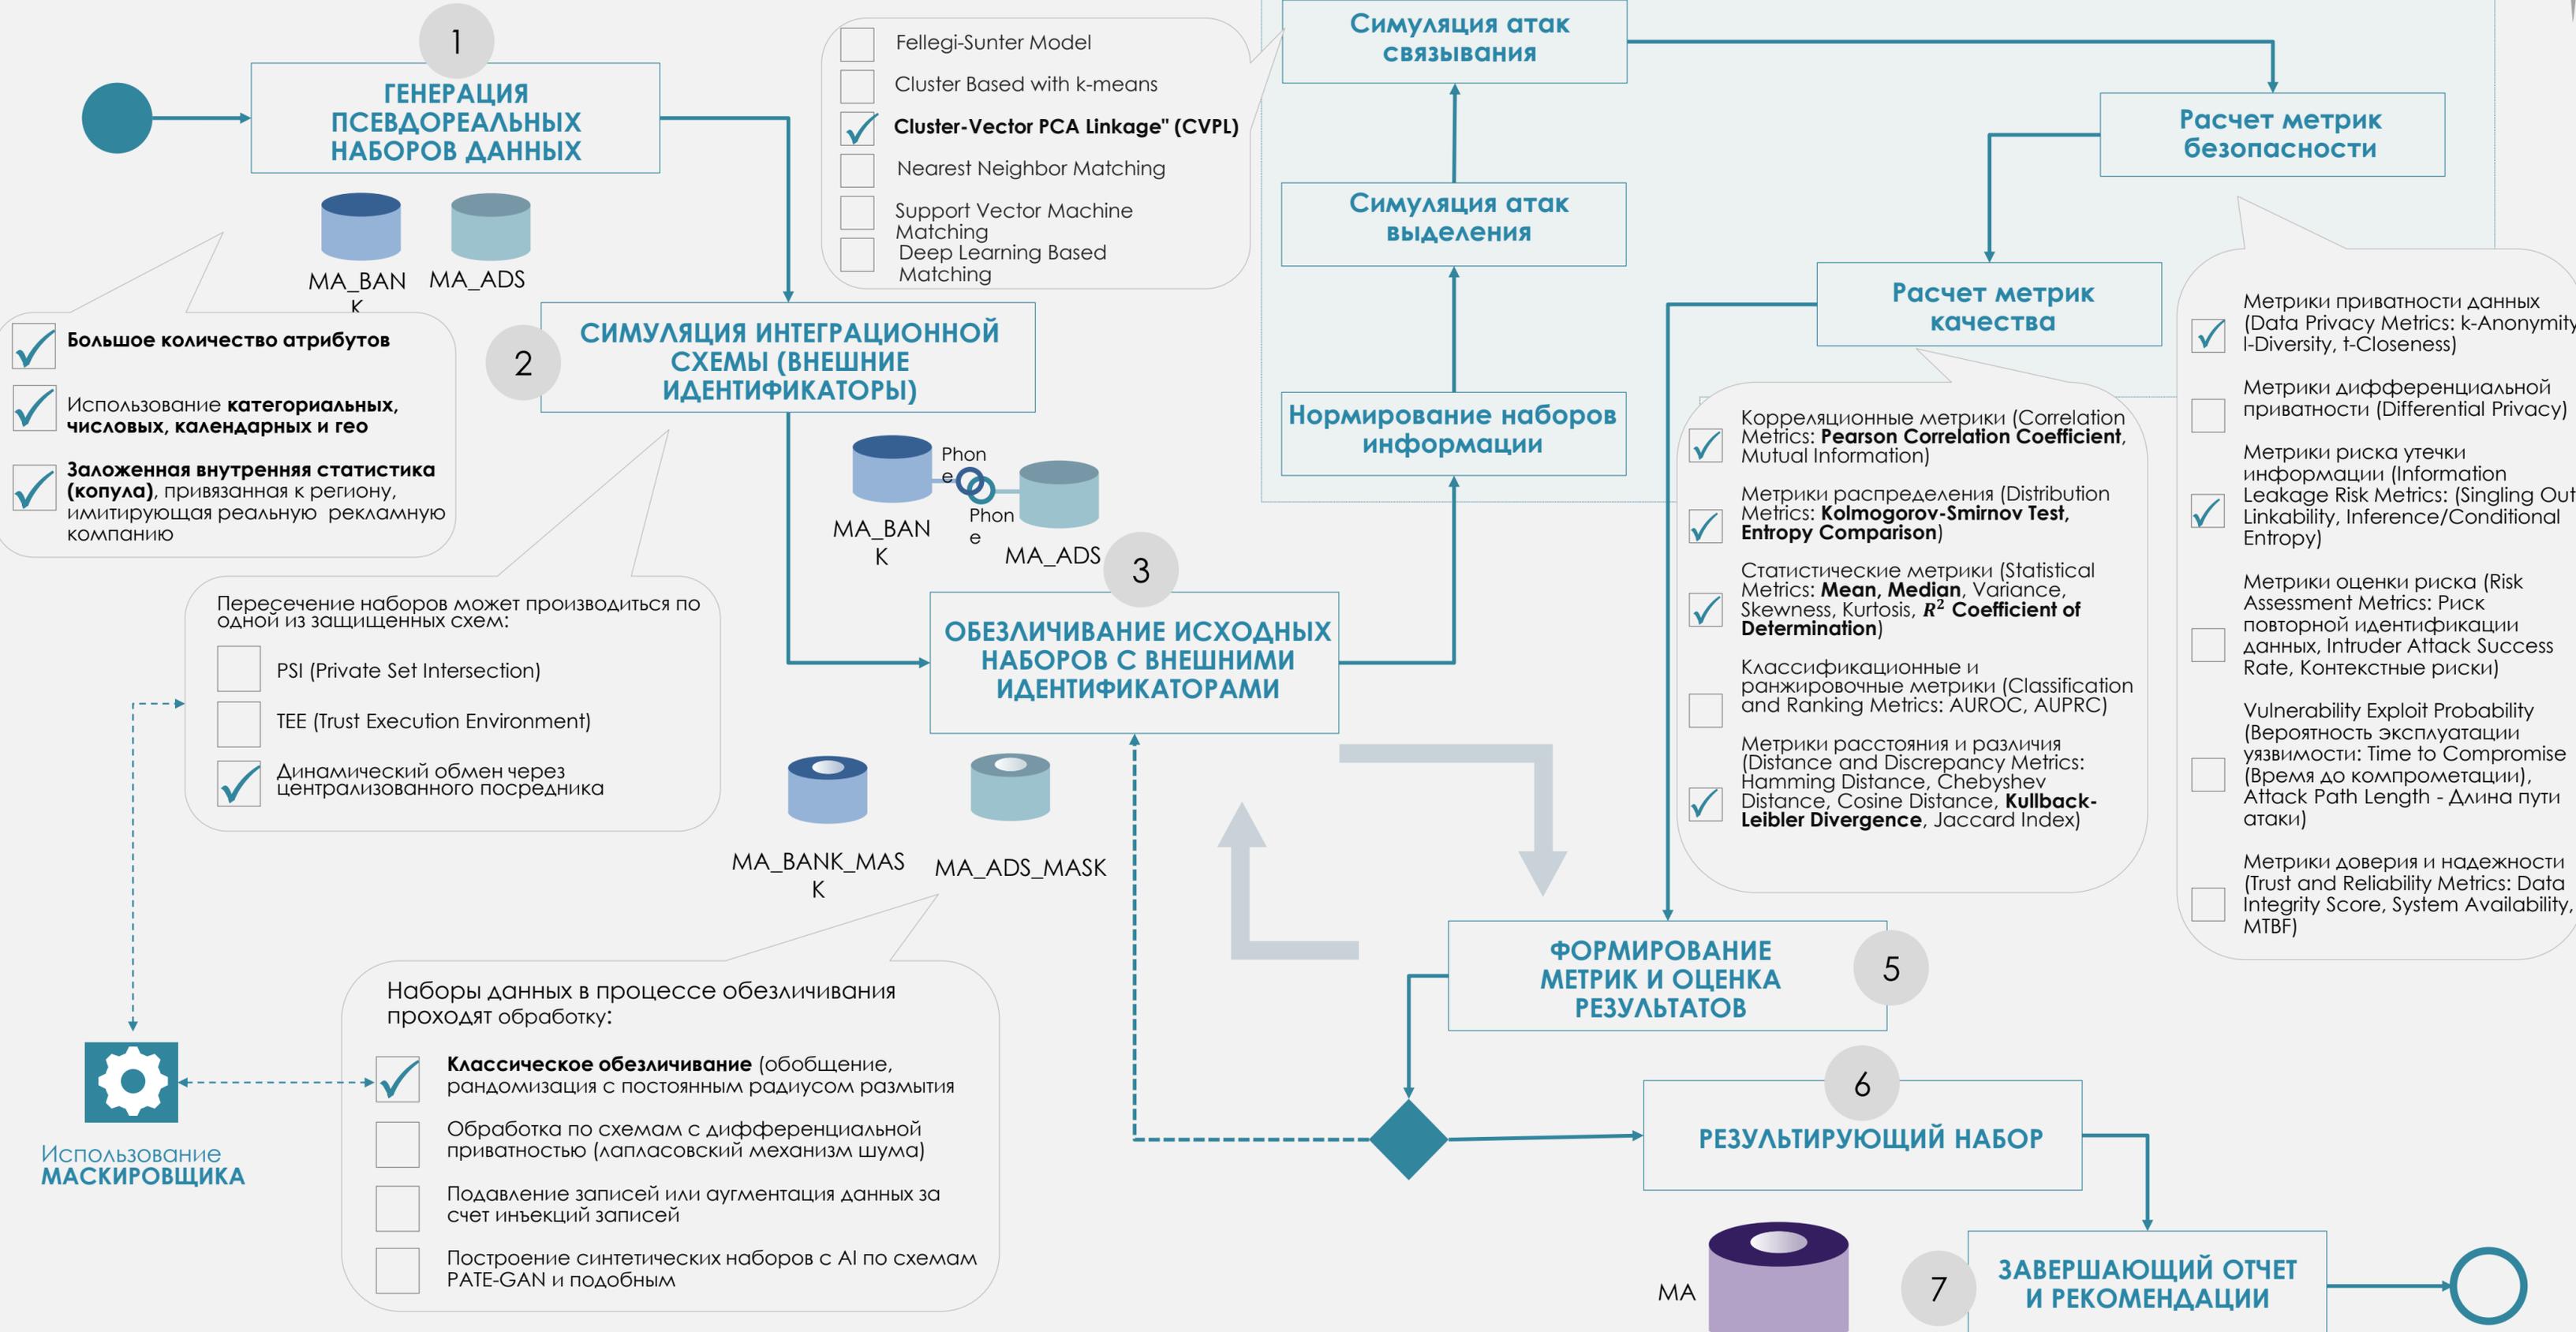
© ПРИ ИСПОЛЬЗОВАНИИ ДАННОГО МАТЕРИАЛА ССЫЛКА
НА АССОЦИАЦИЮ БОЛЬШИХ ДАННЫХ (АБД) ОБЯЗАТЕЛЬНА



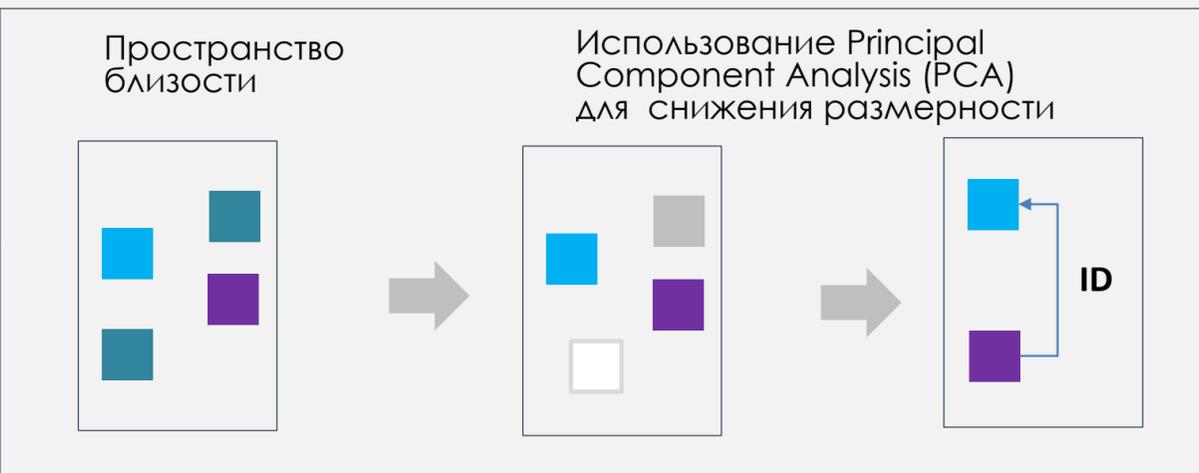
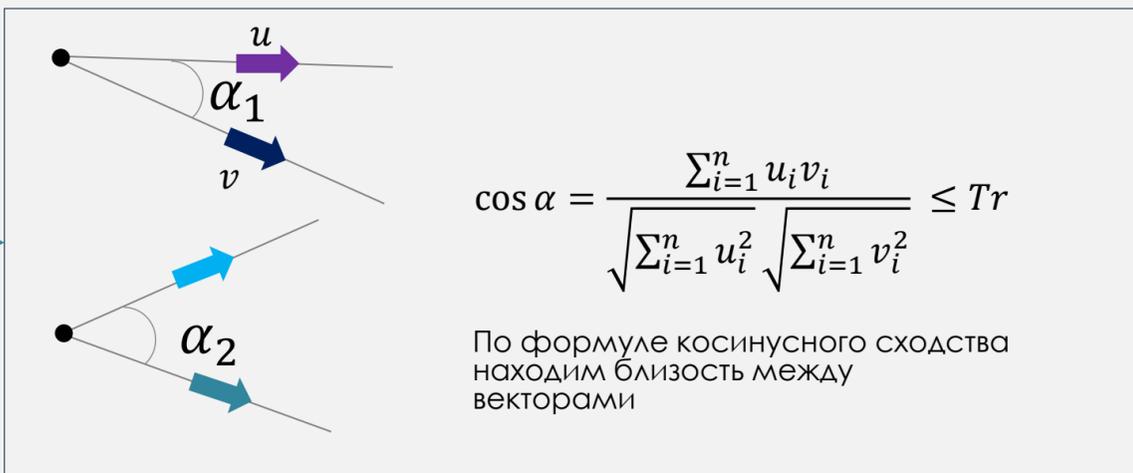
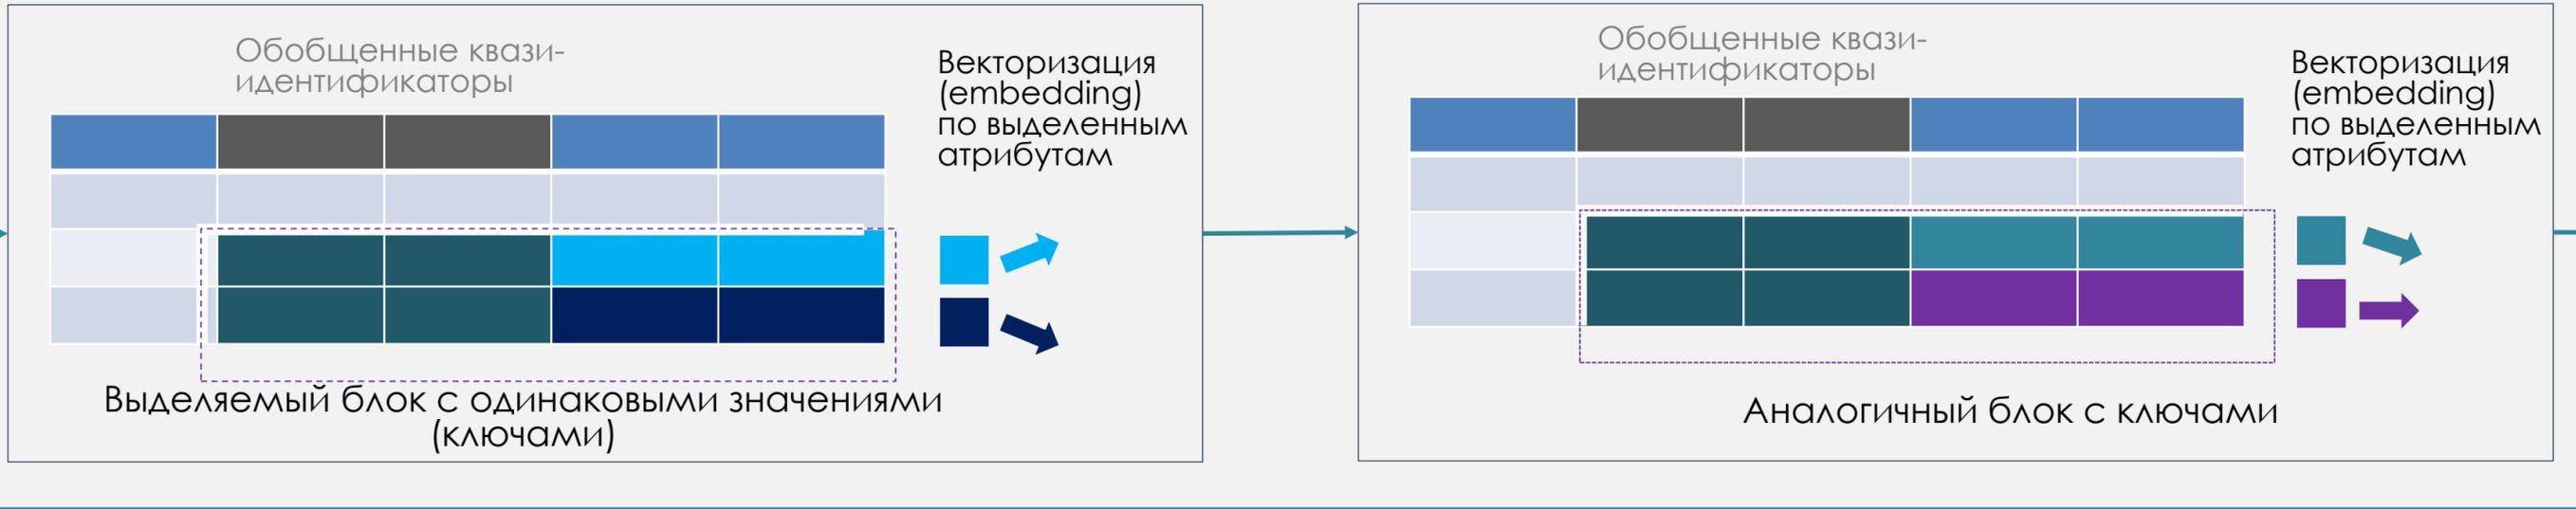
ПОВЕРХНОСТЬ АТАК



АЛГОРИТМЫ И МЕТРИКИ

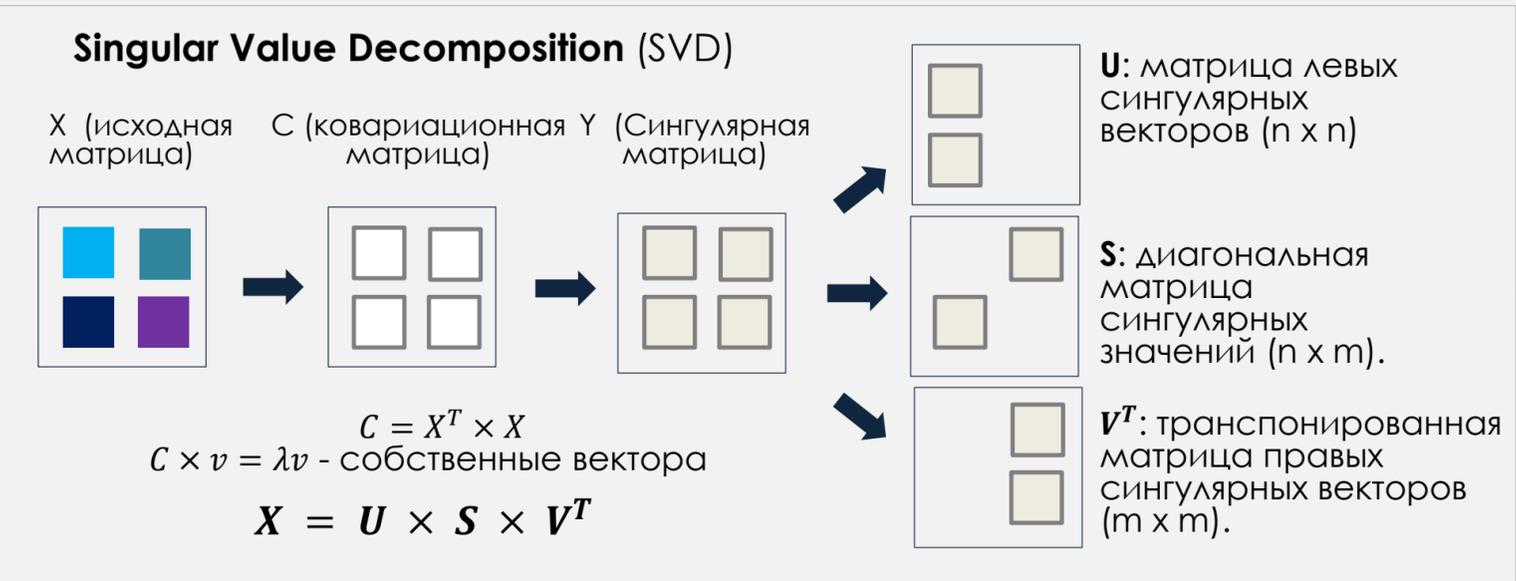


АТАКА СВЯЗЫВАНИЯ: CLUSTER-VECTOR PCA LINKAGE (CVPL)



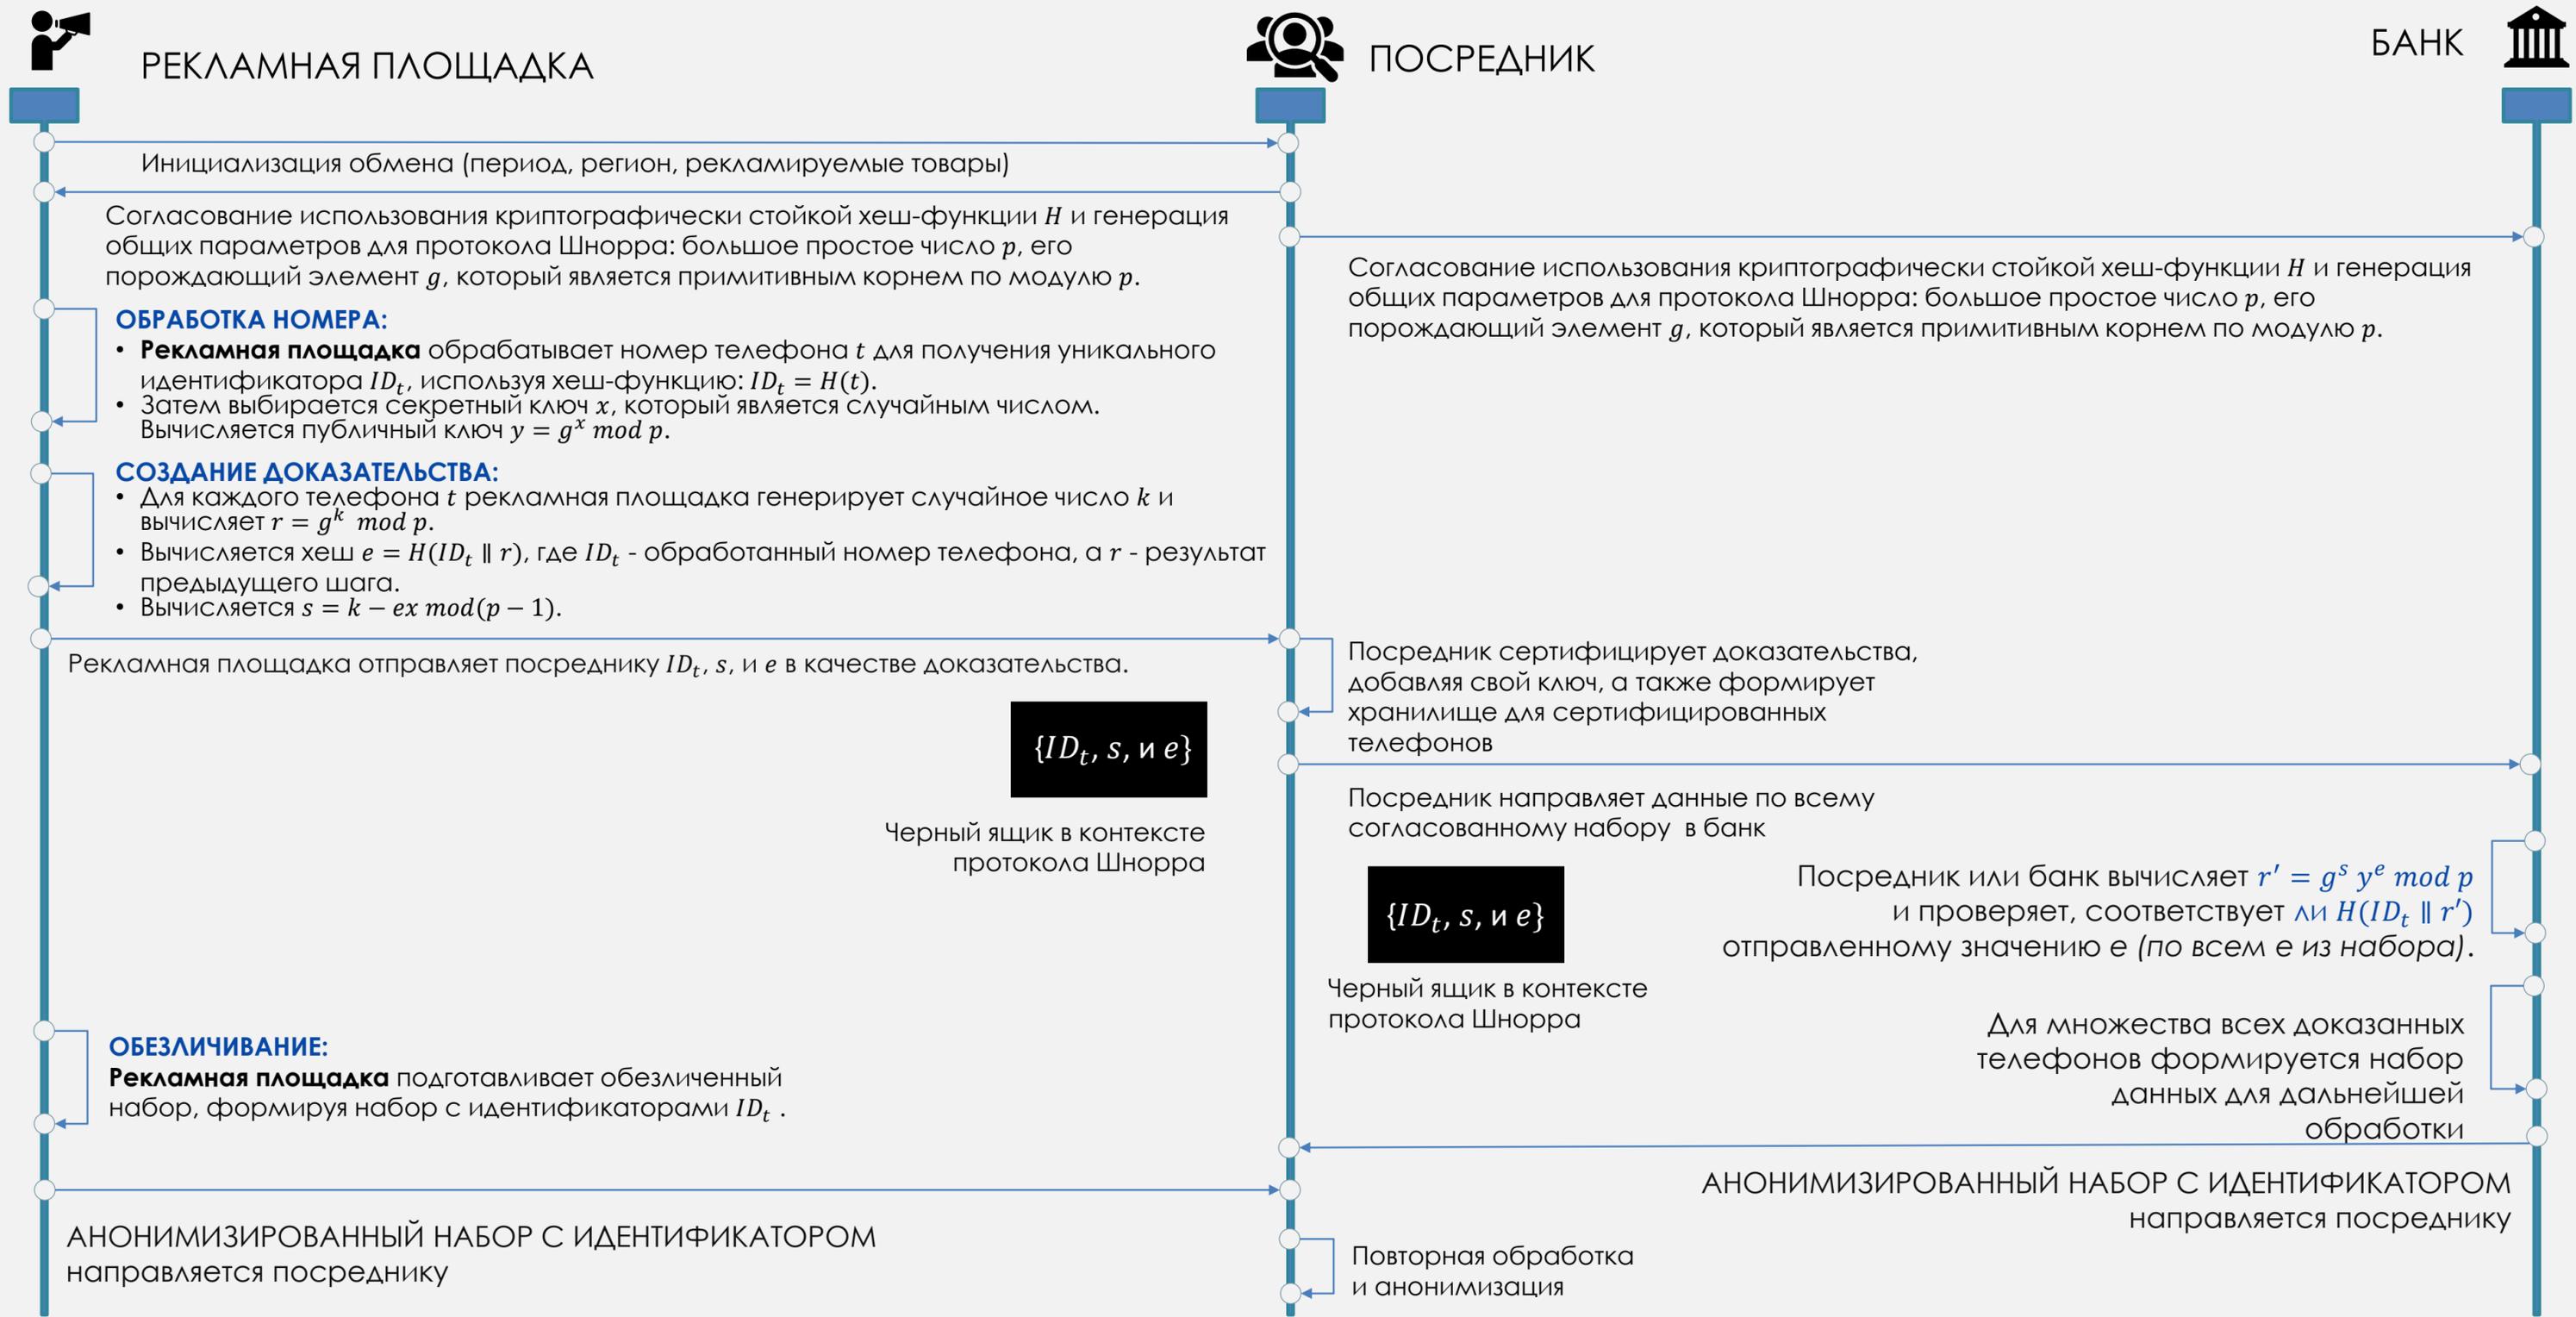
Вычисляем вероятности и подсчитываем однозначные связи

ID	ID_LEFT	ID_RIGHT
1	1024	567
2	789	417, 255
3	1375	...



ИНТЕГРАЦИЯ ПО СХЕМЕ ШНОРРА


Существуют различные схемы объединения распределенной информации. В контексте тестирования используется концепция ЧЕРНОГО ЯЩИКА, в рамках которой происходит объединение информации без раскрытия сторонами информации о мобильных телефонах пользователей. Ниже предлагается концептуальная схема, которая напрямую не тестируется, но предполагает реализацию на стороне МАСКИРОВЩИКА. Такая схема основан ан механизмах доказательства членства в группе (Membership ZKP, Zero Knowledge Proof), использует алгоритм ШНОРРА (Schnorr Scheme).



СТАТИСТИКА ПО АТАКАМ



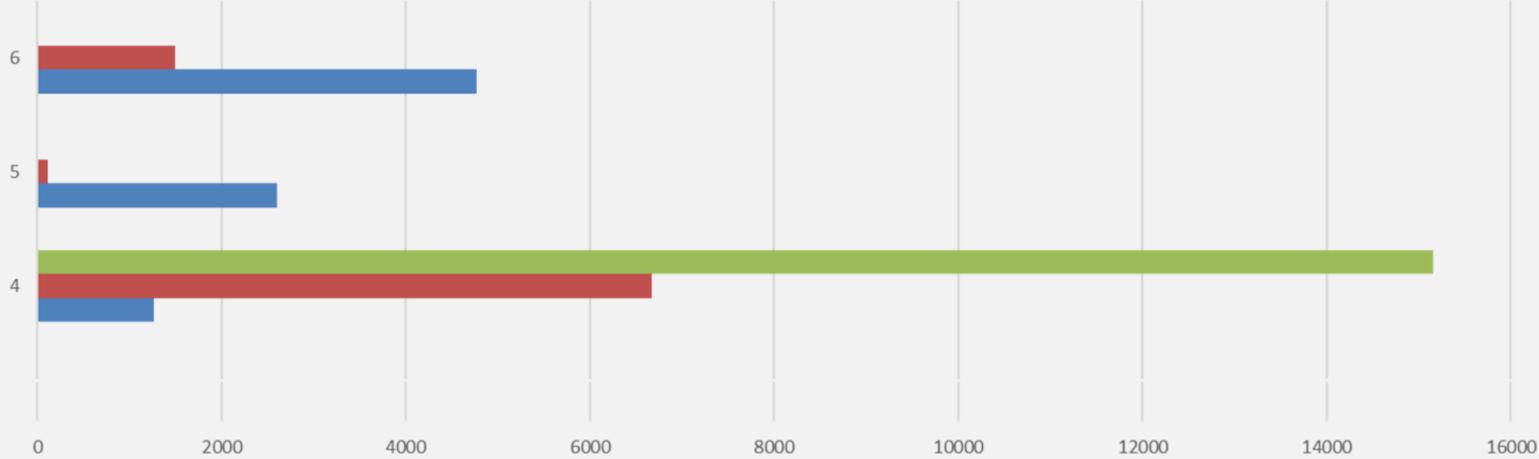
Количество Блоков и векторов для CVPL атак



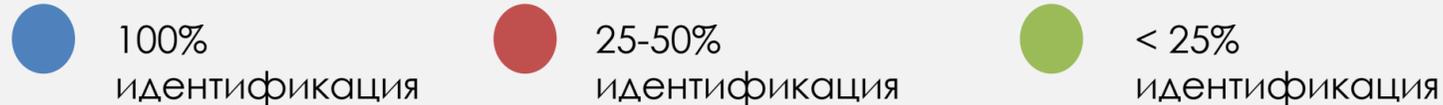
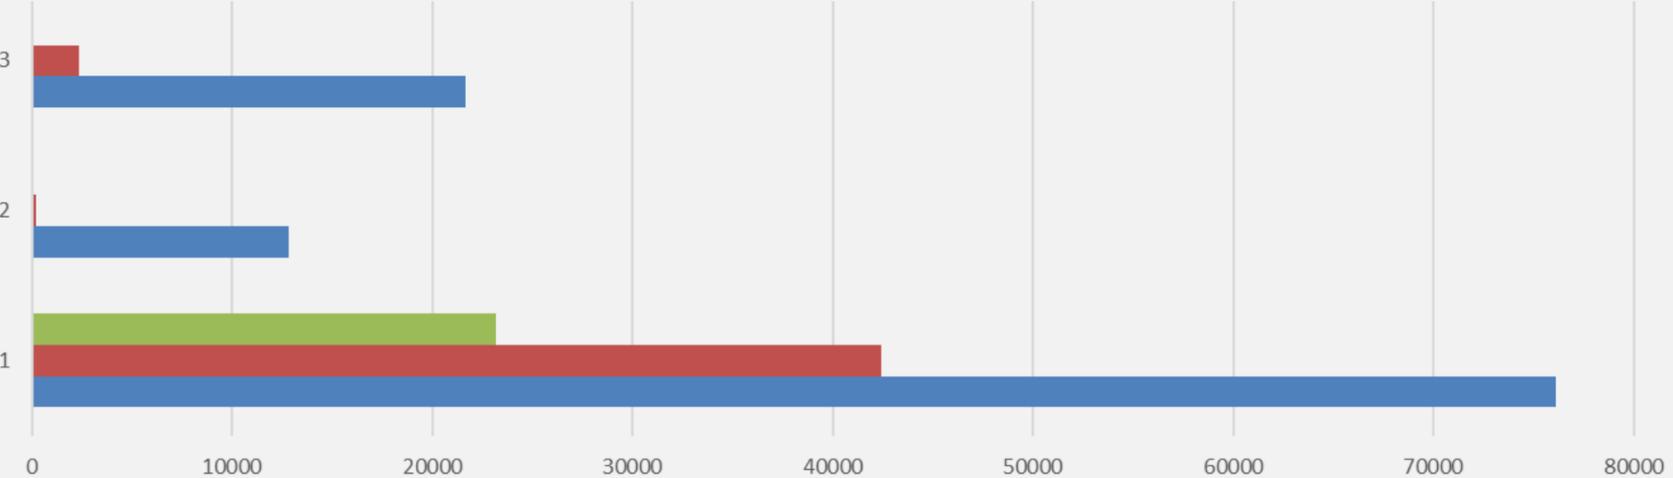
Attack_1	SEX;FAMILYSTATUS;BRAND;_AGE;_SHOPPINGDATE_HRS	БЛОКИ
Attack_4	PURCHASEAMOUNT	Векторы
Attack_2	SEX; FAMILYSTATUS; BRAND; _AGE;_SHOPPINGDATE_HRS	БЛОКИ
Attack_5	PURCHASEAMOUNT; INCOME; _GEO_RO; _GEO_FI	Векторы
Attack_3	SEX;FAMILYSTATUS; BRAND; _INCOME;_SHOPPINGDATE_HRS	БЛОКИ
Attack_6	PURCHASEAMOUNT; _GEO_RO; _GEO_FI	Векторы

Каждая атака определяется выбранными полями для построения блоков и векторов внутри блоков

АТАКИ НА МАЛЫЕ НАБОРЫ (MA_BANK_1 – MA_BAN_MASK_1)



АТАКИ НА БОЛЬШИЕ НАБОРЫ (MA_BANK – MA_BAN_MASK)



МОДЕЛЬ УТЕЧКИ ИНФОРМАЦИИ

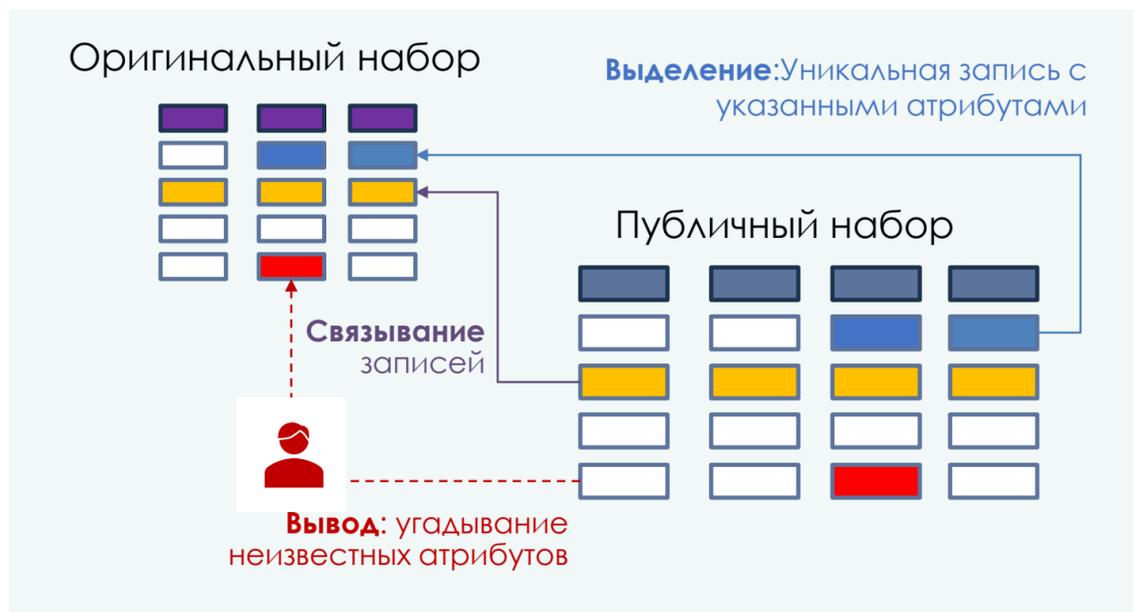
Модель оценивает риск утечки конфиденциальной информации из синтетических данных, а также вероятность идентификации или восстановления исходных данных из синтетического набора данных. Утечка относится к возможности извлечения конфиденциальной информации о реальных данных или людях из синтетических данных.

Риск утечки информации можно оценить, рассмотрев три ключевых аспекта (Giomi Matteo, 2022):

Выделение (Singling Out) - оценка вероятности того, что в исходном наборе данных существует уникальная запись с определенной комбинацией атрибутов.

Связывание (Linkability risk) относится к возможности связывать записи, принадлежащие одному и тому же лицу или группе лиц, в исходном и синтетическом наборах.

Вывод (Inference): Возможность угадывать неизвестные атрибуты исходной записи данных из объединенных (синтетических) данных.



ОБЩЕЕ УРАВНЕНИЕ РИСКА: $R_{total} = w_1 \times R_{singlout} + w_2 \times R_{link} + w_3 \times R_{inf}$

Здесь w_i – веса, которые могут быть приняты равными первому приближению ($w_i \approx 0.3333$)

Каждый из трех вкладов будет оцениваться на основе интервала баллов Вильсона, статистического метода определения доверительного интервала доли в биномиальном распределении WI:

$$WI = \left[\frac{\hat{p} + \frac{z_{\alpha}^2}{2n} - z_{\alpha} \frac{z_{\alpha}}{2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n} + \frac{z_{\alpha}^2}{4n^2}}}{1 + \frac{z_{\alpha}^2}{n}}, \frac{\hat{p} + \frac{z_{\alpha}^2}{2n} + z_{\alpha} \frac{z_{\alpha}}{2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n} + \frac{z_{\alpha}^2}{4n^2}}}{1 + \frac{z_{\alpha}^2}{n}} \right]$$

Здесь:

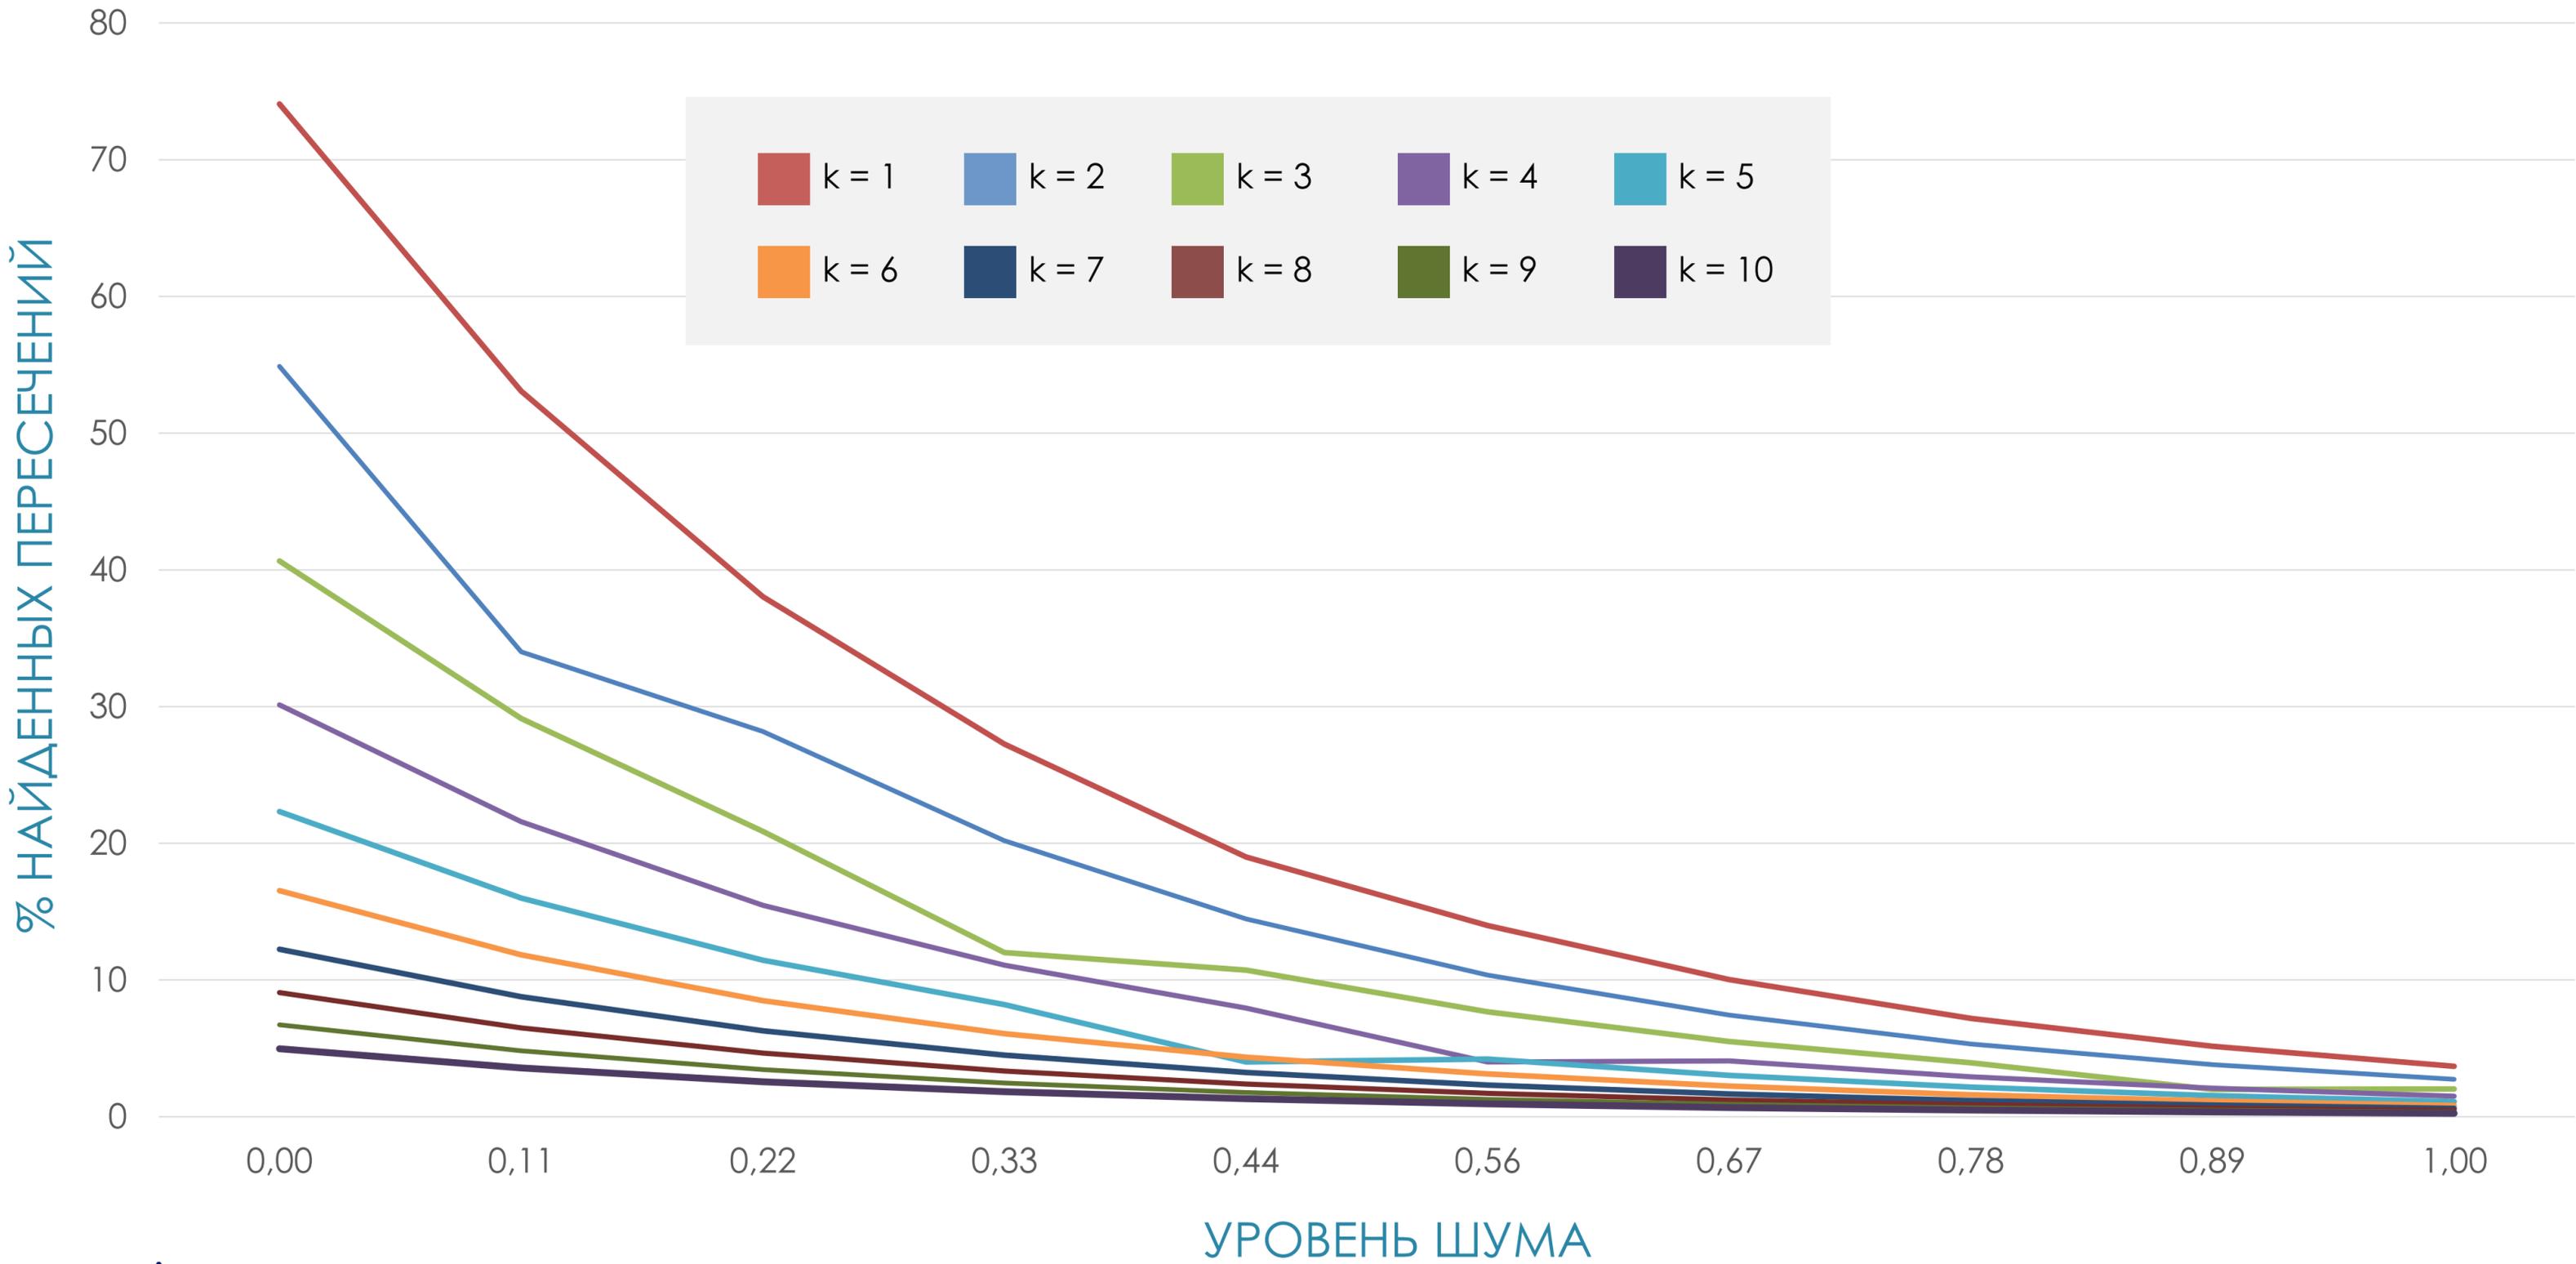
- \hat{p} — Наблюдаемая доля выборки
- n — Объем выборки
- $z_{\alpha/2}$ – Квантиль стандартного распределения для уровня достоверности $(1-\alpha)$: соответствует точке на стандартной нормальной кривой, в которой область под кривой до этой точки соответствует требуемому уровню достоверности.

Интервал доверительной вероятности Вильсона предоставляет диапазон значений, в котором истинное значение риска может быть найдено с заданной степенью достоверности, и для большинства задач приемлемо выбрать среднюю точку.

Для расчетов $R_{singlout}$ and R_{link} доля успеха выбирается естественным образом как уникальное количество элементов синтетического множества, сопоставленных с исходным набором (выделение) или внешним набором (Linkability). В качестве риска умозаключения можно принять приведенную энтропию:

$$\hat{p} = NE(a_j) = \frac{H(a_j)}{\log_2 4} = -\frac{1}{2} \sum_{i=1}^n p_i \log_2 p_i$$

K-ANONYMITY/LINKAGE ATTACKS



ВЫЧИСЛИТЕЛЬНАЯ СЛОЖНОСТЬ ПО ШНОРРУ



Intel Core i7-9750 CPU 32Gb RAM

Время генерации ключей: $O(n^2)$

- Время генерации ключей на одной стороне (Client).
- Время генерации ключей на другой стороне (Server).

Время обмена ключами: $O(n)$

- Время, затраченное на передачу данных между сторонами (сетевое время).

Время вычисления пересечений: $O(n^2)$

- Время, затраченное на вычисление пересечений на одной стороне.
- Время, затраченное на вычисление пересечений на другой стороне.

ВРЕМЯ (в секундах)

