

Процесс анализа данных



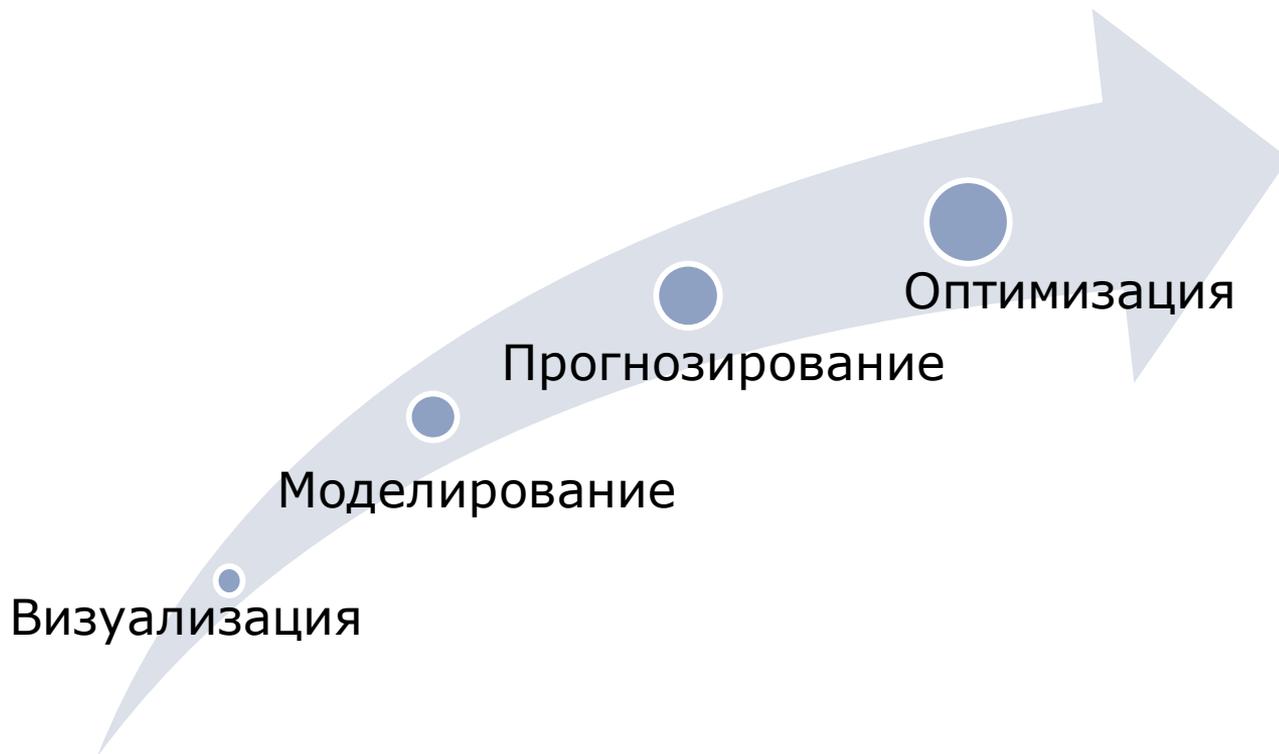
BaseGroup Labs
ТЕХНОЛОГИИ АНАЛИЗА ДАННЫХ



BaseGroup Labs
ТЕХНОЛОГИИ АНАЛИЗА ДАННЫХ

Основные подходы

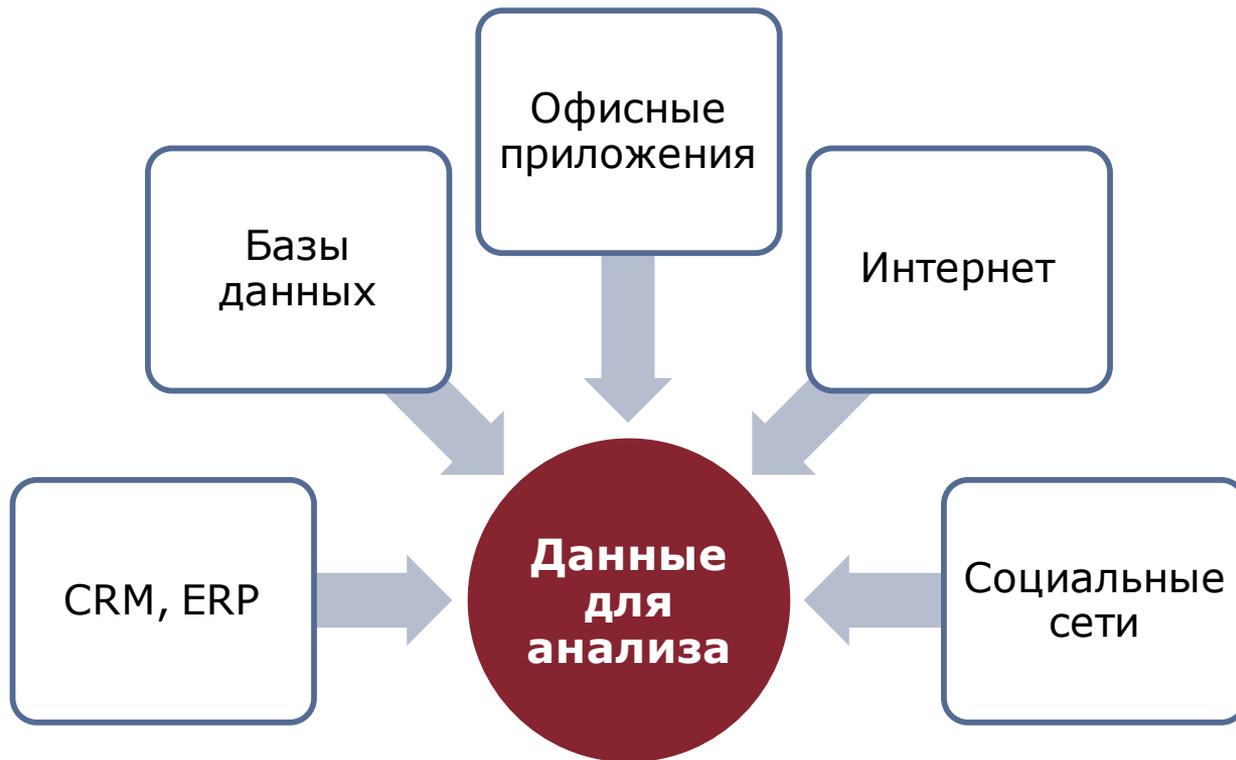
Уровни анализа



Процесс анализа



Выборка данных

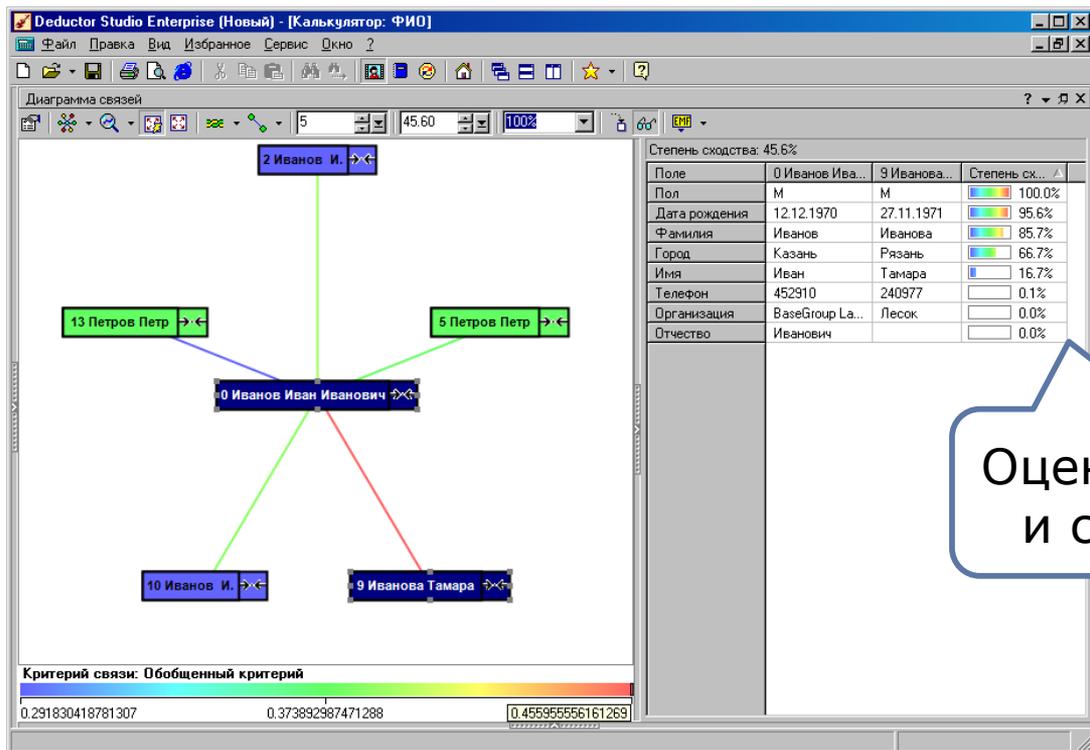


Выборка данных: проблема

| Атрибут | Персона 1 | Персона 2 |
|---------------|--|--|
| ФИО | Иванов Иван Иванович | Иван Иванович |
| Адрес | | г. Рязань ул. Новая 53в |
| Телефон | +7 (4912) 24-09-77 | |
| Дата рождения | 1971 г. | 15 декабря |
| E-mail | ivanov@mail.ru | ivanoff@gmail.com |
| Место работы | BaseGroup Labs | BGL |
| Источник | CRM-система | Facebook |

Это один человек?

Выборка данных: решение



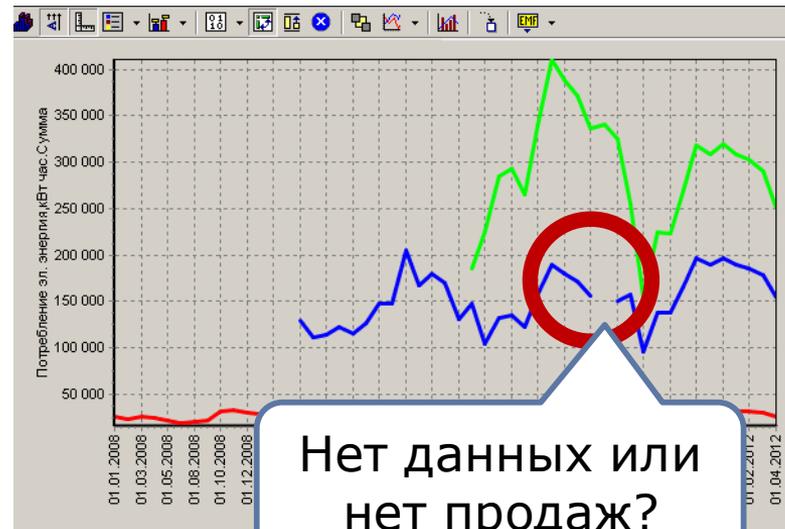
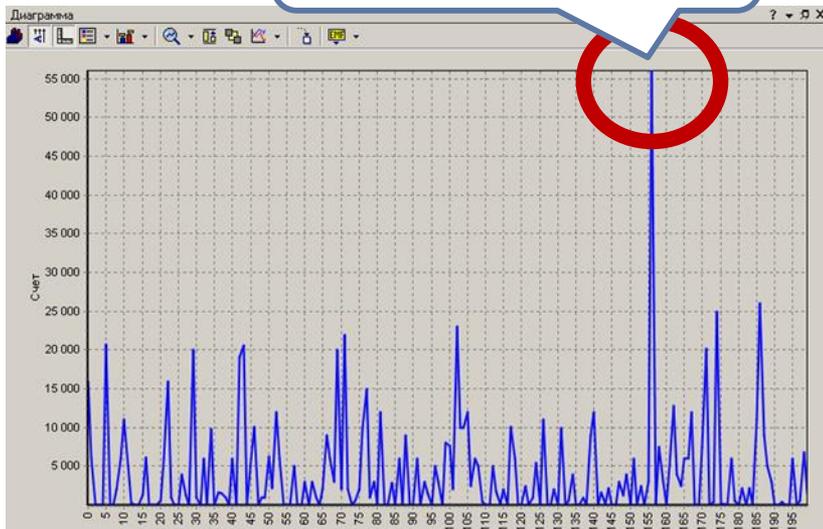
Оценка близости
и связывание

Очистка данных



Очистка данных: пример

Аномалия или норма?



Нет данных или нет продаж?

Очистка данных: решение

| Проблема | Вариант решения |
|--------------|---------------------------|
| Ошибки ввода | Проверить по справочникам |
| Пропуски | Интерполировать |
| Аномалии | Срезать выбросы |
| Дубли | Оставить одну запись |
| Противоречия | Удалить записи |

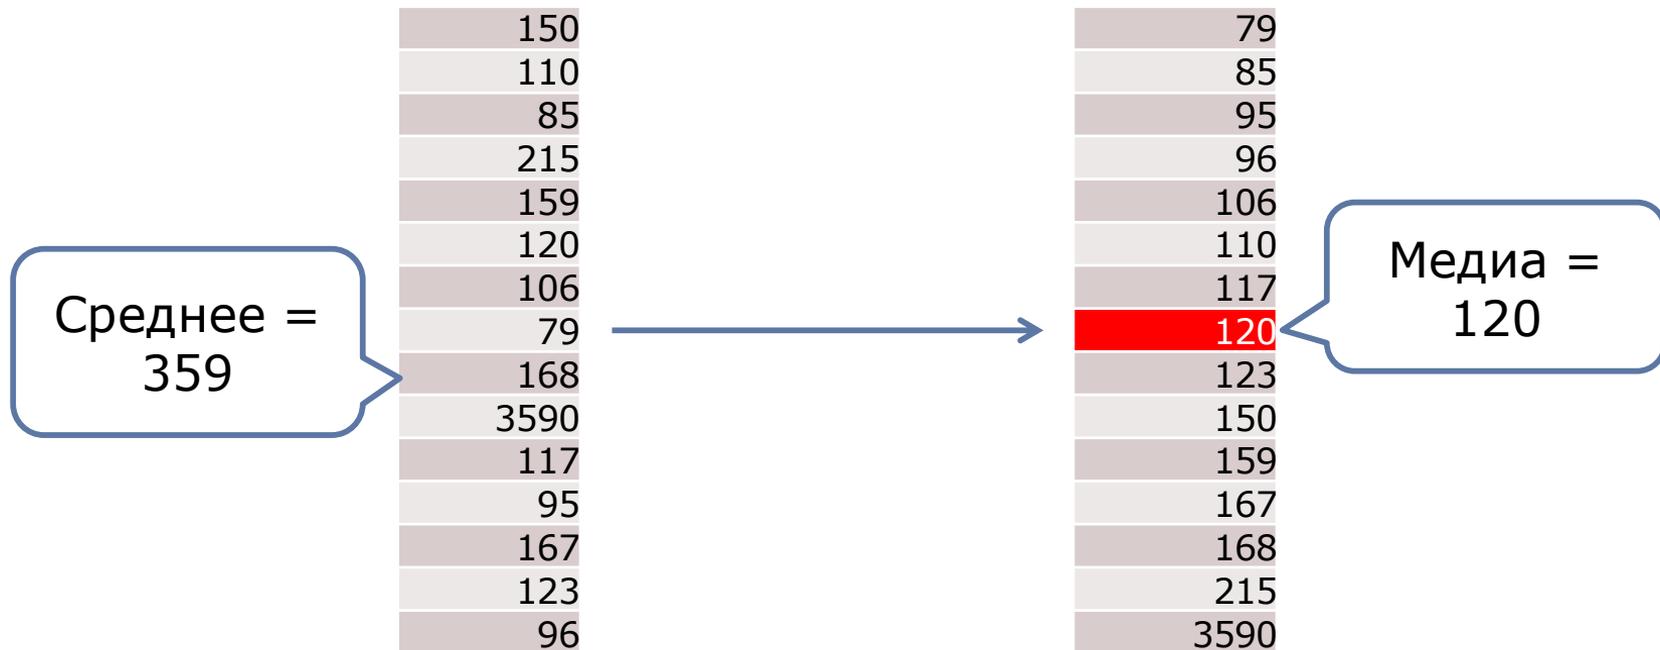
Трансформация



Трансформация: проблема



Трансформация: решение



Data Mining

Обобщение
опыта



Применение
модели



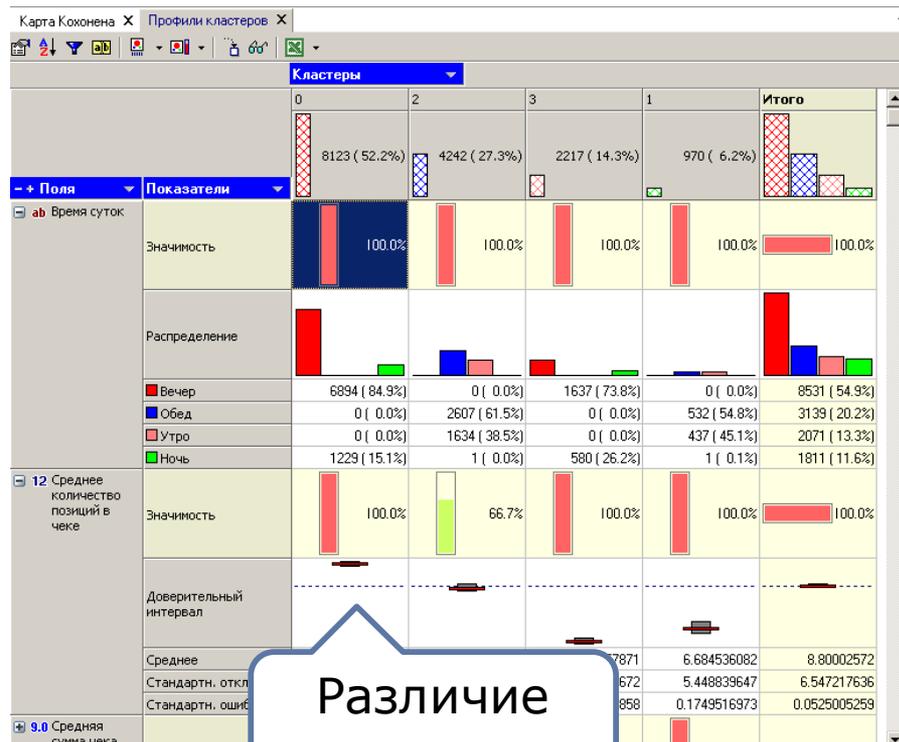
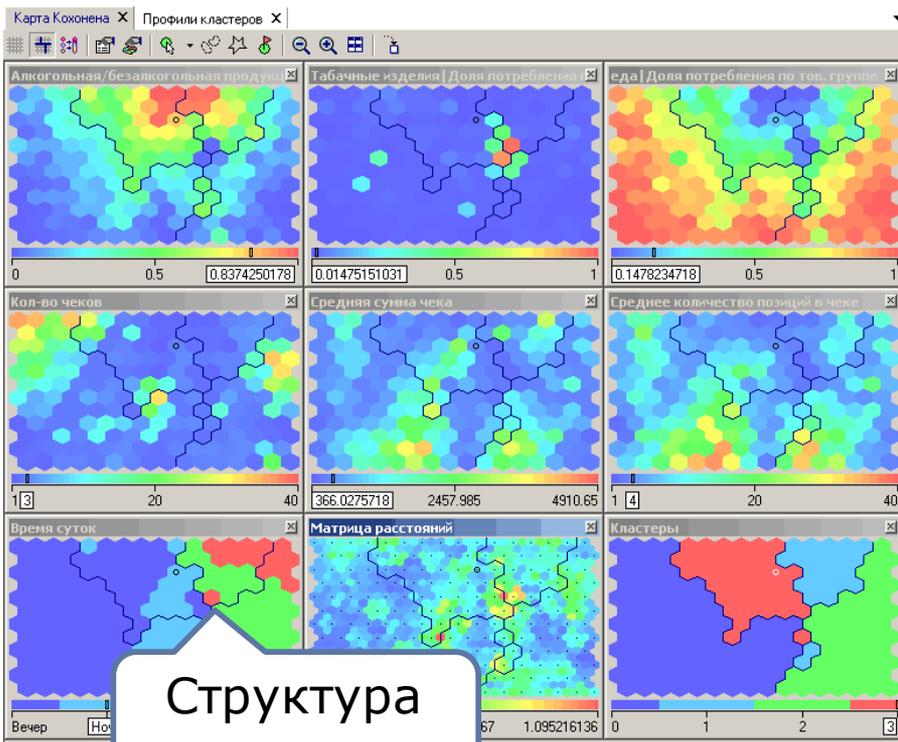
Интерпретация результатов

Трудно понять модель

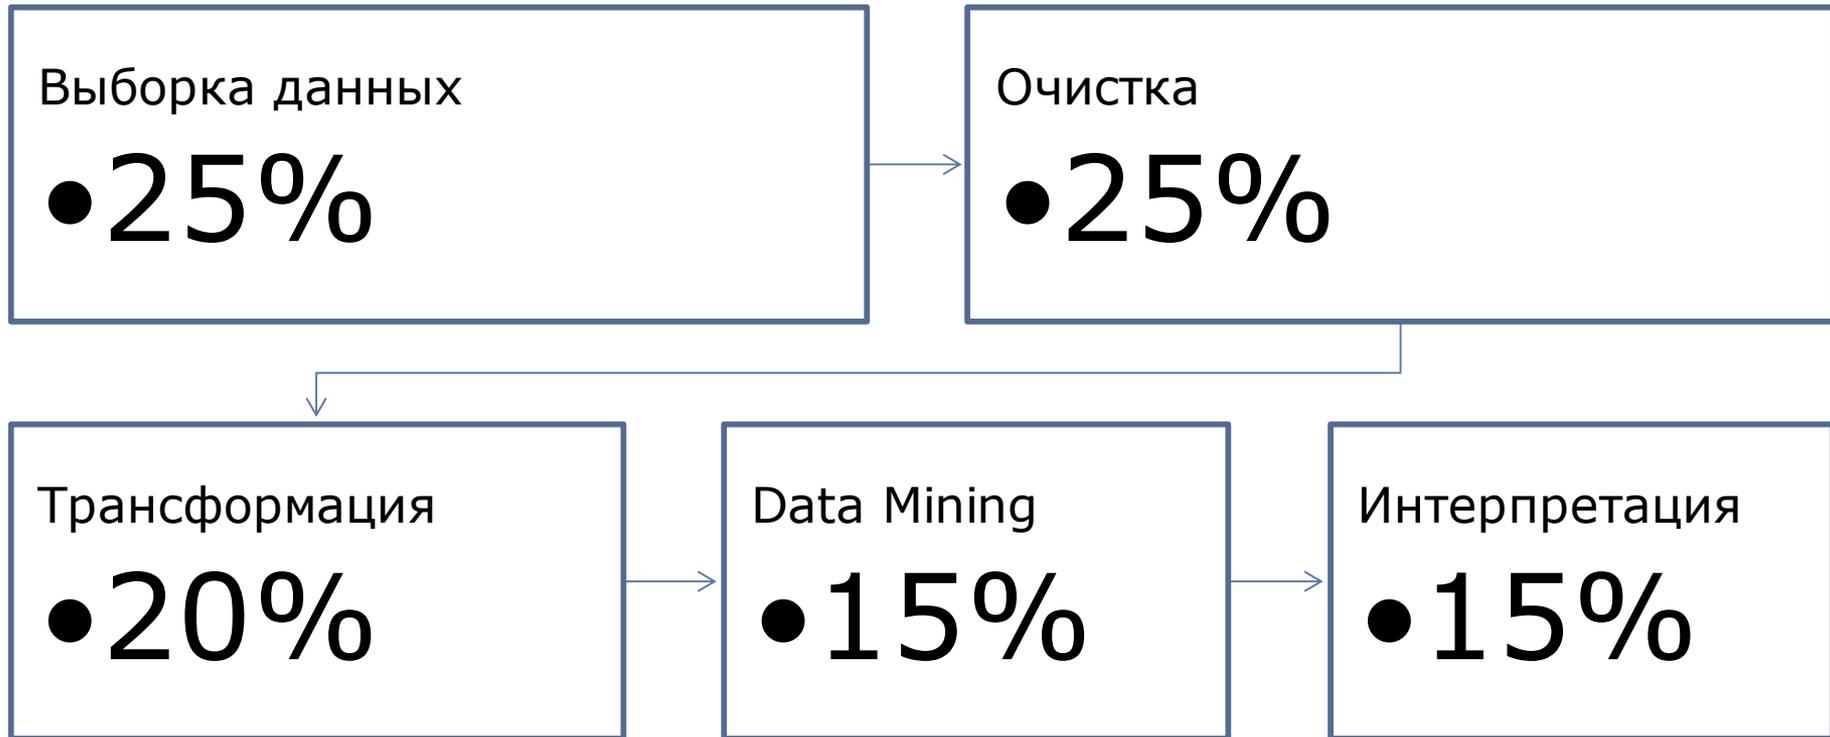
Нет доверия к результатам

Отказ в применении модели

Визуализация – способ понять



Трудоемкость этапов



Пример: прогнозирование

Выборка данных

- История продаж
- История остатков
- Маркетинговые акции
- Связывание данных

Очистка

- Заполнить пропуски
- Удалить аномалии

Трансформация

- Сгруппировать
помесячно
- Скользящее окно

Data Mining – моделирование

- Линейная регрессия
- Нейронная сеть

Интерпретация результатов

- Диаграмма рассеяния
- Ретро-прогноз
- Распределение ошибки

Пример: отток клиентов

Выборка данных

- История звонков
- Параметры тарифных планов

Очистка

- Исключить редкие события
- Удалить аномалии

Трансформация

- Сгруппировать по понедельно
- Сбалансировать классы

Data Mining – моделирование

- Логистическая регрессия
- Дерево решений

Интерпретация результатов

- Таблица сопряженности
- Дерево правил



BaseGroup Labs
ТЕХНОЛОГИИ АНАЛИЗА ДАННЫХ

Data Mining

Data Mining

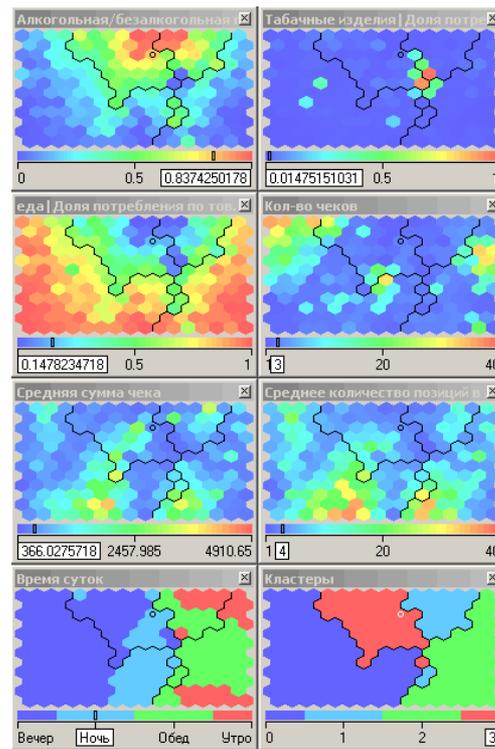
Data Mining – это процесс обнаружения

- в '**сырых**' данных
- ранее неизвестных **нетривиальных**
- практически **полезных** и
- доступных **интерпретации** знаний,
- необходимых для принятия **решений**

Классы задач Data Mining

- Кластеризация
- Регрессия
- Классификация
- Ассоциативные правила
- Последовательные шаблоны
- Анализ временных рядов
- Анализ связей
- Анализ отклонений

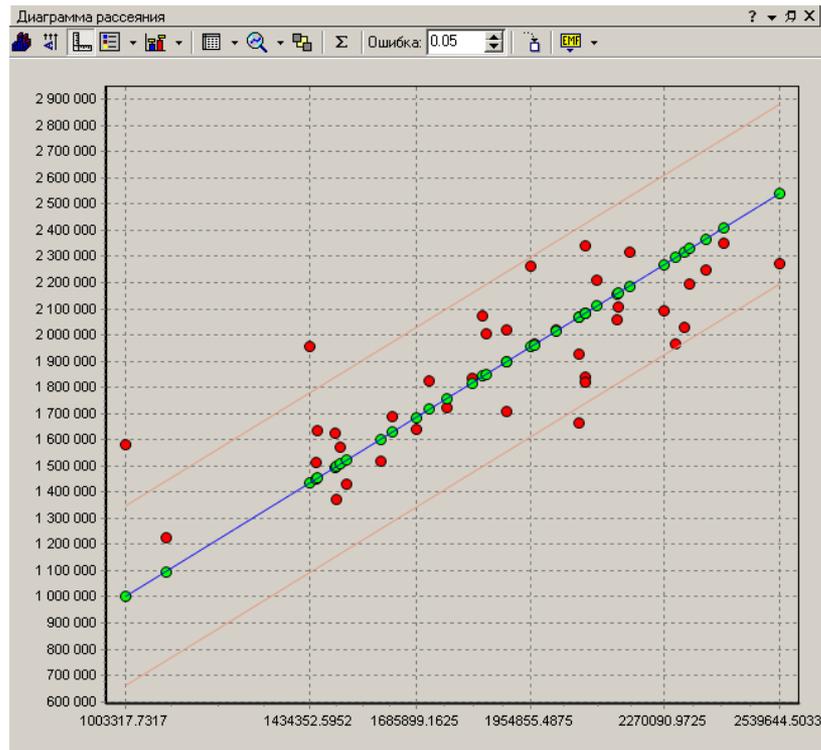
Объединение
«похожих» объектов
в сравнительно
однородные
группы, существенно
отличающихся от
других групп



Кластеризация: задачи

- Сегментация клиентов
- Выявление целевой аудитории
- Анализ миграции клиентов
- Канибализация товаров

Предсказание
значения
непрерывной
зависимой
переменной с
помощью
независимых
переменных

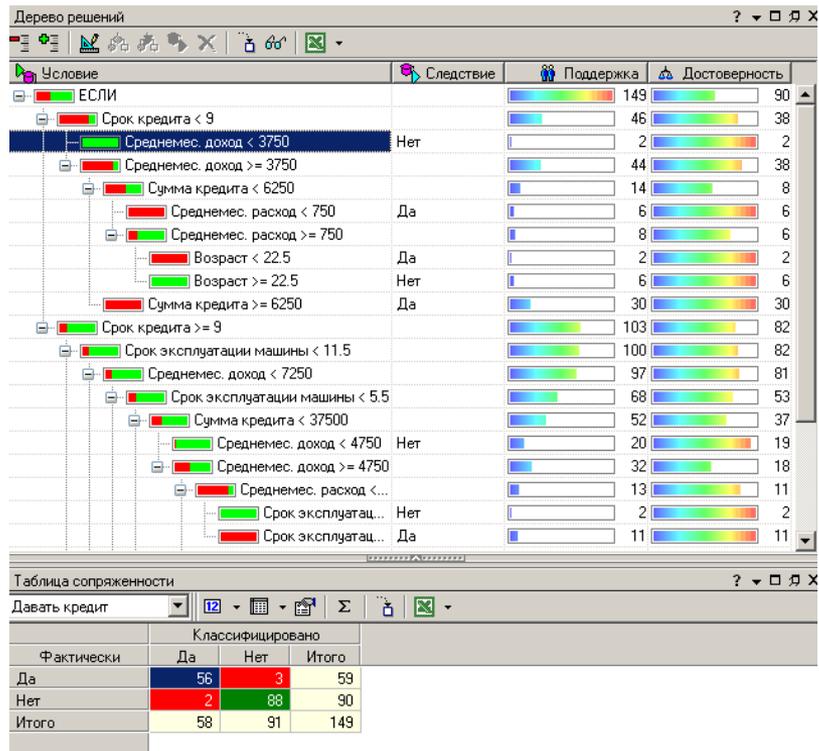


Регрессия: задачи

- Прогнозирование спроса
- Вероятность отклика на предложение
- Оценка эластичности цен
- Кредитный скоринг

Классификация

Отнесение объектов
к одному из
ИЗВЕСТНЫХ КЛАССОВ
с помощью
независимых
переменных



Классификация: задачи

- Оценка перспективности клиента
- Предсказание мошенничества
- Прогнозирование оттока
- Анализ рисков

Ассоциация

Обнаружение в транзакциях зависимостей, что из события X с определенной вероятностью следует событие Y

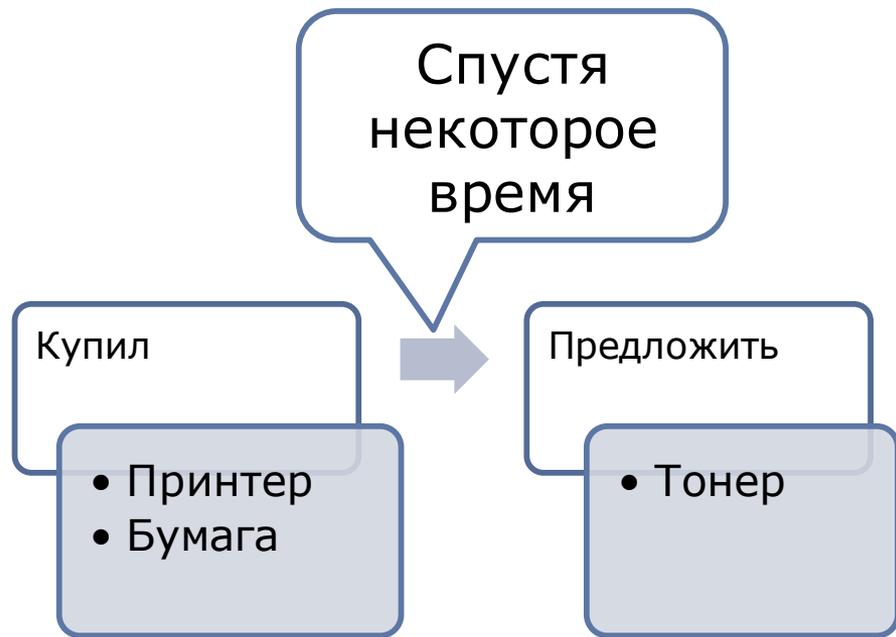
| Правила | | | | | | |
|------------------|------------------------|------------------------|-----------|------|---------------|-------|
| Правил: 65 из 65 | | | | | | |
| № | Условие | Следствие | Поддержка | | Достоверность | Лифт |
| | | | Кол-во | % | | |
| 52 | Срочный вклад | | 126 | 1.58 | 60.58 | 3.913 |
| 53 | Кредитные карты | Депозитные сертификаты | 126 | 1.58 | 28.25 | 1.152 |
| | Срочный вклад | | | | | |
| 54 | Депозитные сертификаты | Экспресс-кредит | 92 | 1.15 | 27.96 | 1.698 |
| | Кредитные карты | | | | | |
| 55 | Депозитные сертификаты | Кредитные карты | 92 | 1.15 | 39.48 | 2.551 |
| | Экспресс-кредит | | | | | |
| 56 | Кредитные карты | Депозитные сертификаты | 92 | 1.15 | 24.86 | 1.014 |
| | Экспресс-кредит | | | | | |
| 57 | Кобрендинговые карты | Срочный вклад | 142 | 1.78 | 51.08 | 4.520 |
| | Кредитные карты | | | | | |
| 58 | Кобрендинговые карты | Кредитные карты | 142 | 1.78 | 67.62 | 4.368 |
| | Срочный вклад | | | | | |
| 59 | Кредитные карты | Кобрендинговые карты | 142 | 1.78 | 31.84 | 1.825 |
| | Срочный вклад | | | | | |
| 60 | Кобрендинговые карты | Экспресс-кредит | 84 | 1.05 | 30.22 | 1.835 |
| | Кредитные карты | | | | | |
| 61 | Кобрендинговые карты | Кредитные карты | 84 | 1.05 | 37.33 | 2.412 |
| | Экспресс-кредит | | | | | |
| 62 | Кредитные карты | Кобрендинговые карты | 84 | 1.05 | 22.70 | 1.301 |
| | Экспресс-кредит | | | | | |
| 63 | Кредитные карты | Экспресс-кредит | 160 | 2.00 | 35.87 | 2.178 |
| | Срочный вклад | | | | | |

Ассоциация: задачи

- Анализ рыночной корзины
- Кросс-продажи (Cross-sale)
- Повышение доходности (Up-sale)
- Лучшее товарное предложение (Next Best Offer)

Последовательность

Выявление зависимости, что **после** события X , с определенной вероятностью наступит событие Y

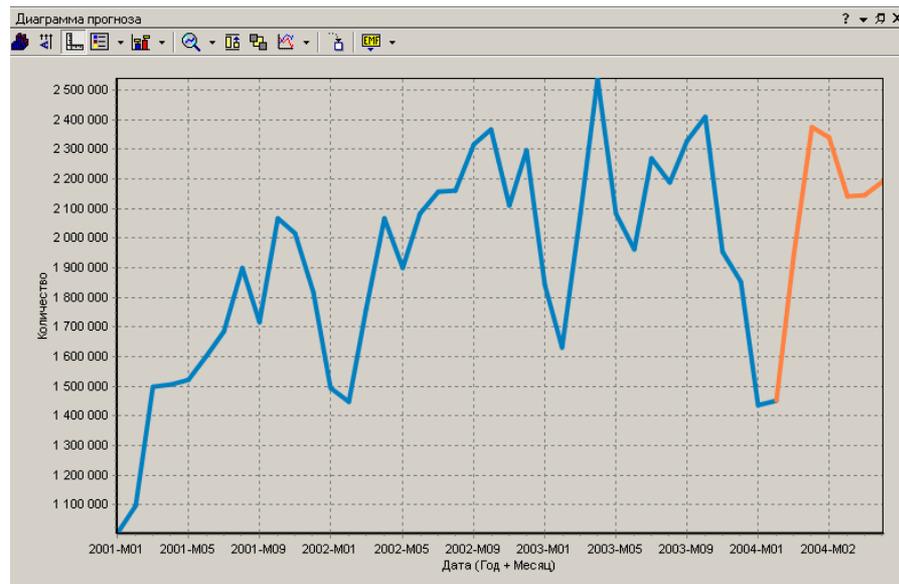


Последовательность: задачи

- Предсказание переходов по сайту
- Анализ отложенного спроса
- Оптимизация работы службы технической поддержки

Анализ временных рядов

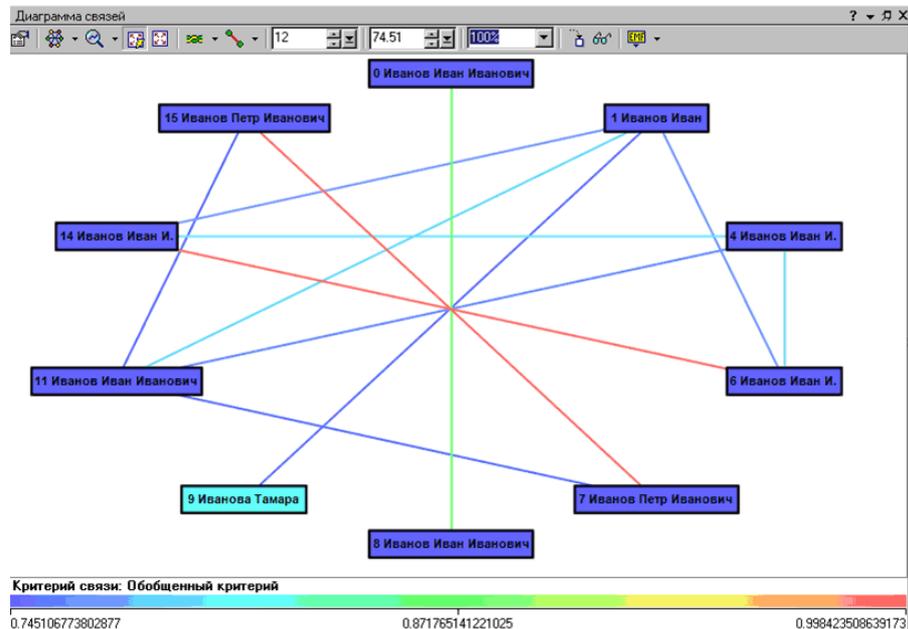
Предсказание
будущих значений
временного ряда по
настоящим и
прошлым значениям



Анализ временных рядов: задачи

- Прогнозирование спроса
- Оптимизация складских запасов
- Прогнозирование финансовых потоков
- Прогнозирование потребности в ресурсах

Выявление отношений между объектами сети для определения ранее неизвестных характеристик объектов



Анализ связей: задачи

- Противодействие мошенничеству
- Защита конфиденциальных данных
- Построение профилей клиентов
- Выбор каналов воздействия

Анализ отклонений

Обнаружение
наиболее
нехарактерных
случаев,
выбивающихся из
общих
закономерностей



Анализ отклонений: задачи

- Выявление подозрительной активности
- Анализ влияния маркетинговых акций
- Автоматический контроль выполнения KPI

Применение в бизнесе

Решение большинства задач бизнес-аналитики сводятся к описанным классам задач Data Mining или их комбинациям.

Кейс: МОШЕННИЧЕСТВО

Мошенничество в рознице

До 70% потерь происходит по вине персонала. Проблемная зона – касса:

- Воровство и обман покупателей
- Неправомерное использование скидок
- Начисление баллов на бонусные карты

Что такое мошенничество

Мошенничество – не только воровство, но и **осознанное** нарушение корпоративных правил работы:

- Начисление баллов на свою карту
- Использование служебной карты для родственников и знакомых

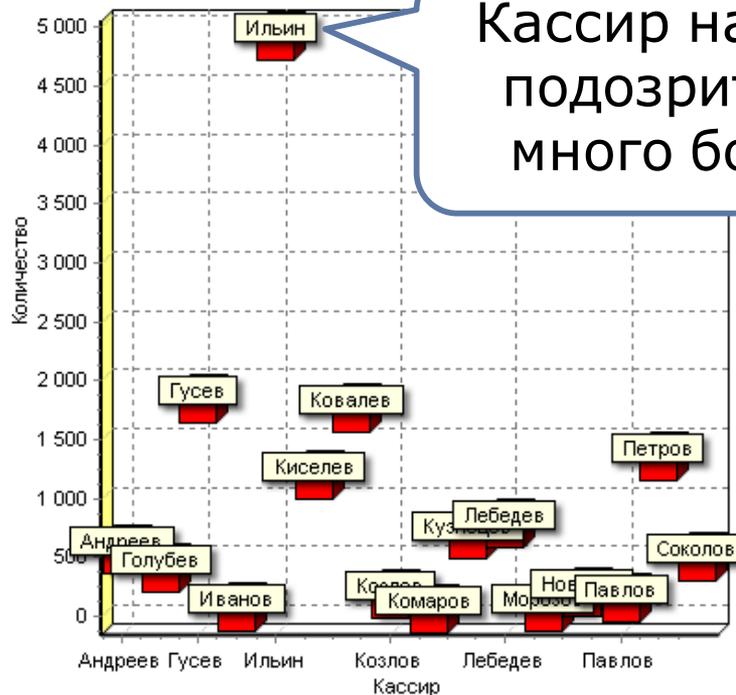
Выявление мошенничества

Противодействия мошенничеству базируются на выявлении последовательности подозрительных действий, оценке вероятности обмана и расчете финансовых потерь:

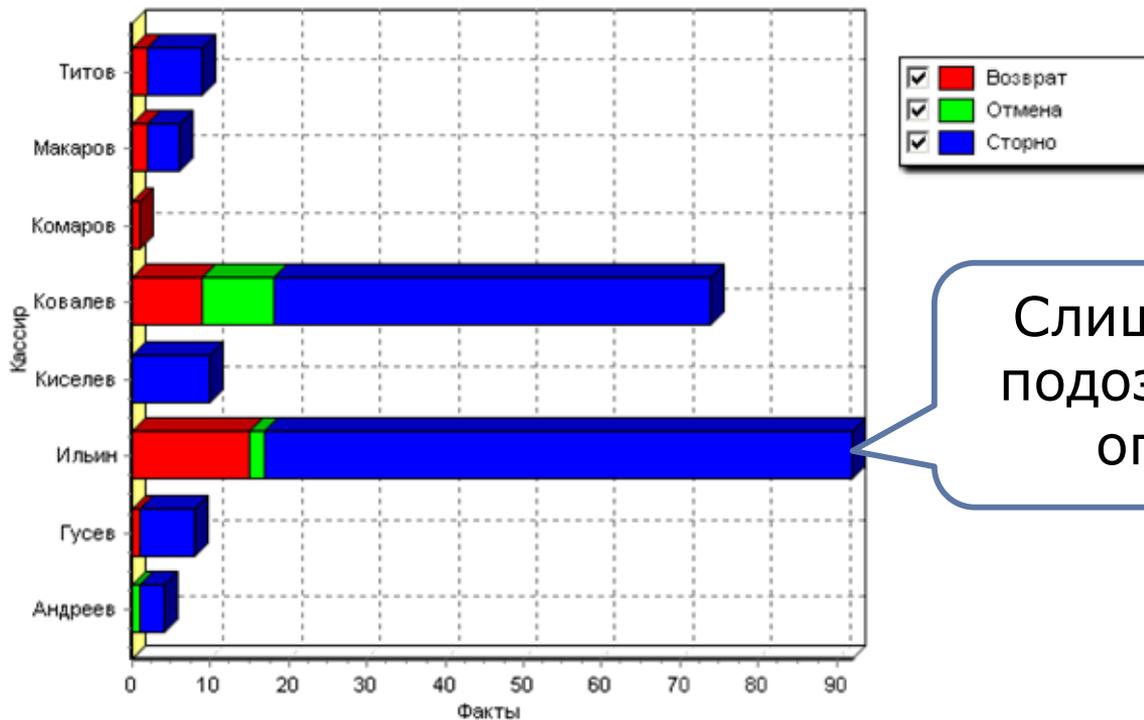
- Жесткие правила известных схем обмана
- Частотный анализ действий
- Аномальные выбросы во временных рядах
- Анализ последовательности действий
- Поиск подозрительных сочетаний
- Кластеризация транзакций

Много бонусов

| Магазин | Месяц | Вариант | # Количество | |
|---------------|---------------|----------------|--------------|--|
| Кассир | Σ Значение | % Процент | | |
| Ильин | 4 877 | 34,70% | | |
| Гусев | 1 796 | 12,78% | | |
| Ковалев | 1 720 | 12,24% | | |
| Петров | 1 306 | 9,29% | | |
| Киселев | 1 148 | 8,17% | | |
| Лебедев | 741 | 5,27% | | |
| Кузнецов | 653 | 4,65% | | |
| Андреев | 521 | 3,71% | | |
| Соколов | 452 | 3,22% | | |
| Голубев | 358 | 2,55% | | |
| Новиков | 153 | 1,09% | | |
| Козлов | 147 | 1,05% | | |
| Павлов | 105 | 0,75% | | |
| Морозов | 33 | 0,23% | | |
| Иванов | 30 | 0,21% | | |
| Комаров | 16 | 0,11% | | |
| Итого: | 14 056 | 100,00% | | |



Аномальное сторно



Слишком много
подозрительных
операций

Странный возврат

Создан чек

| № транзакции | Дата транзакции | Время транзакции | Тип транзакции | № ККМ | № чека | № возвр. чека | Код кассира | Код товара | Цена | Количество | Сумма |
|--------------|-----------------|------------------|-------------------------|-------|--------|---------------|-------------|------------|------|------------|-------|
| 82721 | 40319 | 18:19:15 | 11 – регистрация товара | 2 | 7095 | | | 8 1583 | 56.4 | 3 | 169.2 |
| 82722 | 40319 | 18:19:20 | 11 – регистрация товара | 2 | 7095 | | | 8 249875 | 15.5 | 12 | 186 |
| 82723 | 40319 | 18:19:27 | 11 – регистрация товара | 2 | 7095 | | | 8 13752 | 35 | 8 | 280 |
| 82724 | 40319 | 18:19:51 | 40 – оплата | 2 | 7095 | | | 8 | | | 635.2 |
| 82725 | 40319 | 18:19:51 | 55 – закрытие чека | 2 | 7095 | | | 8 | | | 635.2 |

| № транзакции | Дата транзакции | Время транзакции | Тип транзакции | № ККМ | № чека | № возвр. чека | Код кассира | Код тов. | Цена | Кол-во | Сумма |
|--------------|-----------------|------------------|-----------------------------|-------|--------|---------------|-------------|----------|------|--------|-------|
| 83326 | 40319 | 19:53:33 | 80 – возврат по номеру чека | 2 | 7175 | 7095 | 8 | | | | |
| 83327 | 40319 | 19:53:50 | 13 – возврат | 2 | 7175 | 7095 | 8 | 13752 | 35 | -2 | -70 |
| 83328 | 40319 | 19:53:40 | 40 – оплата | 2 | 7175 | 7095 | 8 | | | | -70 |
| 83329 | 40319 | 19:53:55 | 55 – закрытие чека | 2 | 7175 | 7095 | 8 | | | | -70 |

Отмена чека через час

Плохие сочетания

Кластеров: 2 из 2 Фильтр: Без фильтрации

| № | Номер кластера | Количество транзакций | Ширина кластера | Мощность кластера |
|---|----------------|-----------------------|-----------------|-------------------|
| 0 | 0 | 12 | 3 | 36 |
| 1 | 1 | 16 | 10 | 78 |

Кластер 0

| Элементы |
|--------------------|
| регистрация товара |
| оплата |
| закрытие чека |

Профиль
нормального
чека

Кластер 1

| Элементы |
|---------------------------|
| возврат |
| возврат по номеру чека |
| детализация скидки на чек |
| закрытие чека |
| оплата |
| отложенный чек |
| отмена чека |
| регистрация товара |
| скидка на чек, % |
| сторно |

Профиль
«плохого»
чека



BaseGroup Labs
ТЕХНОЛОГИИ АНАЛИЗА ДАННЫХ

Big Data

Обвал данных

- Каждый день в мире генерируется 10^{18} байт информации
- 90% всех существующих данных созданы за последние 2 года
- Каждый час Wal-Mart генерирует данных в 170 раз больше объема данных Библиотеки Конгресса США



Проблемы больших данных:

- **Volume** – огромные объемы данных
- **Velocity** – высокая скорость генерации **НОВЫХ** данных
- **Variety** – многообразие структурированных и неструктурированных источников данных

Потенциал Big Data

- Мнение клиентов
- Рекомендательные системы
- Массовая кастомизация услуг
- Противодействие оттоку
- Борьба с мошенничеством
- Построение профилей клиентов

Знания из данных

Ручная обработка огромных потоков данных практически бесполезна.

Технологии Data Mining – реальный способ извлечь **ценные знания** из Big Data, превратив умение анализировать данные в конкурентное преимущество.



BaseGroup Labs
ТЕХНОЛОГИИ АНАЛИЗА ДАННЫХ

basegroup.ru