АНАЛИЗ ДАННЫХ

Введение в анализ данных

Вначале были данные

Есть база данных:

Например, БД банка.

Хранит персональные данные, счета, кредиты и т.д.

Источник данных

- Сама по себе БД пользы не несет
- Добавим **оперативный источник данных** (ОИД)

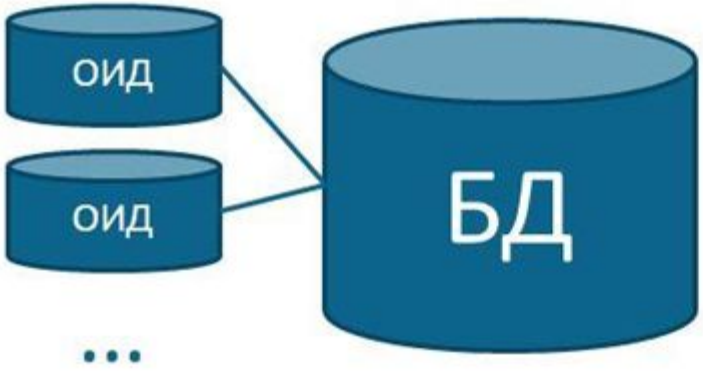

Для банка это терминалы, базы локальных отделений и т.д.

Работа с транзакциями

- Нужна обработка данных в БД
- Добавим **Online Transaction Processing** (OLTP)

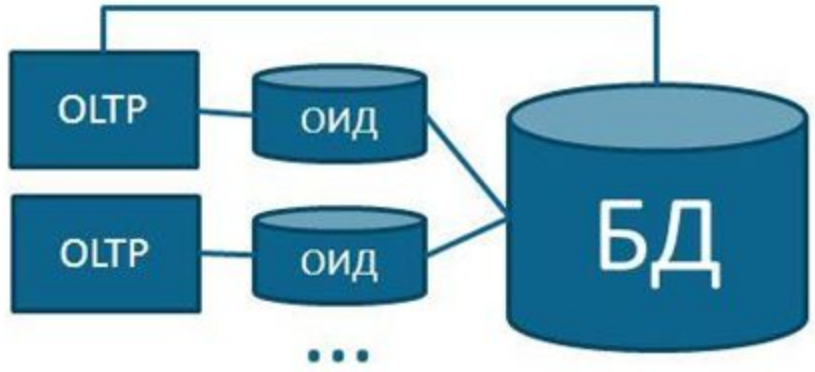

Взаимодействует с ОИД и БД.

Примеры операция для банка: узнать счет, перевести деньги, пополнить баланс.

Особенности OLTP

- Важна скорость работы – результат максимум за пару секунд
- Простые операции с данными (около CRUD)
- Высокая частота вызовов => постоянная средняя загруженность процессора
- Работа только с оперативными данными

Аналитическая система

- Нужна более сложная система для работы с БД
- Добавим **Online Analytical Processing** (OLAP)

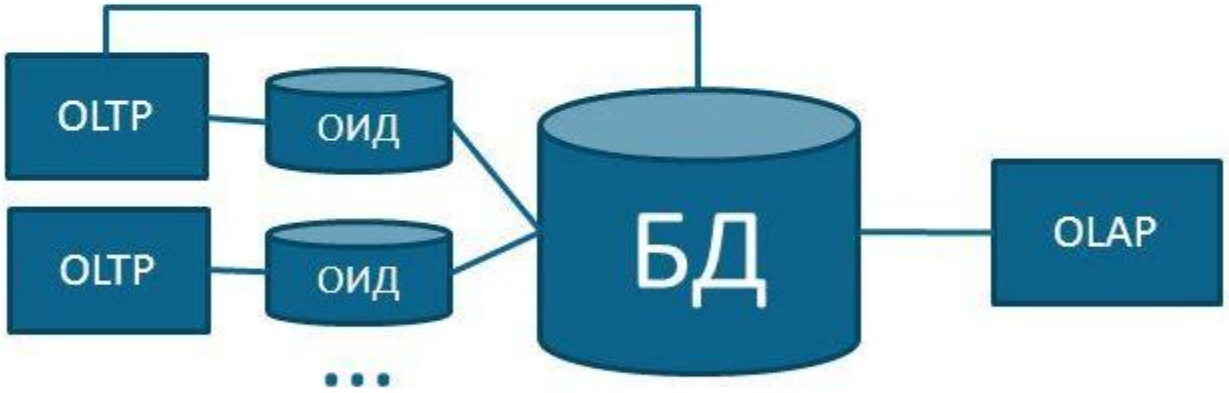

Взаимодействует с БД.

Примеры для банка: найти подозрительные переводы, определить кредитоспособность

Особенности OLAP

- Важна точность анализа
- Сложные запросы, функции, процедуры
- Периодические вызовы чередуются с простоем. Нагрузка на процессор непостоянна.
- Работа с большой коллекцией данных

OLTP и OLAP во время работы

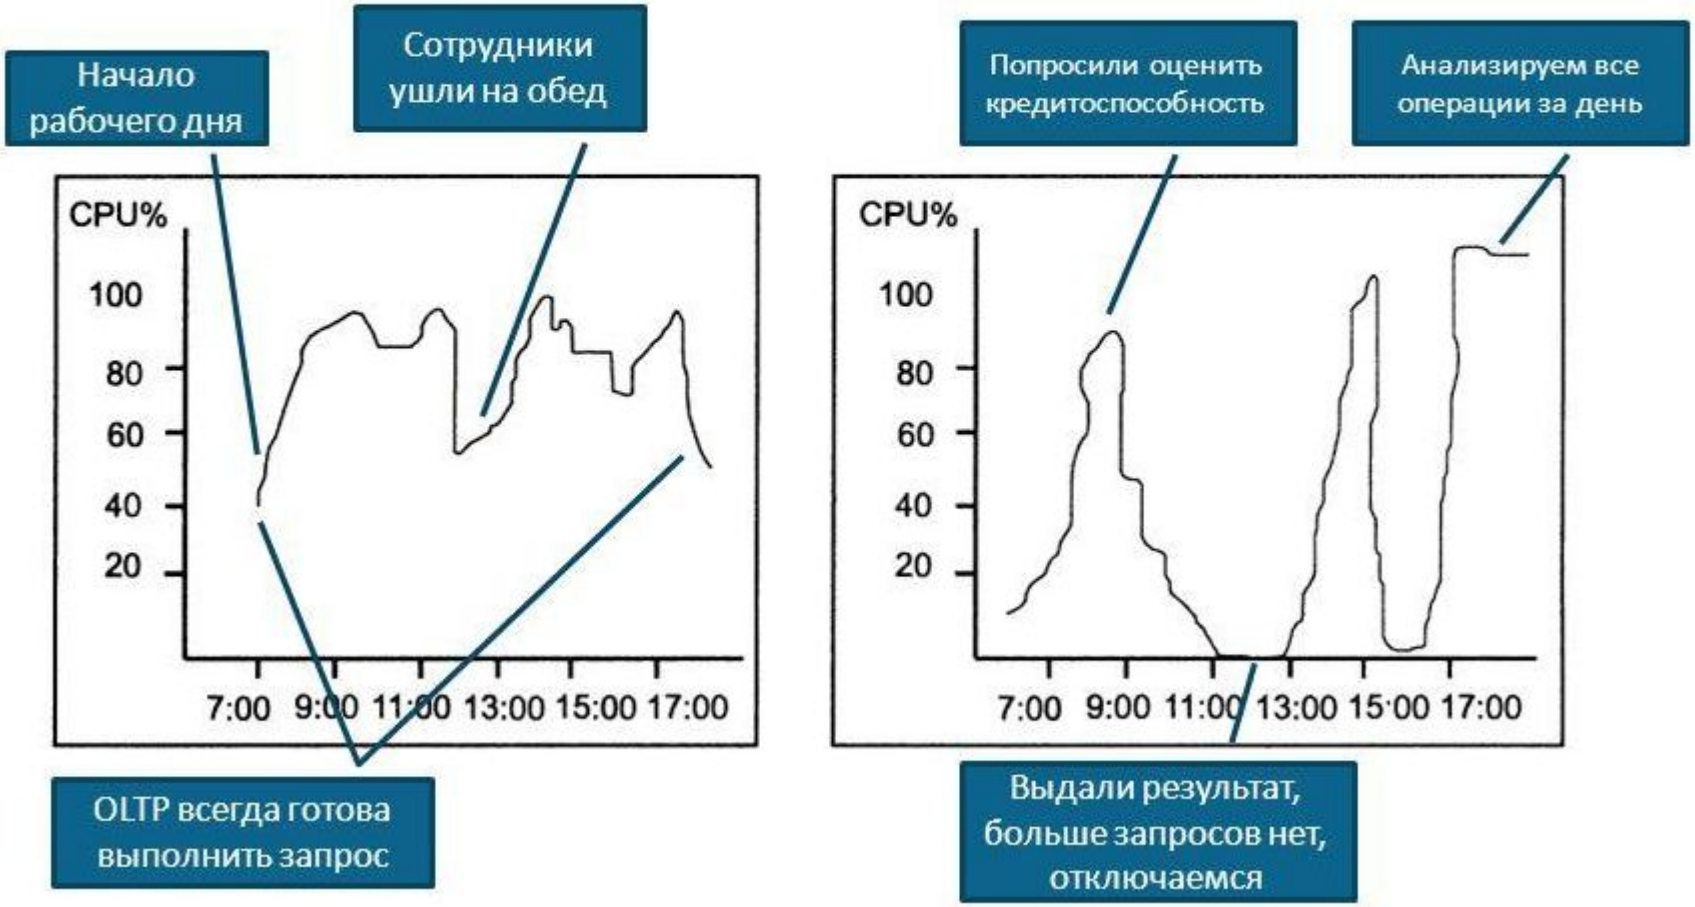

Возможности OLAP

Может:

- Определить кредитоспособность по имеющимся правилам
- Прогнозировать прибыль банка на основе моделей и гипотез

Не может:

- Предложить правило оценки кредитоспособности
- Сгенерировать модель или гипотезу

Анализ данных

- Нужна система генерации гипотез
- Вот и **Анализ Данных** (Data Mining)

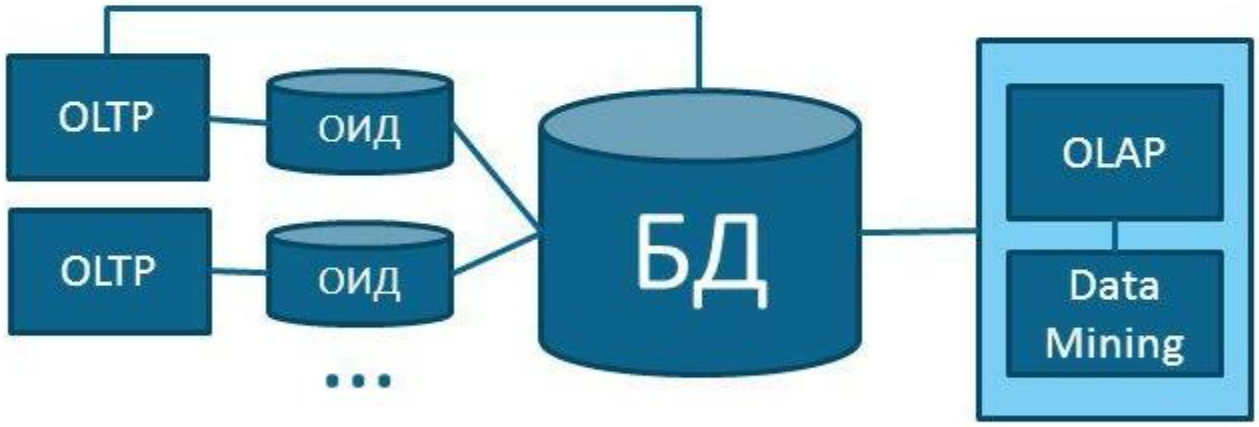

Примеры для банка:

- Выяснить зависимость кредитоспособности человека от наличия высшего образования
- Каковы признаки подозрительных переводов?

Система поддержки принятия решений

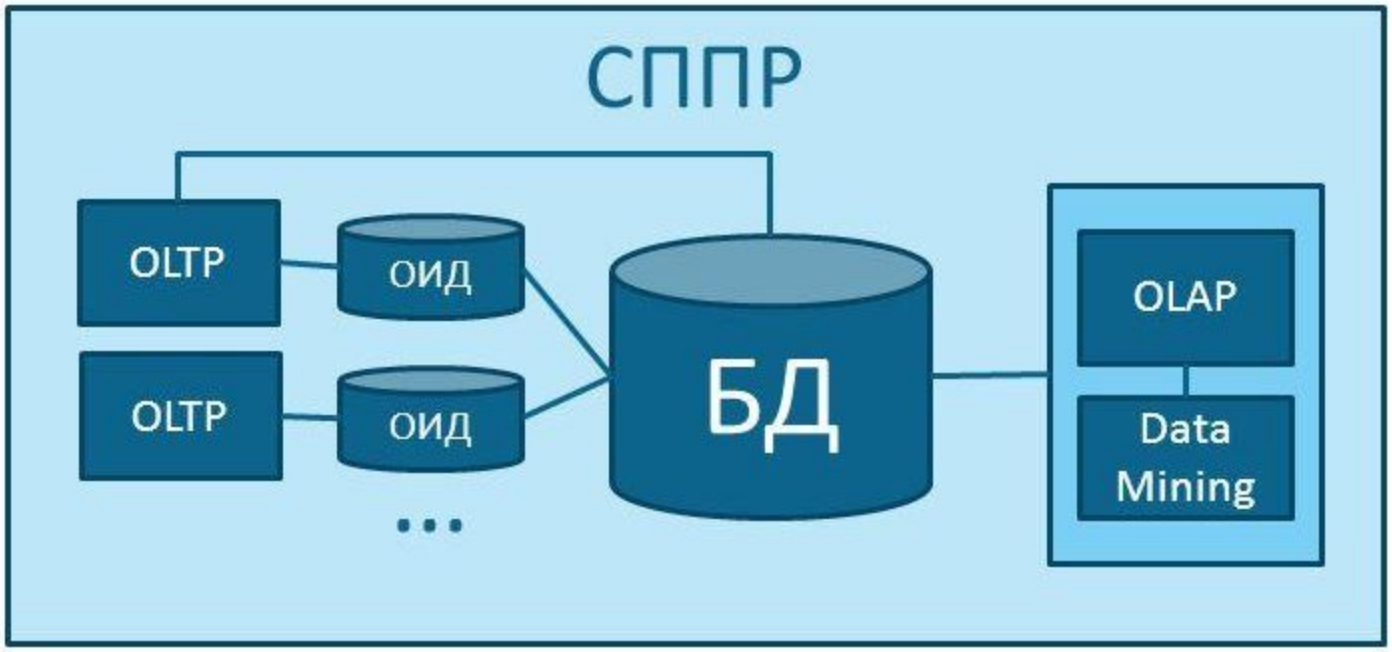

Комплекс для **сбора**, **хранения** и **анализа** информации

Определение

Анализ Данных - это процесс обнаружения в *«сырых»* данных ранее неизвестных нетривиальных практически полезных и доступных интерпретации знаний, необходимых для принятия решений в различных сферах человеческой деятельности.

Примеры для самопроверки

Какие правила являются успешным результатом анализа данных:

- Если фигура - четырехугольник, то сумма его углов равна 360 градусам
- Во время беспорядков повышается спрос на бейсбольные биты
- Если что-то выглядит как утка и крякает как утка, то это вероятно это и есть утка
- Вместе с хлебом люди часто покупают молоко
- Люди старше 60 не ищут ночные клубы в Москве

Примеры для самопроверки

Какие правила являются успешным результатом анализа данных:

- Если фигура - четырехугольник, то сумма его углов равна 360 градусам

- уже известная информация

- Во время беспорядков повышается спрос на бейсбольные биты

+ полезно на будущее

- Если что-то выглядит как утка и крякает как утка, то это вероятно это и есть утка

- тривиальная информация

- Вместе с хлебом люди часто покупают молоко

+ можно продавать комплектом

- Люди старше 60 не ищут ночные клубы в Москве

- практически бесполезное знание

Типичные задачи АД

- Классификация (Classification)
- Кластеризация (Clustering)
- Ассоциация (Associations)
- Визуализация (Visualization, Graph Mining)
- Последовательность (Sequence)
- Прогнозирование (Forecasting)
- Определение отклонений (Deviation Detection)
- Анализ связей (Link Analysis)

Примеры задач классификации

- Определение DDoS-атак
- Спам-фильтры
- Привлечение выгодных клиентов (определение целевой аудитории продукта)
- Определение профиля ДНК

Примеры задач кластеризации

- Группировка документов по темам
- Идентификация людей на записях с камер видеонаблюдения
- Кластеризация тикетов
- Кластеризация структуры фондового рынка

Примеры задач поиска ассоциаций и последовательностей

- Рекомендации товаров
- Обнаружение скрытых факторов влияния

Примеры задач визуализации

- Связи в социальных сетях
- Пробки на дорогах
- Инфографика

Семейство направлений АД

- **Web Mining** – специализируется на анализе страниц в интернете (определение тИЦ, выделение модульной сетки сайта)
- **Opinion Mining** – специализируется на анализе отношений пользователей к различным объектам (whatdoestheinternetthink.net)
- **Information Retrieval** – поиск неструктурированной информации в текстовых документах (поисковые системы)

Основные определения

- **Данные** – необработанный материал, используемый для формирования информации на основе данных.

Например, текст документа

Основные определения

- **Объект -** описывается как набор атрибутов

Сам текстовый документ

- **Атрибут** - свойство, характеризующее объект.

Имя: Текстовый документ (42).txt
Размер документа: 5кб
Дата создания: 05.09.2011

Основные определения

- **Генеральная совокупность** (population) - вся совокупность изучаемых объектов, интересующая исследователя.
- **Выборка** (sample) - часть генеральной совокупности

Основные определения

- **Параметры** - числовые характеристики генеральной совокупности.
- **Статистики** - числовые характеристики выборки.

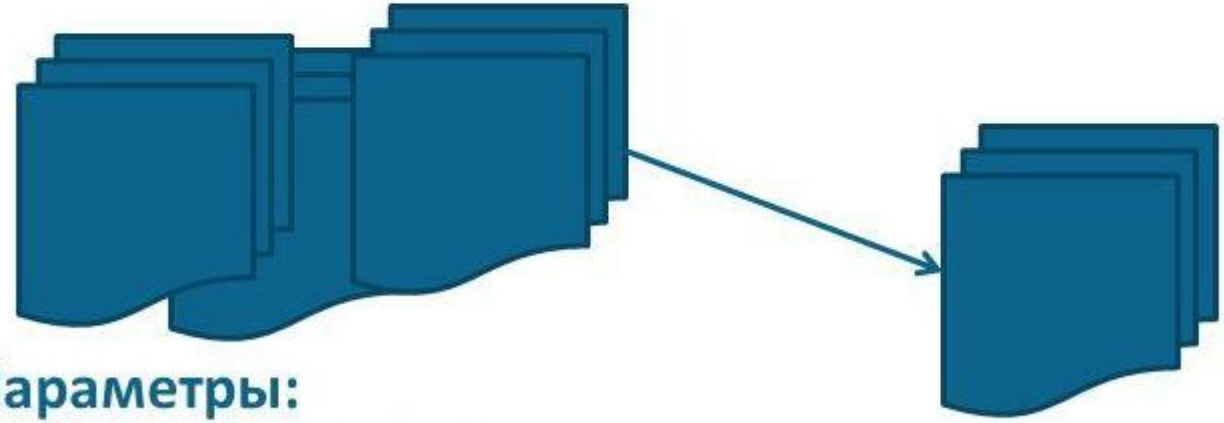

Параметры:
Научные статьи: 30%
Анекдоты: 70%

Статистика:
Научные статьи: 32%
Анекдоты: 68%

Основные определения

- **Гипотеза** - частично обоснованная закономерность знаний, служащая либо для связи между различными эмпирическими фактами, либо для объяснения факта или группы фактов.

Гипотеза:
Если файл < 5кб, то он
скорее всего содержит анекдоты

Основные определения

- **Измерение** - процесс присвоения чисел характеристикам изучаемых объектов согласно определенному правилу.

Количество слов:
количество пробельных символов + 1

Шкалы измерений

Номинальная шкала (nominal scale) -содержит только категории

- Нельзя упорядочить
- Доступные операции: ==, !=

Пример: месяцы, царства животного мира, категории статей

Дихотомическая шкала (dichotomous scale) - шкала, содержащая только две категории.

Пример: бит, пол

Шкалы измерений

Порядковая шкала (ordinal scale) - шкала, в которой числа присваивают объектам для обозначения относительной позиции объектов, но не величины различий между ними.

- Доступные операции: ==, !=, >, <

Пример: место в рейтинге

Шкалы измерений

Интервальная шкала (interval scale) - шкала, разности между значениями которой могут быть вычислены, однако их отношения не имеют смысла.

- Доступные операции: ==, !=, >, <, +, -

Пример: температура

Шкалы измерений

Относительная шкала (ratio scale) - шкала, в которой есть определенная точка отсчета и возможны отношения между значениями шкалы.

- Доступные операции: ==, !=, >, <, +, -, *, /

Пример: вес и размеры предметов