



# Анализ больших данных на платформе Oracle

## *Ольга Горчинская*

# *Директор по исследовательским проектам Форс*

# План

- Краткое введение в Big Data
- Технологии и продукты Oracle для больших данных
- Эксперименты и проекты
- Вопросы и ответы



# Введение в Big Data

# Большие Данные

- Сверхбольшие объемы структурированных и неструктурированных данных, с которыми трудно работать с помощью традиционных средств
- Впервые термин появился 3 сентября 2008 года, Клиффорд Линч, редактор научного журнала Nature, в связи с возможностями для науки накопления научных данных
- Источники больших данных – интернет-документы, социальные сети, блоги, измерительные устройства, радиочастотная идентификация, устройства ауди и видеорегистрации
- Инновационные технологии сбора, хранения данных (Hadoop, MapReduce, NoSQL базы данных и др)
- Новая парадигма анализа данных




vvv  
**Velocity, Volume, Variety**  
(скорость, объем,  
многообразие)

# Новые подходы к решению бизнес-задач

*Анализ статистики поисковых запросов Google показал, что примерно за несколько недель до того, как медики объявляют об эпидемии гриппа, в этом регионе отмечается всплеск поисковых запросов по его лечению. То есть, анализ запросов сообщает нам о начале эпидемии быстрее, чем официальная медицина*

# Технологии и инструменты

- Hadoop & MapReduce
- NoSQL базы данных
- Углубленная аналитика
  - Статистика,
  - предиктивная аналитика и *data mining*
  - Лингвистическая обработка текстов
- Инструменты класса Data Discovery





# Hadoop

- Система распределенных вычислений, проект фонда Apache Software Foundation
- Свободно распространяемые функции, утилиты, framework для разработки и выполнения распределённых программ, работающих на кластерах из сотен и тысяч узлов
- Разработка Hadoop началась в 2005г Дугом Каттингом (Doug Cutting) под влиянием публикации сотрудников Google (Джеффри Дин и Санжай Гемават) о вычислительной концепции MapReduce
- 2008г: в феврале Yahoo запустила кластерную поисковую машину на 10 тыс ядер под управлением Hadoop; апрель – побит мировой рекорд по стандартным тестам на сортировку (1ТБ – 209 сек – 910 узлов)
- Yahoo (более 4 тыс. Узлов, 15 Пбайт каждый), Facebook (около 2 тыс. узлов на 21 Пбайт) и Ebay (700 узлов на 16 Пбайт)

# Общие принципы построения Hadoop систем

- Компоненты: Hadoop Common, HDFS, YARN, Hadoop MapReduce
- Большое количество (до десятков тысяч) узлов, на основе относительно дешевого оборудования
- Каждый узел является сервером и хранения и обработки
- Обработка данных ведется в массивно-параллельном режиме
- MapReduce
- Данные хранятся в нескольких копиях (обычно в трех) и отказ узла или двух не ведет к потере данных
- Система практически неограниченно масштабируется

# NoSQL базы данных

Not  
Only SQL

- Нереляционные СУБД
- Позволяют горизонтально масштабироваться
  - Данные хранятся в копиях (обычно 3) на разных серверах
  - Отказ узла не приводит к потере данных
  - Чтение производится с мастера или копий
- Всю логику обрабатывает приложение
- Преимущество -- скорость обработки


# NoSQL базы данных

Not  
Only SQL

- Нет традиционной структурированной схемы
  - Часто данные хранятся в схеме Key-Value
  - Интерпретация смысла данных – в приложении
- Целостность данных поддерживается не так жестко, как в традиционных RDBMS
- Нет стандартов
  - Существует около 130 NoSQL СУБД, очень много OpenSource


# Язык статистических исследований R

- Open source проект, R Foundation
- Язык для статистических исследований и работы с графикой (Росс Айхэк, Роберт Джентельмен, Оклендский ун-т, 1997)
- Широкий спектр различных функций (временные ряды, прогнозирование, классификация, кластеризация)
- Возможность расширения, технология разработки дополнительных пакетов участниками проекта (астеризация и др) -- 2014г более 5500 пакетов
- Высокий уровень популярности




The R Project for Statistical Computing  
<http://www.r-project.org/>

# Визуализация в R



» Random entries






Частично благодаря появлению концепции *Big Data*, бизнес-анализ(BI) остается быстро растущим рынком .... Одновременно с ростом рынка BI постоянно увеличиваются инвестиции в предиктивную аналитику; **R является не только хорошим готовым инструментом, но и идеальной средой для исследований в области углубленной аналитики.** R ориентирован на расширения и интегрируется с инструментами бизнес-анализа , обогащая отчеты глубокой аналитикой.

Gartner.

### Hype Cycle for Analytic Applications, 2011, 30 August 2011

<http://www.gartner.com/technology/core/products/research/topics/businessIntelligence.jsp>



Кол-во f web site линков, которые указывают на основной сайт инструментальной среды March 19, 2011.

<http://www.r4stats.com/popularity>

# Автоматическая обработка текстов

- Поддержка русского языка
- Продукты отечественных компаний
- Иногда можно обойтись без глубокой лингвистики, но почти всегда нужна морфология
- Возможности инструментов
  - *Поиск с учетом морфологии, синтаксиса, семантики*
  - *Извлечение сущностей или объектов*
  - *Извлечение фактов*
  - *Классификация, рубрикация, тональность*
  - *Определение тематики*



# Технологии RCO ([www.rco.ru](http://www.rco.ru))



- Содержательный портрет текста
- Упоминания персон и организаций
- Упоминания особых объектов
- Распознавание ситуаций в тексте
- Отношение к объекту в тексте
- Разбор частично-структурированного текста
- Тематическое рубрирование текстов
- Кластеризация новостей
- Поиск документов
- Выявление заимствований и поиск похожих текстов
- ...




# ABBYY Compreno

## Семантический разбор текста и визуализация

Г-н Тешич должен был принять меры, для того чтобы стоимость оружия, которое, по его словам, он экспортировал в Нигерию, соответствовала сумме поступивших денег. Г-н Тешич должен был скрыть те дополнительные суммы, которые он сумел заработать, нарушая санкции. С этой целью он, возможно, разработал сложный план с использованием фирмы «Ваксом» и счетов в швейцарских банках. Выплаченная сумма в 250 000 долл. США, которая 9 мая 2002 года была переведена на счет в банке «ЮБС Свайцерлаенд», принадлежащей руководителям компании «Ваксом анштальт», может представлять собой часть разыскиваемых дополнительных поступлений по части партии оружия, отправленного в Либерию. Лицейский банк «Аль-Мариярид банк» перевел деньги со счета № 0001-202662-СС1 в Швейцарию, без указания личности владельца счета. В конфиденциальной информации, связанной с этим переводом, говорится, что эти средства были переведены от имени компании «Джифф корпорейшн». Через несколько дней после того, как на счет фирмы «Ваксом» поступили 250 000 долл. США, Г-н Тешич распорядился о переводе 5000 долл. США, 300 000 долл. США, и 45 000 долл. США на три различные счета лиц, которые, возможно, не связаны с назначением звандаго. Дополнительная сумма в 90 000 долл. США была переведена на принадле

- факты
- персоны
- время
- организации
- локация
- деньги, счет



# От бизнес-анализа к исследованию данных

## *Business Intelligence*

- Анализ числовых показателей
- Внутренние данные
- Устойчивый состав данных
- Качество и точность данных




## *Data Discovery*

- Преобладают поисковые операции
- «Чужие» данные
- Состав данных быстро изменяется
- Не качество, а количество



# Технологии и инструменты

- Hadoop & MapReduce
- NoSQL базы данных
- Углубленная аналитика
  - Статистика,
  - предиктивная аналитика и *data mining*
  - Лингвистическая обработка текстов
- Инструменты класса Data Discovery



**Hardware and Software**  
**ORACLE**  
**Engineered to Work Together**

# Платформа Oracle для Big Data

# Платформа Oracle для больших данных



Oracle  
Big Data Appliance



Сбор

Обработка

Oracle  
Exadata



Хранение

Oracle  
Exalytics



Анализ

# Oracle Big Data Appliance

## Аппаратное обеспечение



- Кластер из 18 узлов (18 Sun X4270 M2 )
- На каждом узле
  - 64 GB RAM (всего 1152GB RAM)
  - 16 ядер Intel (всего 288 ядер)
  - 48 ТБ дисков (всего 864TB)
- 40 Gb p/sec InfiniBand
- 10 Gb p/sec Ethernet



# Oracle Big Data Appliance

## Программное обеспечение



- Oracle Linux
- Java Hotspot VM
- Cloudera Hadoop Distribution
  - *Hadoop Core, HDFS, Hive, HBase, Zookeeper, Oozie, Mahout, Sqoop*
- R Distribution
- Oracle NoSQL Database
- Oracle Big Data Connectors

# Платформа Oracle для больших данных



Oracle  
Big Data Appliance



Сбор

Обработка

Oracle  
Exadata



Хранение

Oracle  
Exalytics



Анализ


# Oracle Exadata



- Машина баз данных
- Построена на основе Oracle Database
- Инновации
  - Интеллектуальная СХД (*Smart Scan, InfiniBand*)
  - Интеллектуальный PCI Flash Cache (ускорение I/O до 30 раз, сканирование снижается в 3 раза)
  - Гибридное колоночное сжатие (10 – 15-кратное сжатие)



# Oracle In-Database Advanced Analytics




## Oracle R Enterprise

- Распространенный язык статистических исследований R -- open source
- Встроен в Oracle Database – R-вычисления транслируются и выполняются в Oracle Database
- R интегрирован с Hadoop & OBIEE

Статистика

Визуализация



## Oracle Data Mining

- Встроенные в базу данных процедуры data mining
- API для разработки приложений, встраивание data mining в существующие приложения и системы
- Oracle Data Miner

Data & Text Mining


Предиктивная аналитика

# Oracle Data Mining Algorithms


## Задача

## Алгоритм


## Применение

Классификация		Logistic Regression (GLM) Decision Trees Naïve Bayes Support Vector Machine	Прогнозирование принадлежности объекта к одному из заданных классов
Регрессия		Multiple Regression (GLM) Support Vector Machine	Прогнозирование непрерывных показателей
Выявление аномалий		One Class SVM	Отсутствие «отрицательных» примеров
Значимость атрибутов		Minimum Description Length (MDL)	Сокращение числа атрибутов Выделение важных атрибутов
Ассоциативные правила		Apriori	Анализ рыночной корзины Аналisis связей (Link analysis)
Кластеризация		Enhanced K-means O-cluster Expectation Maximization (EM)	Сегментация клиентской базы Text mining Gene and protein analysis
Выявление признаков		Non-Negative Matrix Factorization Singular Value Decomposition Principal Component Analysis	Анализ текстов Уменьшение числа признаков

# Модель кластеризации для сегментации клиентской базы



# Построение классификационной модели для анализа лояльности клиентов



# Платформа Oracle для больших данных



Oracle  
Big Data Appliance



Сбор

Обработка

Oracle  
Exadata



Хранение

Oracle  
Exalytics



Анализ


InfiniBand

InfiniBand

# Oracle Exalytics In-Memory Machine



- Машина для анализа и визуализации
- In-Memory Analytics
- Аппаратное обеспечение
  - *2 TB RAM, 40 ядер CPU, 2,4 TB of PCI flash*
- Программное обеспечение
  - *Oracle Business Intelligence*
  - *TimesTen In-Memory Database*
  - *Oracle Essbase (OLAP сервер)*
  - *Oracle Endeca*




# Oracle Endeca Information Discovery



- Совместный анализ структурированной и неструктурированной информации
- Интуитивное исследование
- Фасетный поиск
- Контекстный поиск, навигация, аналитика
- Динамические метаданные
- Неструктурированная информация и Text Enrichment (обогащение текста)
- In-Memory технологии

# Oracle Endeca Information Discovery


- **Endeca Server**
  - Поисково-аналитическая база данных
- **Endeca Integrator**
  - Загрузка данных в Endeca Server
- **Endeca Information Discovery**
  - Быстрая компонентная разработка приложений для исследования данных



# Endeca Server

## Информационно-поисковая *NoSQL* база данных


- Фасетная модель данных
- Набор записей, каждая из которых имеет собственную «структурку»
  - Многозначные поля
  - Неструктурированные поля (тексты)
- Один из видов «Key Value» модели
- Модель состоит из
  - Записей
  - Атрибутов
- Каждая запись – это набор пар (атрибут, значение)
- Нет никакого разбиения на таблицы
- Нет понятия схемы данных



# Endeca Integrator

## Загрузка данных в Endeca Server

- ETL-среда для загрузки данных в базу данных Endeca Server
- При загрузке выполняются преобразования и извлечение из текстов фактов – упоминание персон, географических объектов, событий, определение тональности и др.
- Для семантической обработки русскоязычных текстов используются инструменты компании RCO




# Endeca Studio

## Интерфейс пользователя

- Быстрая компонентная разработка, возможность расширения
- Поиск + Фасетная навигация + Визуальный анализ
  - Поиск и выбор атрибутов в стиле вэб сайтов
  - Уточнение критерия поиска
  - Быстрое вычисление статистики
  - Текстовый поиск
- Интеграция с географическими картами
- Интерактивные исследования



# Технологии Oracle для Больших Данных



# Эксперименты и проекты

# Рынок Большых данных

- Один из самых быстрорастущих в мире
- Наиболее активные индустрии – банки, телеком и ритейл
- IDC:
  - *мировой рынок Big data будет расти в среднем на 31,7% в год и достигнет к 2016 году \$23,8 млрд*
  - *ежегодно объемы хранимой информации вырастают на 40%*
- Gartner:
  - *рост объемов корпоративной информации составит 650% с 2010 по 2014 год и 85% ее будет неструктурированной*
  - *мировые расходы на big data в 2012 году - \$28 млрд, а в 2013 году – \$34 млрд*
  - *В 2013 году объем мирового рынка средств анализа и бизнес-аналитики вырос примерно на 8% и достиг 14,4 млрд долларов. На него практически не повлияли технологии анализа больших данных*

# Большие данные в России

- Большой интерес к новому направлению, но низкий уровень востребованности
- Много экспериментов, но почти нет промышленных внедрений
- Наиболее активные индустрии
  - Банки и финансовые организации
  - Телеком
  - Госсектор
  - Недвижимость
  - Ритейл



# Большие данные в российских банках

10 российских банков из топ-30 используют технологии Big Data  
Cnews, январь 2014

- Применяют технологии Big Data
  - Сбербанк
  - Газпромбанк
  - ВТБ 24
  - Альфа Банк
  - Райффайзенбанк
  - Промсвязьбанк
  - Ситибанк
- Планируют применять Big Data
  - ВТБ
  - МДМ Банк
  - Юникредит Банк
  - Россельхоз
  - Петрокоммерц

[http://www.cnews.ru/top/2014/01/30/10\\_rossiyskih\\_bankov\\_iz\\_top30\\_ispolzuyut\\_tehnologii\\_big\\_data\\_558490](http://www.cnews.ru/top/2014/01/30/10_rossiyskih_bankov_iz_top30_ispolzuyut_tehnologii_big_data_558490)

# В финансовых организациях

- Анализ предпочтений и прогнозирование поведения клиентов на основе данных социальных сетей, блогов, документов, транзакций
  - *Увеличение кросс продаж и дополнительных продаж*
  - *Повышение уровня лояльности*
  - *Повышение потенциальной прибыльности клиентов*
- Предупреждение мошенничества
- Управление рисками невозврата кредита, мошенничества, рыночными, валютными, операционными, репутационными

# Банк HSBC



- крупнейший в Европе по размеру рыночной капитализации
- Внедрена система по противодействию кредитному мошенничеству
- Результаты
  - *эффективность этой службы повысилась в 3 раза*
  - *точность выявления мошенничества — в 10 раз*
- В первые две недели эксплуатации семь специалистов службы безопасности HSBC выявили новые криминальные группы и схемы с общим потенциальным ущербом более \$10 млн.



# Тинькофф Кредитные Системы

Тинькофф.  
Кредитные Системы

- В банке внедрена система для анализа больших данных в режиме реального времени Причины миграции хранилища данных на технологию Big Data
  - планы по наращиванию клиентской базы
  - возросшие требования к обработке накопленной информации
- Проект выполнен за 6 месяцев
- Результаты: время решения аналитических задач сократилось минимум в 10 раз, а для некоторых – более чем в 100 раз.

# Оценка проекта

«Ценность выполненного проекта заключается в развитии существующей в Банке культуры принятия решений на основе анализа информации. Умение превращать накопленные данные в знания давно является признаком конкурентоспособности Банка, а сами данные – стратегическим активом и потенциалом для будущего роста. В ближайшее время клиентами будут востребованы Банки, которые лучше понимают их поведение, привычки и максимально соответствуют им».

**Вячеслав Цыганов, Вице-президент, СИО,  
банк «Тинькофф Кредитные Системы»**

# Большие данные в российском ритейле

Cnews, 24 апреля 2014

- Применяют технологии Big Data
  - Лента
  - Азбука вкуса
  - Глория Джинс
  - Юлмарт
- Планируют применять Big Data
  - X5 Retail Group
  - М.Видео
  - Эльдорадо
  - Белый ветер




<http://www.cnews.ru/news/top/index.shtml?2014/04/17/568717>

ФОРС

# Проекты в области больших данных

- Повышение производительности и затрат
  - Многократное ускорение для известной задачи
  - Примеры – разбор входных битовых данных, предобработка для обогащения данных, выделение значимой информации в большом потоке
- Новые данные, новая аналитика
  - Новая задача или новые данные для известной задачи
  - Примеры – данные соцсетей, прогнозирование на основе интернет-запросов пользователей



# Проект «повышение производительности»

## *Пилот в российском банке*

## ■ Данные:

- *файлы (без переноса строк) размером в несколько сотен Мб*
  - *Суммарный объем десятки Тб*
  - *Мета описание меняется раз в месяц*

## ■ Необходимо

- Хранить все в течении нескольких лет
  - Загружать часть полей в *Oracle Database* (~ 50 из 1000)
  - Список полей для загрузки постоянно ме

# Типовой проект для «новой аналитики»

- Совместный анализ текстов и «реляционных» данных
- Обработка неструктурированных текстов
  - *Интернет-источники*
  - *Внутренние архивы*
- Цели -- расширение состава данных для клиентской аналитики, смысловой поиск в неструктурированном контенте, поддержка аналитических исследований



# Недвижимость и большие данные

- Индустрия недвижимости входит в top5 для Big Data
- Большой объем неструктурированных данных
- Многочисленные источники вэб-информации: уполномоченные госструктуры, открытые источники
- Постоянное непредсказуемое изменение в источниках
- Интенсивное использование методов статистики и предиктивной аналитики




# Пилотный проект по оценке недвижимости

- Проект выполнялся компанией Форс для Российского Общества оценщиков & РОСЭКО
- Функциональные возможности системы
  - Сбор данных из интернет источников
  - Стандартизация и обогащение данных
  - Поддержка статистических исследований (регрессия, карты Кохонена, кластеризация)
  - Построение предиктивных моделей оценки и подбора аналогов
- Реализация на основе технологий Oracle



РОССИЙСКОЕ  
ОБЩЕСТВО  
ОЦЕНЩИКОВ

# Проект «Big Data для недвижимости»



Сбор информации из интернета обработка и хранение средствами Hadoop


Семантическая обработка текстов, геопозиционирование, загрузка данных

Хранение данных в информационно-поисковом сервере Endeca Server


Рабочие места пользователей: аналитиков и конечных пользователей

# Обработка данных об адресах

- Лингвистическая обработка (RCO)
- Геопозиционирование (ArcGIS, СканЭкс)
- Получение дополнительных факторов (расстояние от центра, транспортная доступность)




# Статистическая обработка



- Оценка значимости атрибутов (корреляционный анализ)
- Гетероскедастичность (неоднородность наблюдений)
- Мультиколлинеарность (взаимозависимости между факторами)
- Чувствительность
- Тест на нормальность


# Построение моделей



- Построение самоорганизующихся карт Кохонена
- Кластеризация
- Формирование правил


# Первичное ценовое зонирование

- На основе карт Кохонена и кластеризации
- Геотрактовка
- Сопоставление полученных кластеров и с географической картов



# Ценовое зонирование на основе регрессионного анализа

- Построение регрессии внутри кластера
- Применение регрессии для восстановления данных
- Окончательное ценовое зонирование



# Об использовании больших данных

Big data is like teenage sex: everyone talks about it, nobody really knows how to do it, everyone thinks everyone else is doing it, so everyone claims they are doing it...

*Dan Ariely*



# Спасибо за внимание!