




Smart data

Лекция #5

Большие данные и
хранилища больших
данных

И.А. Куликов

i.a.kulikov@gmail.com



Big Data (Большие данные)

Большие данные (Big data)

По данным Gartner -

«Большие данные» - это объемные, быстро доступные и разнообразные информационные ресурсы, которые требуют рентабельных, инновационных форм обработки информации для лучшего понимания и принятия решений.

Чаще всего о больших данных говорят как о таких данных, размер которых превышает способность типовых СУБД собирать, хранить, управлять и анализировать их. А также анализ и обработки которых может иметь большую ценность для бизнеса.

Большие данные (Big data)

2001 год. Дуглас Лэйни из META Group (сейчас Gartner) предложил три измерения (3V) - Volume, Velocity, Variety больших данных. Годами добавлялись новые V:

- Veracity – достоверность
- Validity – действительность
- Volatility – изменчивость
- Value – ценность
- Visualization – визуализация
- Vulnerability – уязвимость
- Variability - изменчивость


Примеры больших данных для организаций

- Данные о погоде
- Данные контрактов
- Данные о рабочей силе
- Данные технического обслуживания
- Данные финансовой отчетности
- Данные о соответствии стандартам
- Данные клинических испытаний
- Обработка записей врачей по диагностике и лечению

Источники данных



Источники данных



Типы источников больших данных

- Направленные данные (Directed data)
- Автоматизированные данные (Automated data)
- Данные систем автоматизированного мониторинга (Automated surveillance)
- Цифровые устройства (Digital devices)
- Считываемые данные (Sensed data)
- Данные сканеров (Scan data)
- Данные взаимодействий (Interaction data)
- Данные, предоставленные добровольцами (Volunteered data)
- Данные транзакций (Transactions)
- Данные социальных сетей (Social media)
- Данные управления своим здоровьем (Sousveillance)
- Краудсорсинг (Crowdsourcing)
- Гражданская наука (Citizen science)

Примеры источников открытых данных для разных доменов

- Facebook API Graph
- Open Corporates
- Global Financial Data
- Open Street Map
- The National Centers for Environmental Information (NCEI)
- DBpedia


Классификация источников данных с точки зрения характера предоставляемых ими данных и методов их обработки

- Текстовые данные.** Методы обработки: Preprocessing, Named Entity Recognition (NER), Entity Linking (EL), Relation Extraction (RE), Joint tasks
- Размеченные данные** (например, лог файлы). Методы обработки: Wrapper-based extraction, Web table extraction, Deep Web crawling
- Структурированные данные** (таблицы, деревья, базы данных, графы знаний). Методы обработки: Mapping from tables, Mapping from trees, Mapping from other knowledge graphs



Архитектура систем обработки больших данных

Компоненты архитектуры для обработки больших данных



Потоковая обработка против пакетной обработки

Пакетная обработка.

Плюсы

- Наиболее применима при работе с большими объемами.
- Обработка данных происходит самостоятельно.
- Это экономичный метод обработки данных.

Минусы

- Пользователи должны тщательно подготовить входные данные, предназначенные для пакетной обработки, прежде чем запускать их на компьютере.
- Проблемы с данными, сбои программы и ошибки, возникающие во время пакетной обработки, могут остановить весь процесс. К ним относятся незначительные ошибки в данных, такие как опечатки в датах.

Потоковая обработка.

Плюсы

- Данные всегда актуальны.
- Данные обновляются в режиме реального времени.
- Случаи задержки минимальны.

Минусы

- Потоковая обработка - это дорого и сложно.
- Информационный аудит при потоковой обработке является сложной задачей.

Лямбда архитектура




Figure 1.6 Lambda Architecture







Figure 1.7 Architecture of the batch layer

Лямбда архитектура (продолжение)



Лямбда архитектура (продолжение)





Figure 1.11 Lambda Architecture diagram

Каппа архитектура



Хранилища данных




Технологии хранения больших данных

- Распределенные файловые системы
- Базы данных NoSQL
- Базы данных NewSQL
- Платформы запросов к большим данным


Hadoop HDFS



Hadoop Architecture




Hadoop HDFS (продолжение)



Hadoop HDFS (продолжение)


Rack Awareness




Block Replication

Namenode (Filemane, numReplicas, block-ids, ...)
/user/dataflair/hdata/part-0, r:2, {1,3}, ...
/user/dataflair/hdata/part-1, r:3, {2,4,5}, ...


Datanodes





**Хранилища данных
NoSQL базы данных**

Хранилища "ключ-значение"




Redis^e Cluster Manager

detecting failures and orchestrating auto-failover

Redis Shards


Master and Slave shards maintained using in-memory replication over LAN



M Master | S Slave

Хранилища столбцов

Пространство ключей схема (в РБД)



Хранилища столбцов (продолжение)

Ячейка


Name	colA	value1	Value

Строка


key	columns					
a	colA	value1	colFoo	aval	milk	white

Column Family


Rows	→	a	colA	value1	colFoo	aval	milk	white
	→	+	colA	value1	long col name	foo	X	piece
	→	ж	—	μ	↑	↗	↙	↔




База данных документов



База данных документов (продолжение)




База данных документов (продолжение)




Графовые БД



Графовые БД (продолжение)



Графовые БД (продолжение)



NewSQL базы данных



Базы данных NewSQL - современная форма реляционных баз данных, предназначенная для обеспечения масштабируемости, сравнимой с базами данных NoSQL при сохранении транзакционных гарантий, поддерживаемых традиционными системами баз данных.

Такие СУБД обладают следующими характеристиками:

- SQL - это основной механизм взаимодействия с приложениями.
- Поддержка ACID для транзакций
- Механизм управления неблокирующими параллелизмом.
- Архитектура, обеспечивающая гораздо более высокую производительность на каждом узле.
- Горизонтально масштабируемая архитектура без совместного использования ресурсов, способная работать на большом количестве узлов без проблем.

Ожидается, что системы NewSQL примерно в 50 раз быстрее традиционных СУБД.

CDN – Content Delivery Network



Платформы запросов к большим данным

- Hive
- Impala
- Spark SQL
- Drill

Облачные хранилища

- Amazon cloud
- Microsoft Azure
- Google cloud
- Etc.

Перспективные требования к хранению больших данных

- Стандартизованные интерфейсы запросов
- Безопасность и конфиденциальность
- Отслеживание данных и их происхождения
- «Песочница» и виртуализация
- Семантические модели данных

Новые парадигмы для хранения больших данных

- Расширенное использование баз данных NoSQL
- Хранение данных в памяти и хранилища столбцов
- Конвергенция с аналитическими платформами
- Центр данных (The Data Hub)

Благодарю за внимание