



Умный  
выбор  
меняющихся  
технологий

# Как строить корпоративное озеро данных на базе проектов с открытым кодом

Золотарев С.А.



# Основной тренд - Open Source

IBS

78% компаний используют Open Source Software (OSS)  
88% компаний участвуют в развитии OSS



Источник: *Black Duck - Future of Open Source Survey*



# DataLake vs DWH

## Принципиальные отличия



Критерий	Business Data Lake	EDW
Модель данных	Неструктурированная, структурированная, реляционная, многомерная	Структурированная, реляционная, многомерная
Data quality		
Интеграция		
Интерфейсы	SQL, SAS, R, MapReduce, NoSQL	SQL access integration with SAS, R and other analytical interfaces
Обработка и историчность	Вариативная обработка (онлайн, пакетный) = длительная история	Небольшая историчность = пакетная обработка

# Пример миграции с СУБД Oracle на платформу Hadoop у мобильного оператора для решения задач СОРМ

# Что послужило причиной для проекта



- Невозможное дальнейшее масштабирования существующей платформы хранения
- Высокая стоимость владения на базе СУБД Oracle
- Со стороны бизнеса ( маркетинга) было большое желание использовать огромный массив данных и для того, чтобы зарабатывать деньги.

# Принципиальная схема проекта



УРОВЕНЬ  
ОТЧЕТНОСТИ



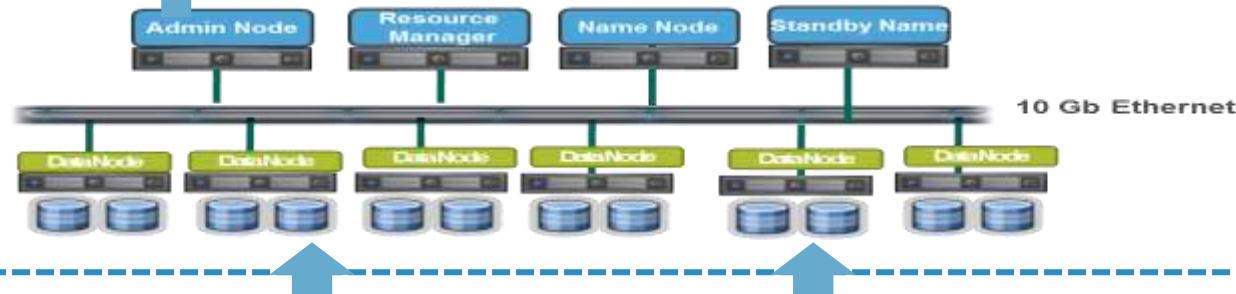
АНАЛИТИЧЕСКАЯ  
ПЛАТФОРМА



ОЗЕРО ДАННЫХ



SQL on Hadoop



ИСТОЧНИКИ  
ДАННЫХ

HTTP трафик и звонки ( XDR\CDR)



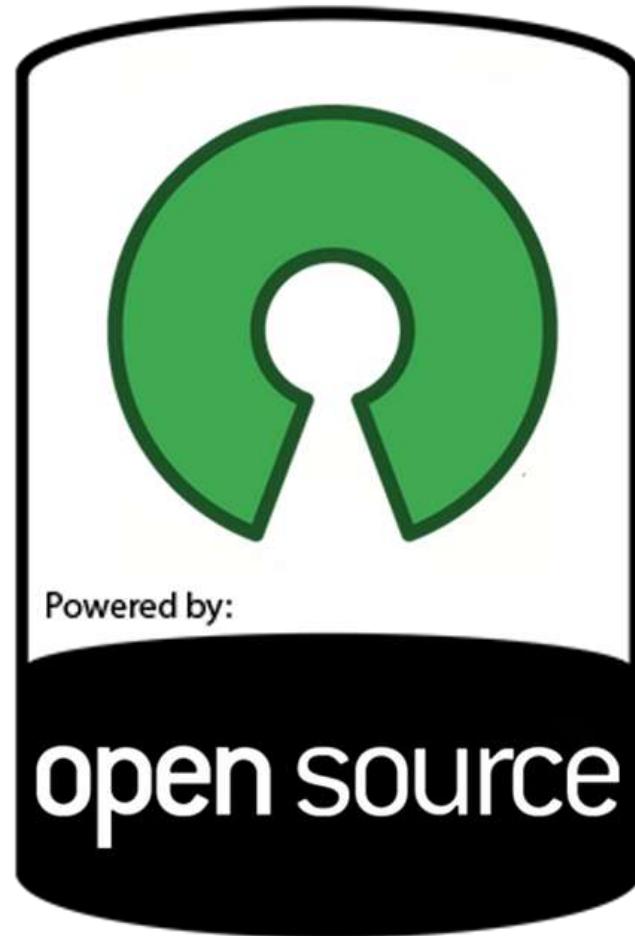
Сеть  
оператора

# Преимущества от внедрения



- Капитальные затраты удалось снизить более чем в 2 раза по сравнению с традиционной платформой
- Операционные более чем в 3 раза.
- Текущая конфигурация рассчитана на хранение до 1 Пб данных с возможностью неограниченного линейного роста.
- Пользователи получили современный, удобный и универсальный ландшафт для работы с данными.
- Использование программных продуктов с открытым исходным кодом позволило гарантировать отсутствие vendor lock-in в будущем.

# А что если ?



# Архитектура универсальной платформы для обработки данных

IBS

Загрузка данных  
(ETL, near-realtime,  
streaming)



Приложения  
(аналитические системы,  
ad-hoc)

# Почему ARENADATA HADOOP?

IBS

- **Почти полное отсутствие экспертизы вендоров в России и даже Европе**
- **Отсутствие опыта интеграции в корпоративный ландшафт для решения типовых корпоративных задач**
- **Невозможность он-сайт поддержки от вендора (только удаленно)**
- **Неподъёмная цена на специалистов**
- **Отсутствие русскоязычной документации, обучения и т.п.**
- **Российские требования по сертификации**

# ARENADATA HADOOP (ADH)

IBS

ARENADATA Ambari ADP 0 apps 2 alerts

Dashboard Services Hosts 1 Alerts Admin admin

Metrics Heatmaps Config History

Metric Actions Last 1 hour

HDFS Disk Usage 11% DataNodes Live 1/1 HDFS Links NameNode Secondary NameNode 1 DataNodes More...

Memory Usage 18.6 GB Network Usage 1.9 KB 1000 B

CPU Usage 100% Cluster Load 5 NameNode Heap 17% NameNode RPC 0.13 ms NameNode CPU WIO 0.0%

NameNode Uptime 282.9 s HBase Master Heap 1% HBase Links HBase Master 1 RegionServers Master Web UI More...

HBase Ave Load 3 HBase Master Uptime 179.2 s

ResourceManager Heap 16% ResourceManager Uptime 166.7 s NodeManagers Live 1/1 YARN Memory 0% YARN Links ResourceManager 1 NodeManagers More...

Flume Live 1/1

ARENADATA

# ARENADATA HADOOP (ADH)



ARENADATA

# ARENADATA HADOOP (ADH)



About    ODPI For ISVs    ODPI For End Users    Community    News    Blog



All the following Apache Hadoop platforms are [ODPi Runtime Compliant](#). This dramatically decreases engineering complexity for Big Data developers by ensuring a consistent set of base level expectations.

VENDOR	PRODUCT / VERSION	CONTACT
 altiscale	Altiscale Data Cloud 4.2	Raymie Strata < <a href="mailto:rstrata@altiscale.com">rstrata@altiscale.com</a> >
	Arenadata Hadoop (ADH) 1.3.1	Alexander Nermakov < <a href="mailto:ean@arenadata.io">ean@arenadata.io</a> >
	HDP 2.4.2	Alan Gates < <a href="mailto:gates@hortonworks.com">gates@hortonworks.com</a> >
	IOP 4.2 / BigInsights 4.2	Susan Malaika < <a href="mailto:malaika@us.ibm.com">malaika@us.ibm.com</a> >

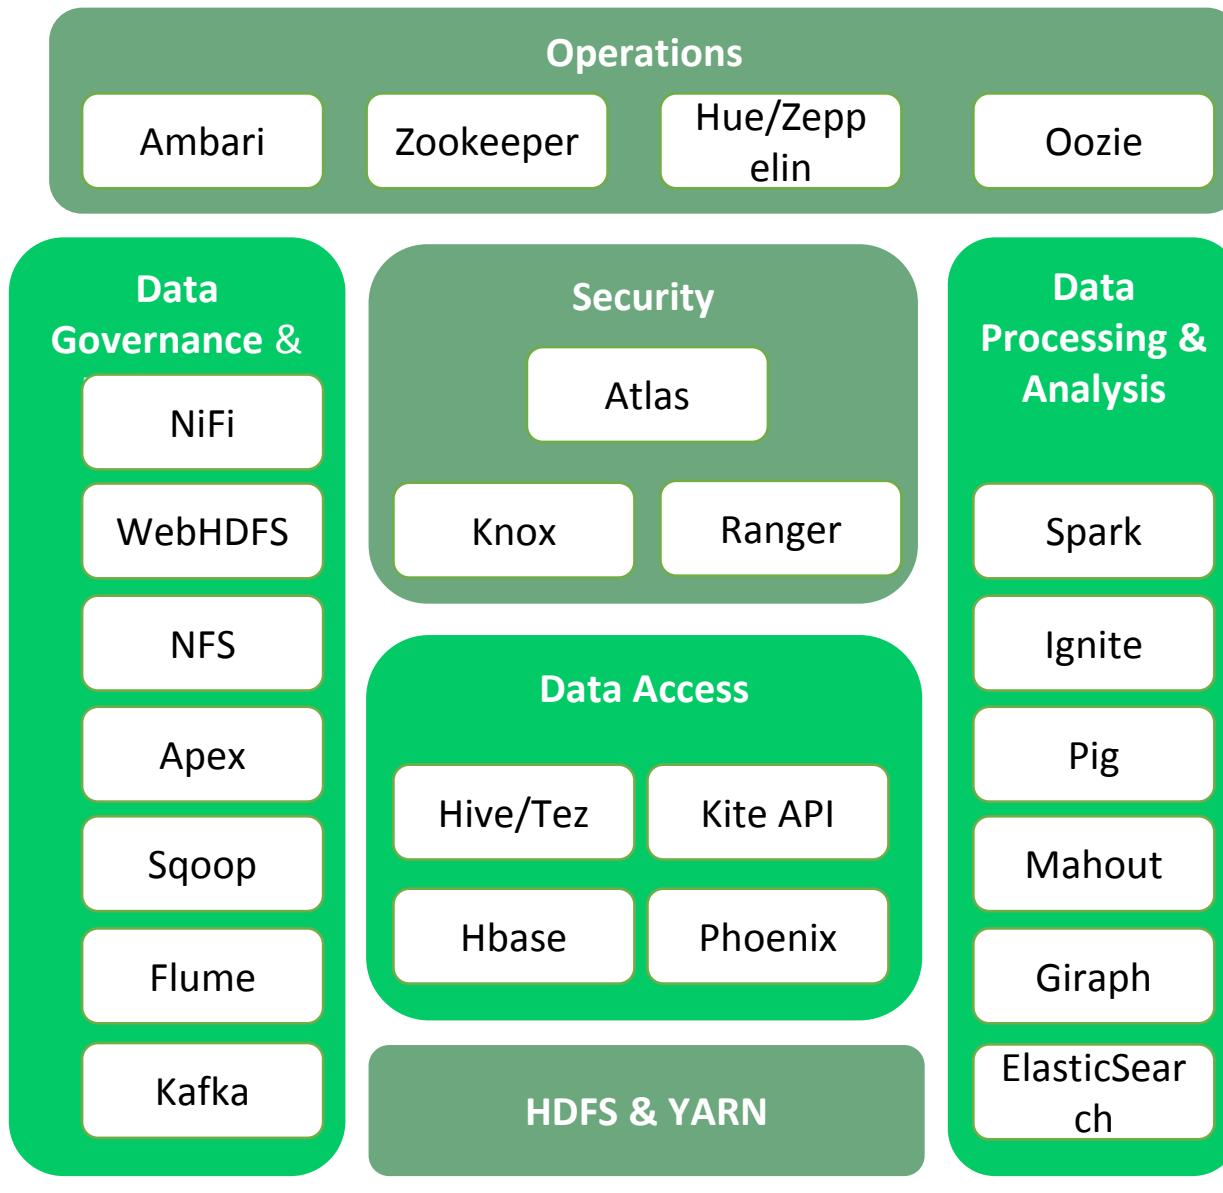
# Почему HADOOP ?



- Широкое использование ключевыми аналитическими системами (SAP , SAS, Tableau и др) как уровень хранения наряду с СУБД
- Наиболее полная и быстроразвивающаяся эко-система хранения и обработки данных
- Упростилась адаптация в корпоративном ИТ

# ARENADATA HADOOP (ADH)

IBS



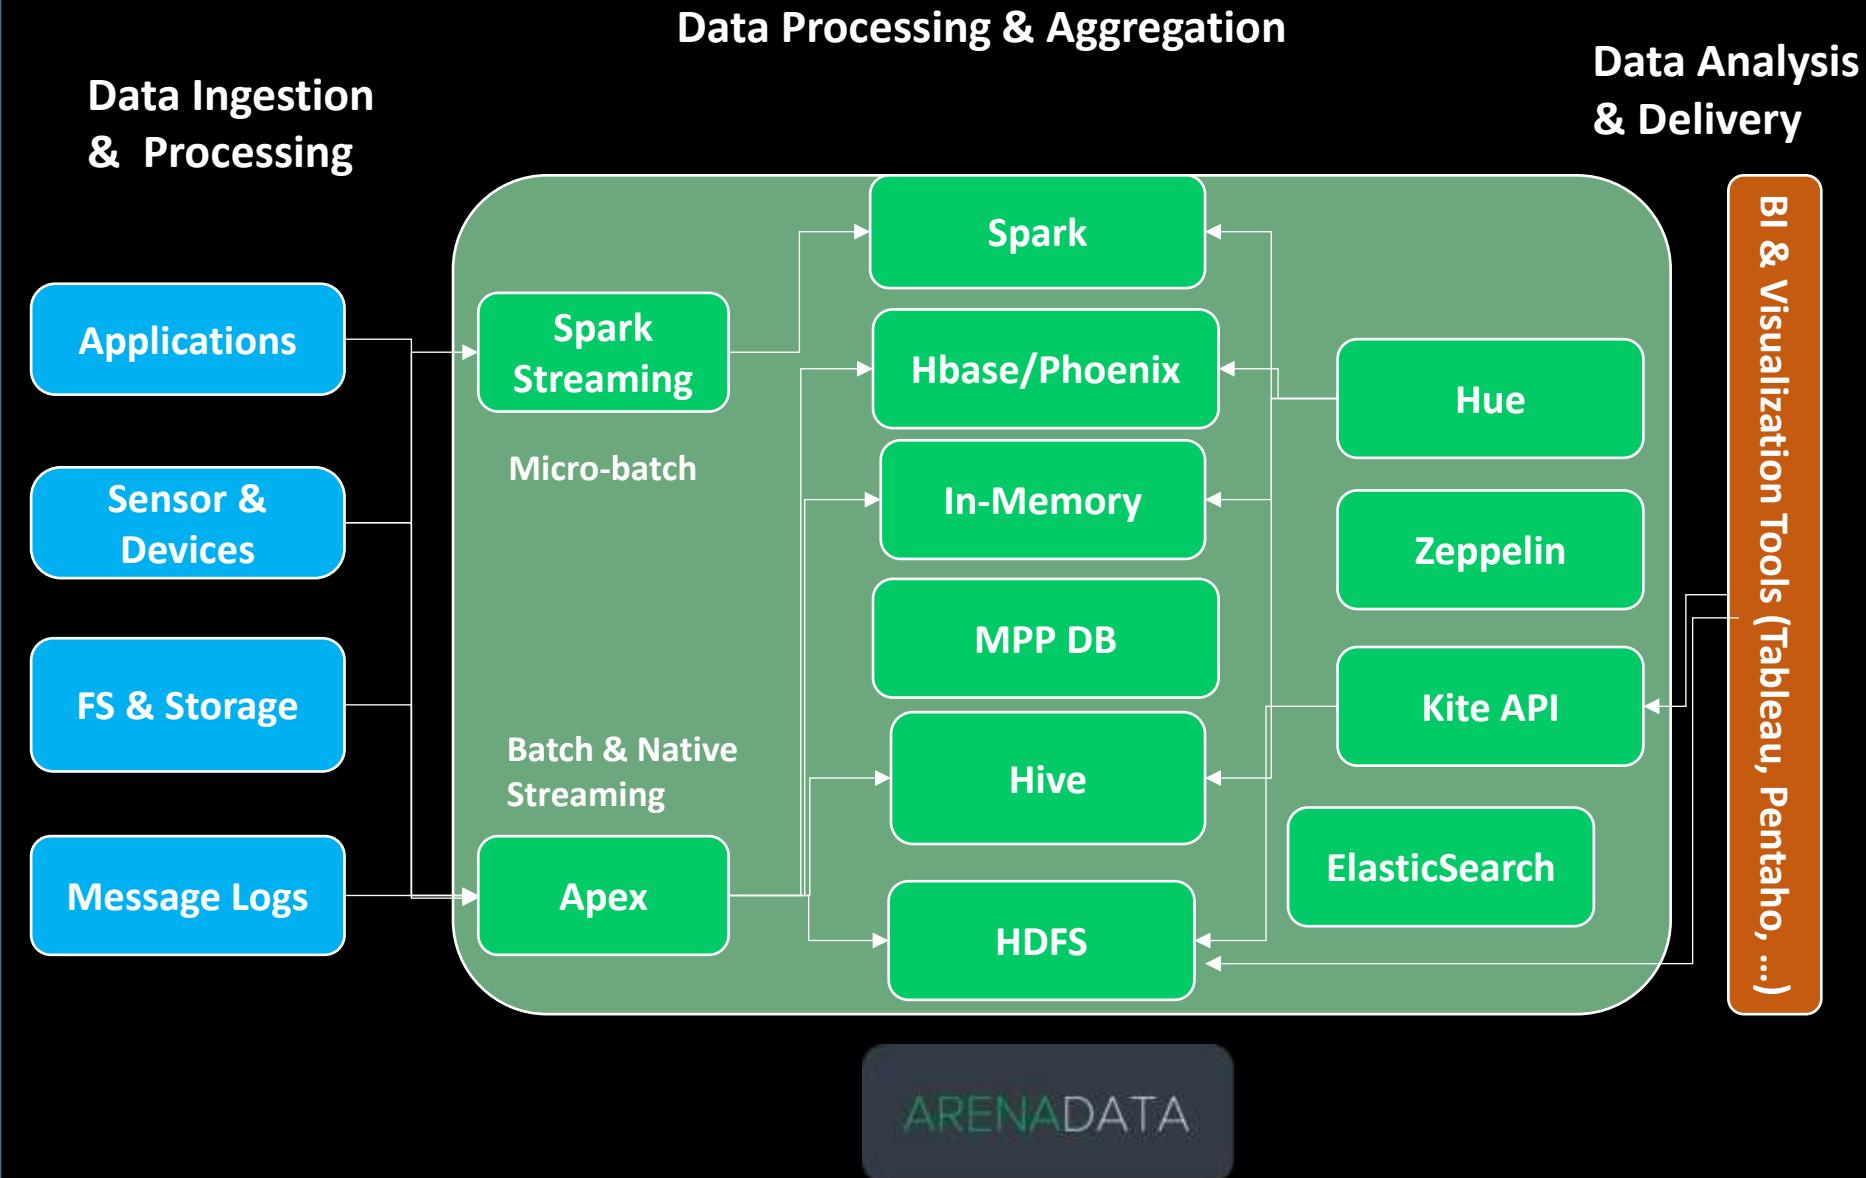
# ARENADATA HADOOP (ADH)

IBS

## Основные преимущества :

- Вся поддержка и экспертиза доступна в России и на русском языке;
- Разработан пакет утилит для оффлайн установки (без доступа в интернет);
- Вся сборка выполнена на базе открытых проектов Apache, нет проприетарных компонентов;
- Полностью российское программное обеспечение;
- Доступен не только в виде ПО , но и как Hadoop Appliance СКАЛА-Р с полной и единой поддержкой всего программно-аппаратного комплекса от вендора;
- Есть набор доступных типовых пакетных сервисов по планированию, установке и аудиту системы.

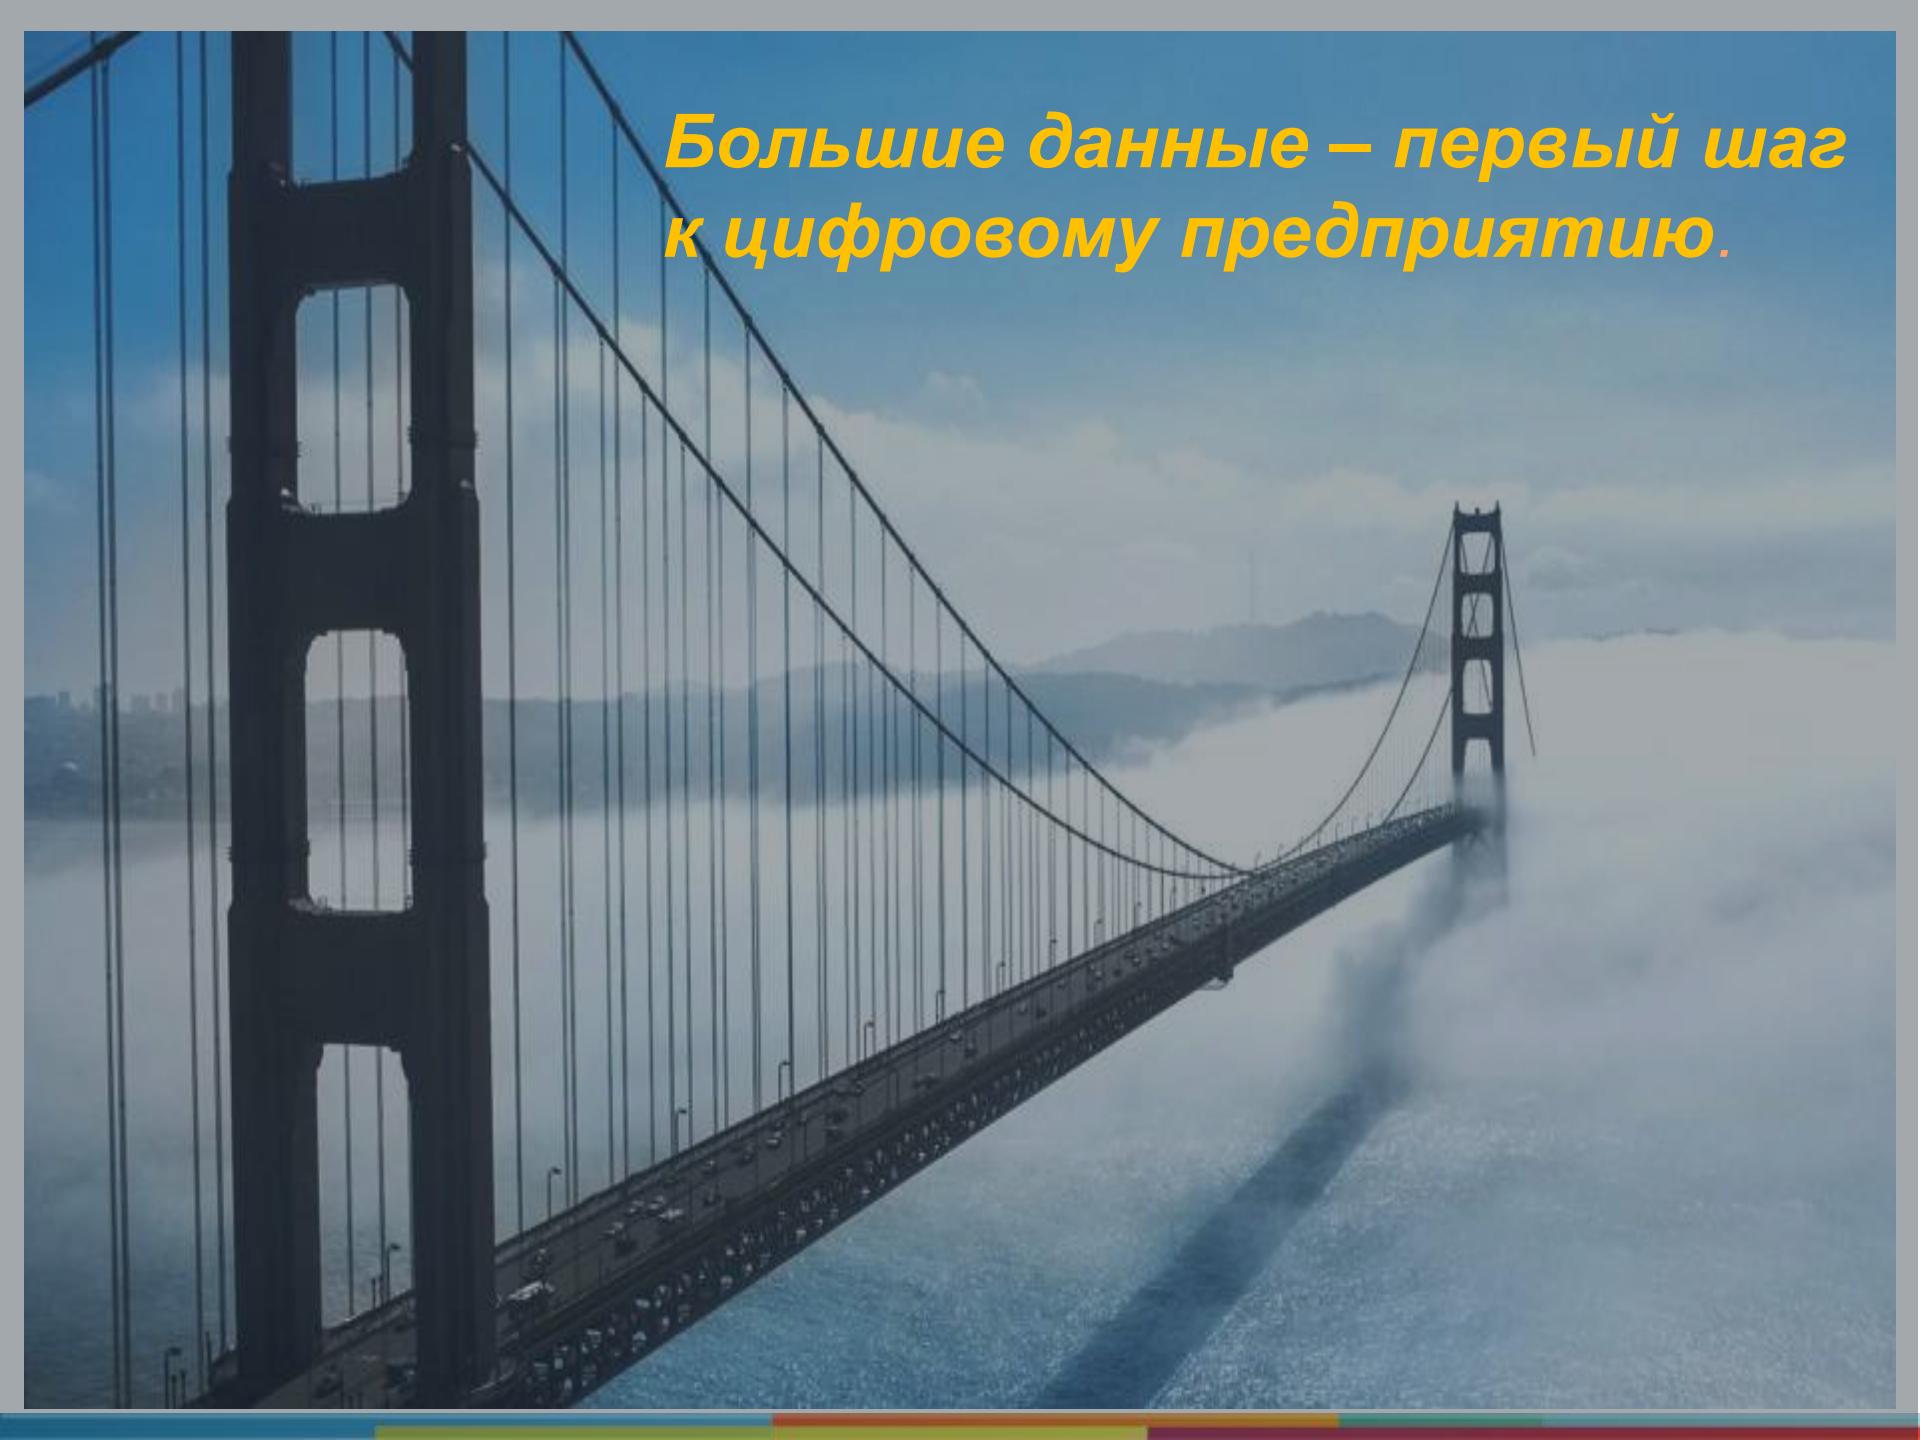
# ARENA DATA PLATFORM



# Hadoop Appliance СКАЛА-Р



- Программно –аппаратная платформа под ключ
- Единая поддержка от вендора
- Полностью российская платформа
- Минимальные сроки по вводу в эксплуатацию



*Большие данные – первый шаг  
к цифровому предприятию.*



WWW ARENADATA IO