

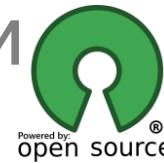
---

Построение и эксплуатация серьезных Enterprise решений на  
базе Open Source проектов  
( на примере платформы данных Arenadata)

Казань, 27 июня 2019

Сергей Золотарев

# Программная платформа для работы с данными



## Наши заказчики

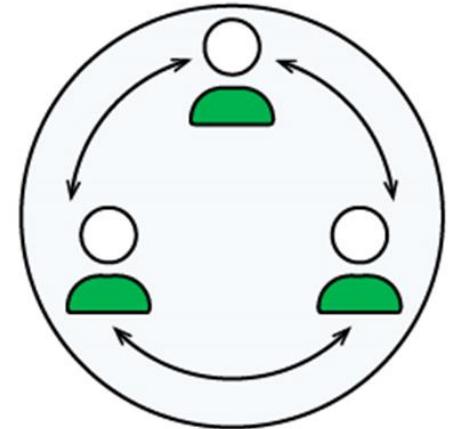


## Наши партнеры



# Команда Arenadata

- Arenadata основана в конце 2015 года;
- Ядро команды **Pivotal / EMC Greenplum** ;
- Многолетний опыт в классических КХД;
- Крупнейшие на рынке России и СНГ проекты по проектированию/построению/аудиту платформ данных на технологиях MPP и Hadoop;
- Разработчики из самых инновационных ИТ компаний:



**Pivotal**<sup>™</sup>

  
**Tinkoff**

  
**MIRANTIS**

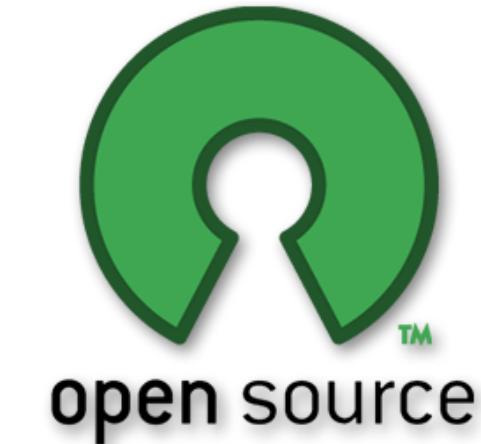
**Yandex**

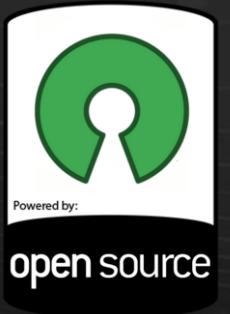
**@mail.ru<sup>®</sup>**

**Рамблер/**  
**ARENA**DATA

# Arenadata Open Source

- Являемся контрибьюторами и коммитерами проектов Apache Software Foundation:
  - Apache Ambari;
  - Apache Bigtop;
  - Apache PXF;
- Являемся членами ODPI (Linux Foundation) с 2015 года;
- Крупнейший контрибьютор в проект Greenplum.

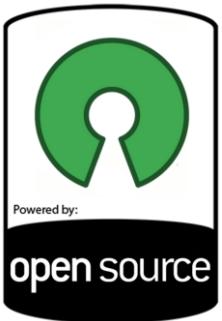




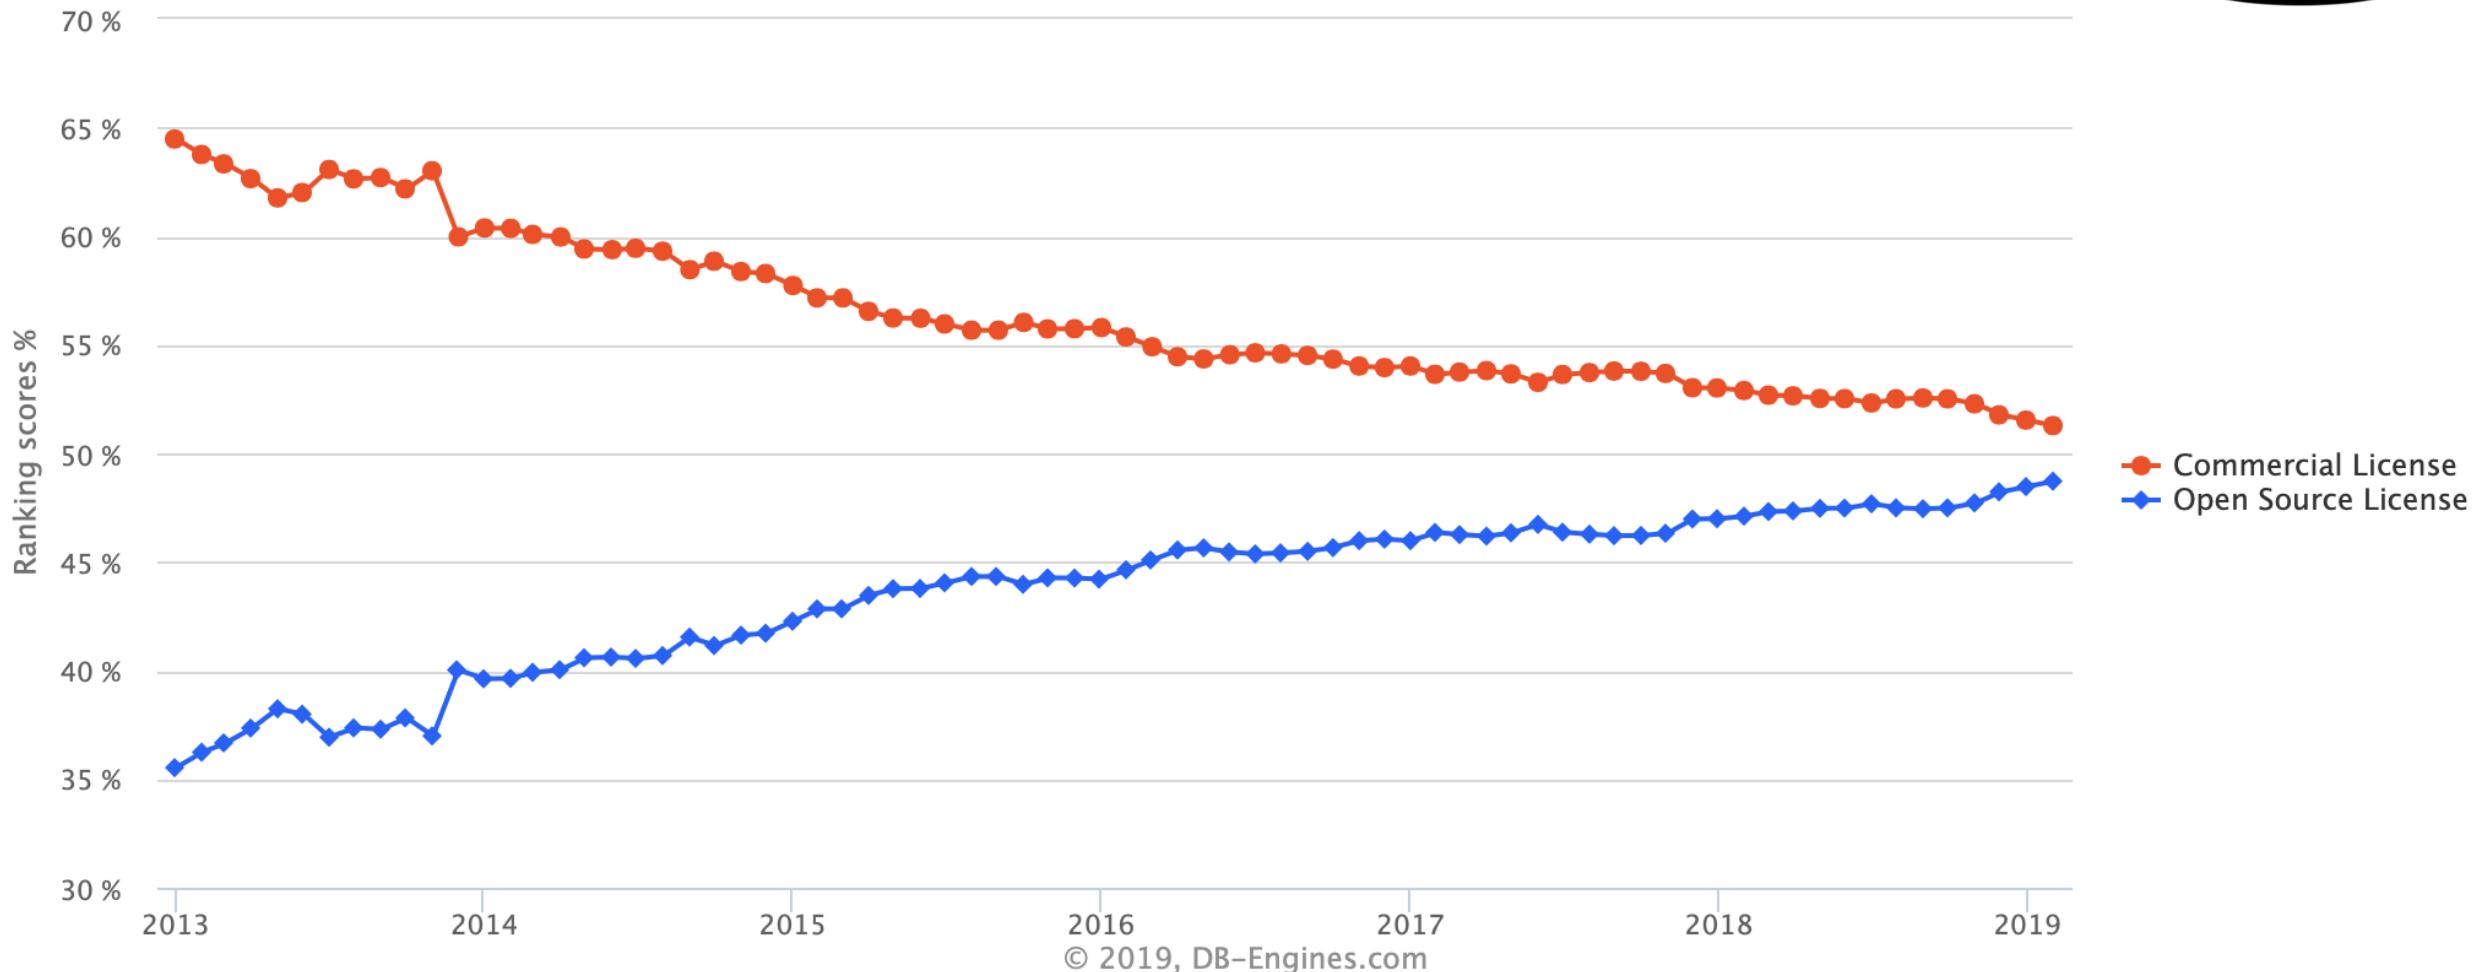
# Open Source vs Enterprise

понятия взаимоисключающие или дополняющие?

# Open Source vs Коммерческое ПО

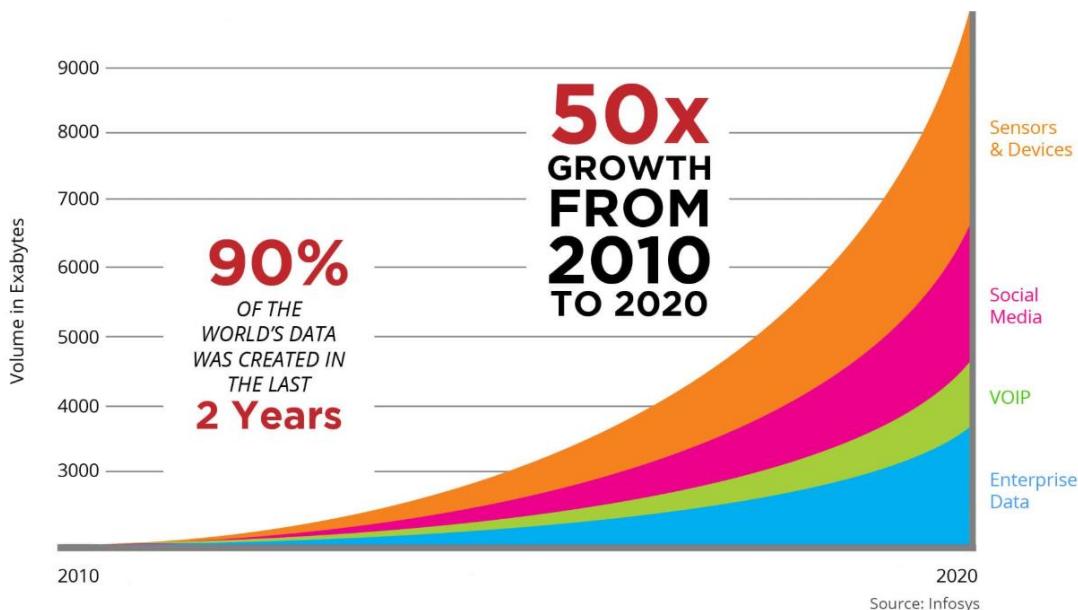


## Popularity trend

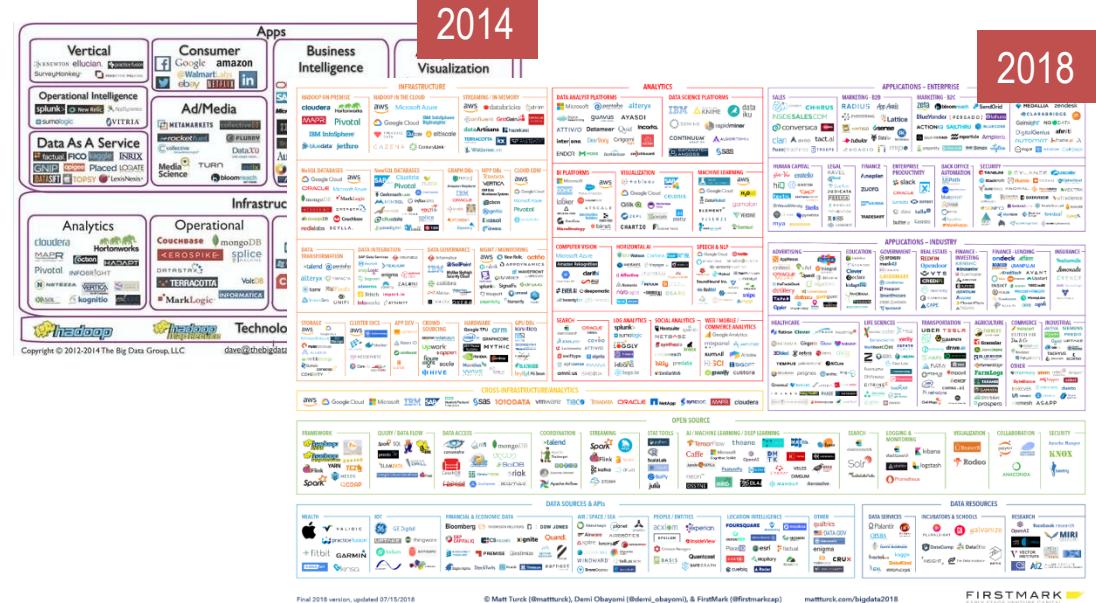


# Новый рынок платформ данных

## Революция данных



## Революция платформ

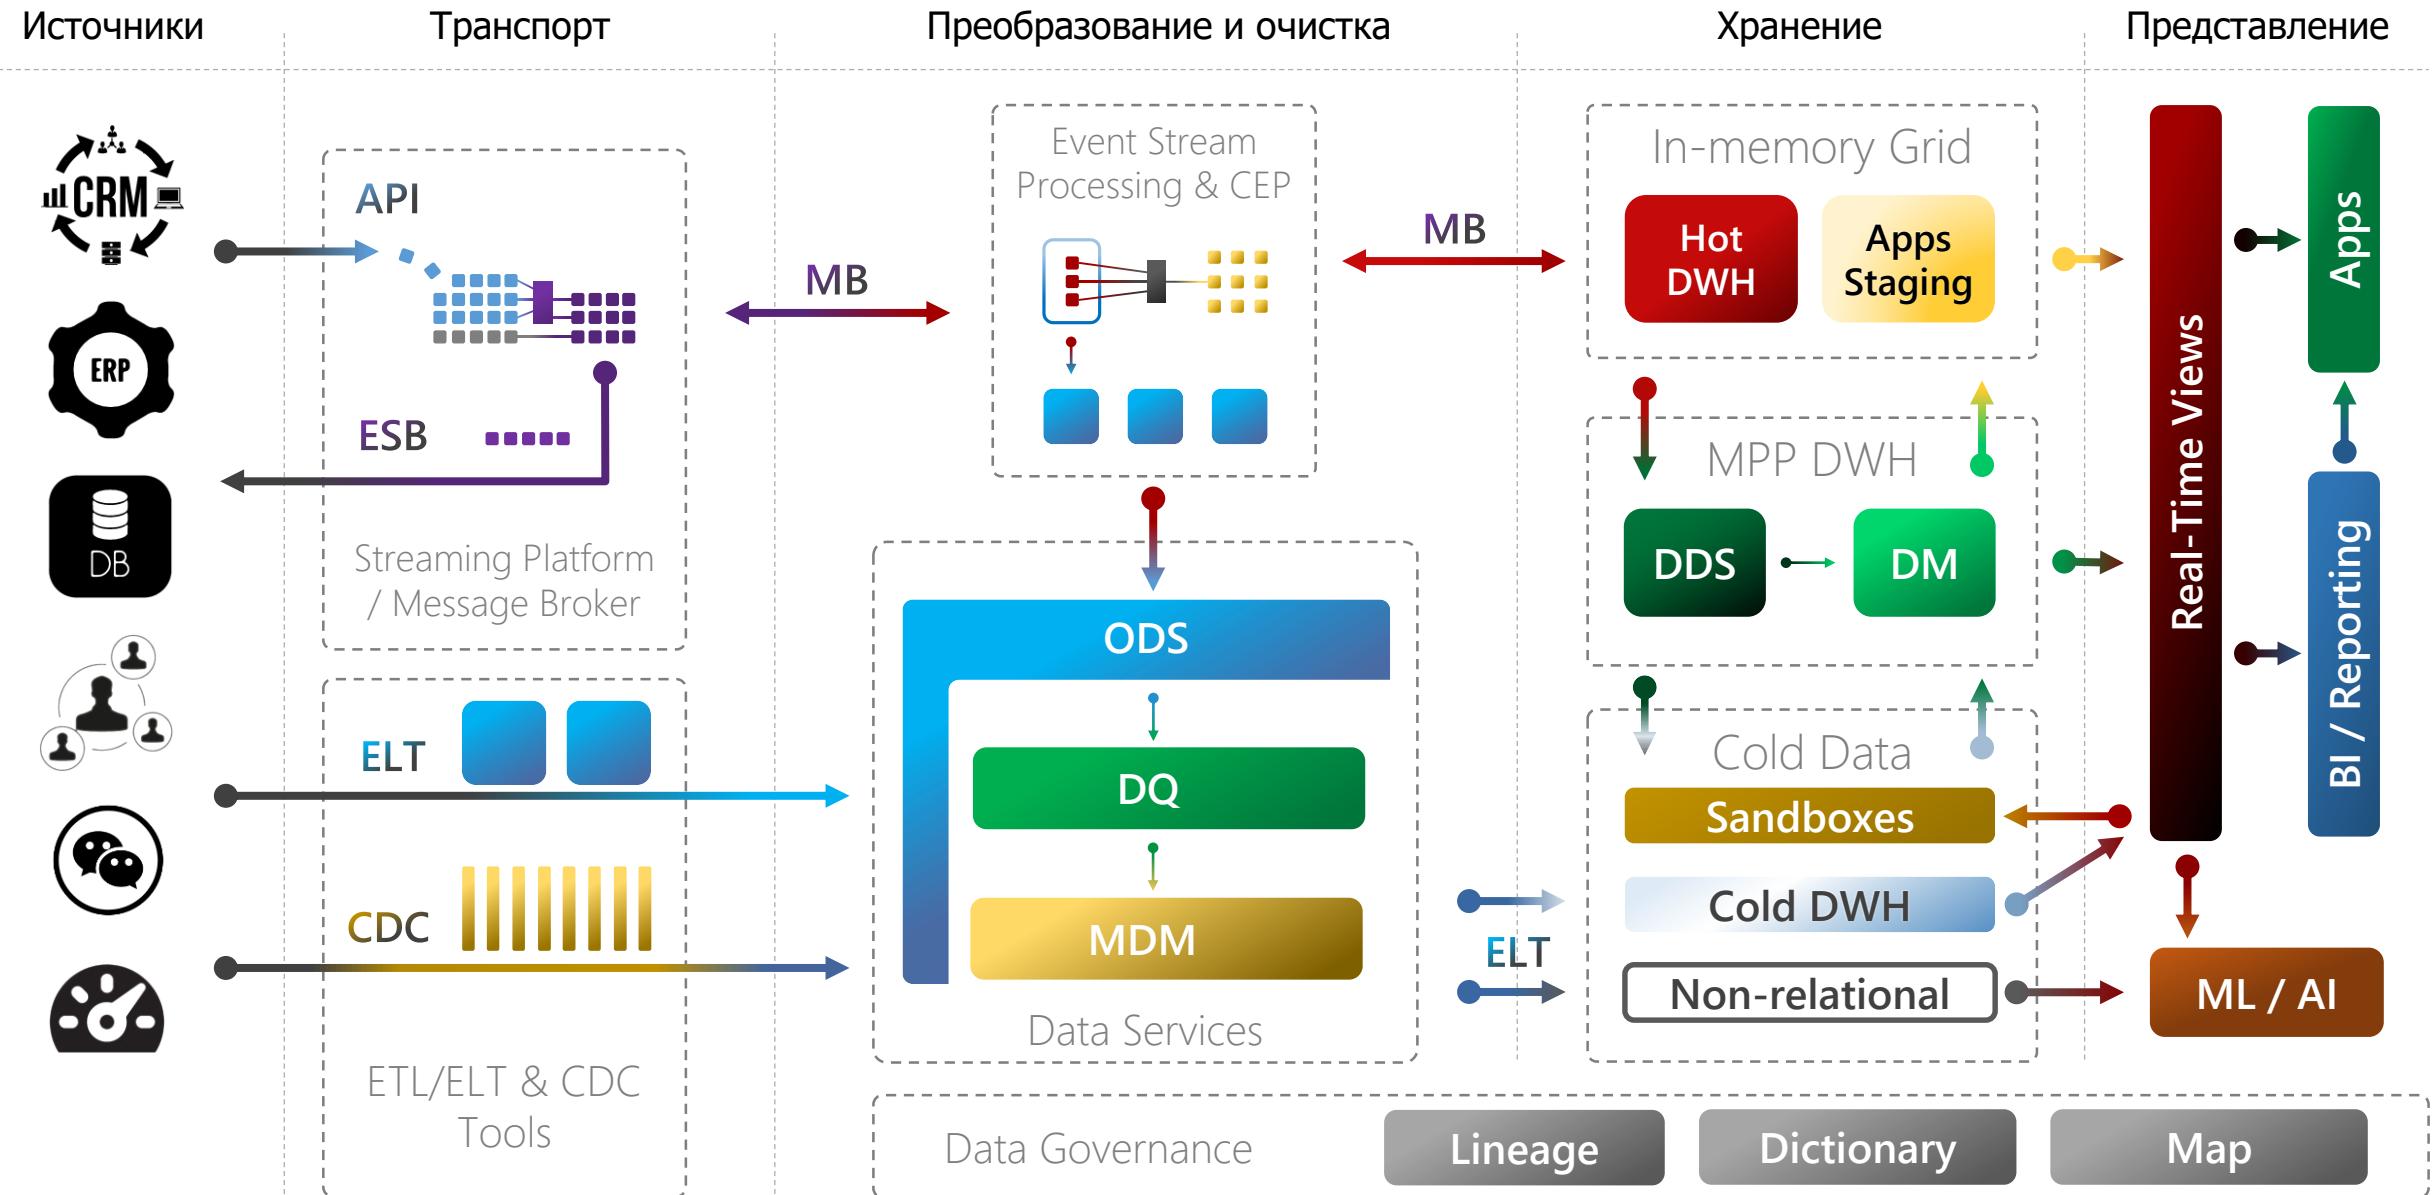


## Изменение правил

- Вместо монолитных систем – интегрированные программные платформы
- Вместо нескольких приложений с закрытой архитектурой – сотни open source проектов для решения конкретных задач
- Вместо закрытых и «неповоротливых» монстров-производителей – сотни мобильных и динамичных команд разработчиков, открыто обменивающихся идеями, наработками, кодом



# Типичная современная платформа данных



# Многофункциональная платформа данных | Arenadata EDP

## Источники



## Транспорт

AD Streaming

kafka apache nifi

Шина данных

## Преобразование и очистка

AD ETL Pack

AD Big Data DQ

Загрузка, трансформация и  
контроль качества  
данных

## Хранение

AD Grid

apache Ignite

Вычисления в реальном  
времени

AD DB

GREENPLUM  
DATABASE

DWH / КХД

AD Hadoop

hadoop

Холодные данные

## Представление

tableau

Power BI

Business Objects

Средства отчёtnости

AD Analytic Workspace

Apache  
Zeppelin

Рабочее место  
аналитика

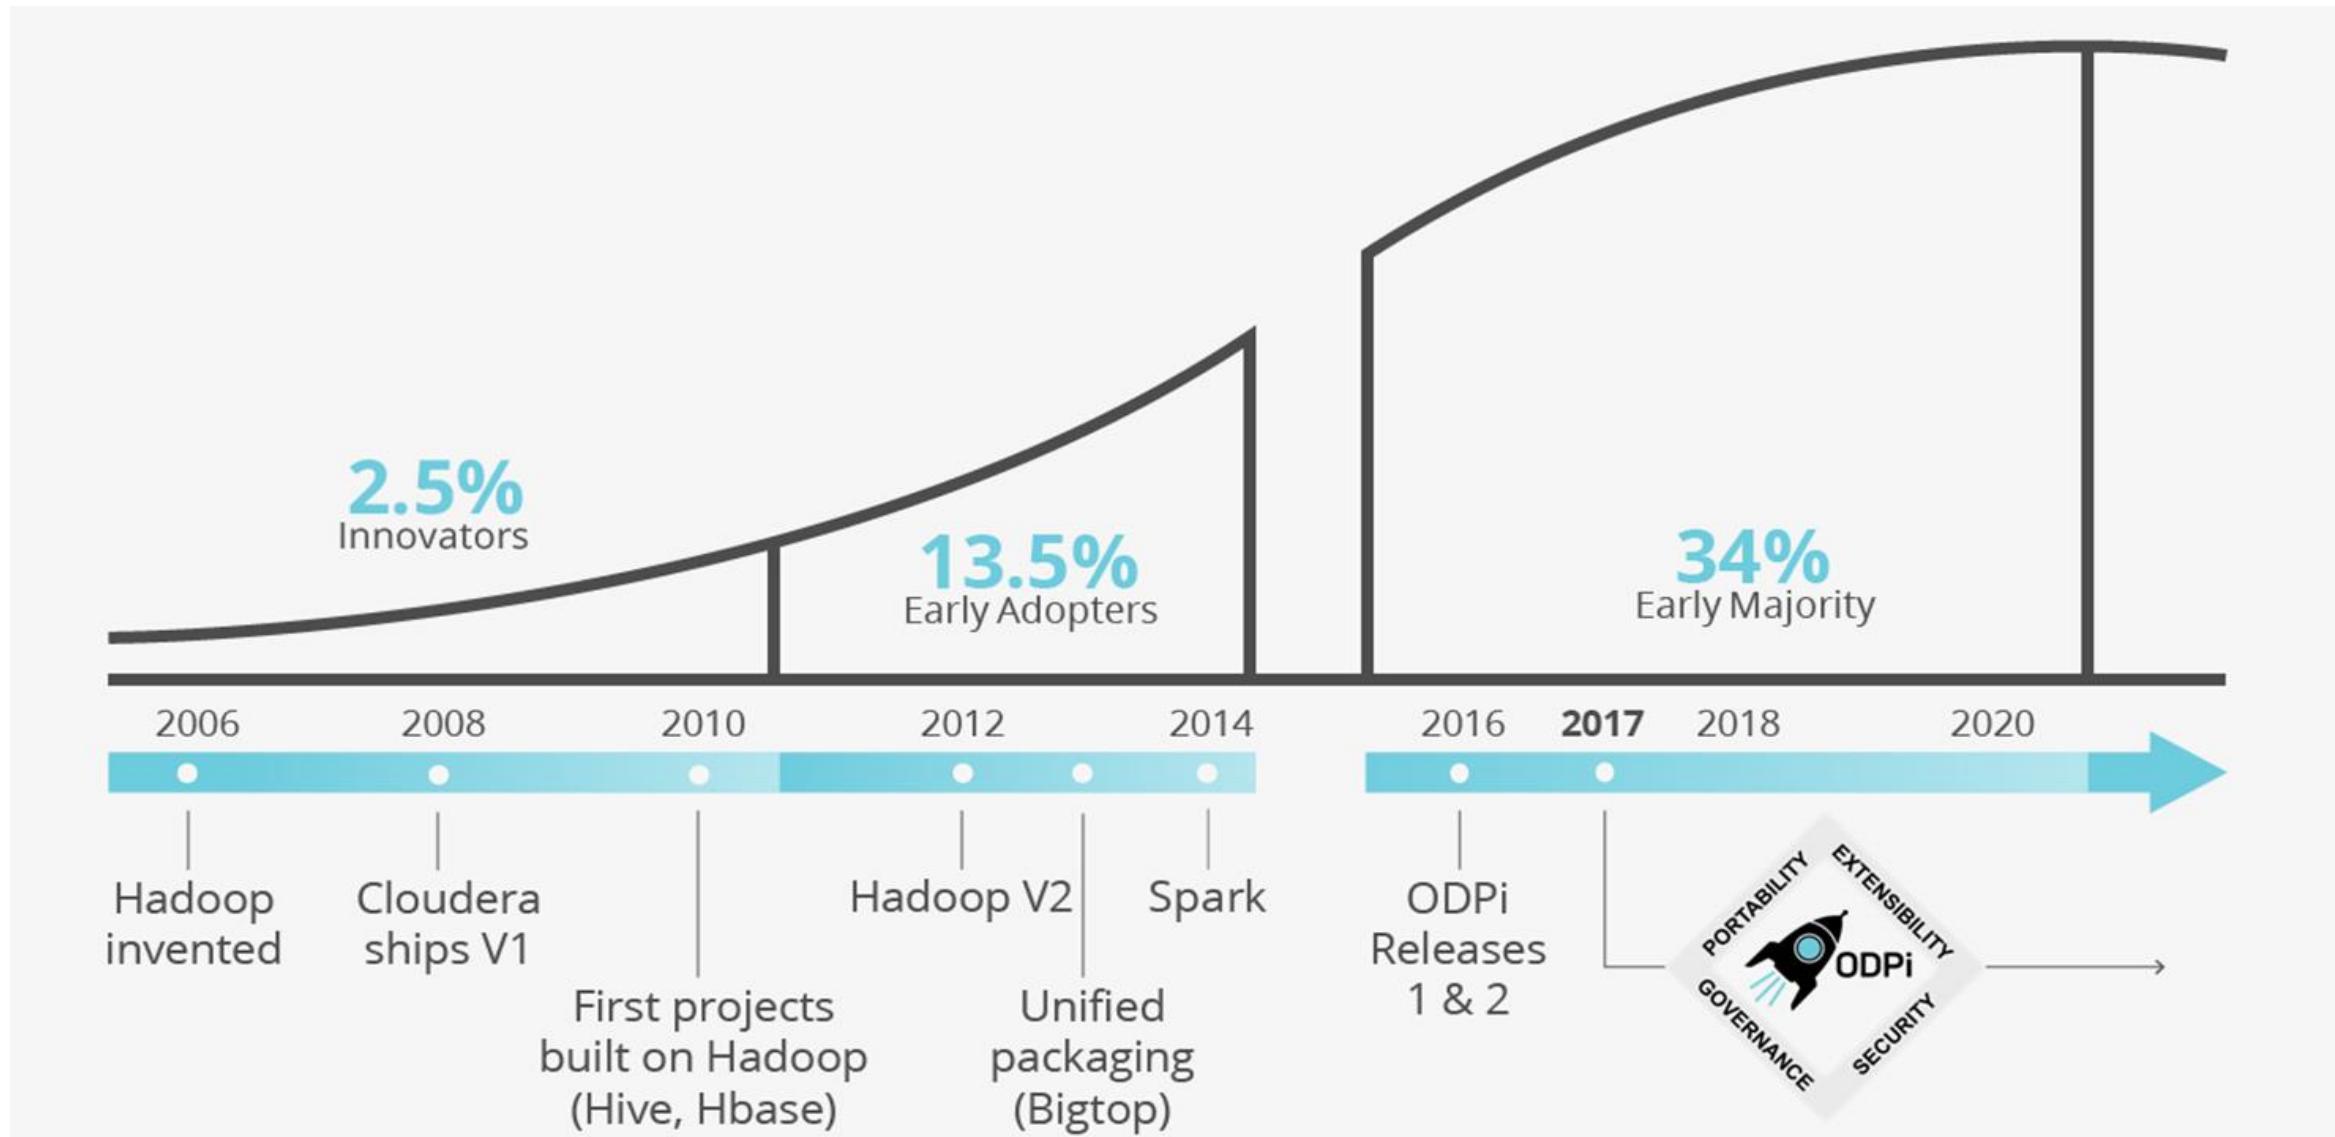
Управление данными и кластером

AD Data Catalog

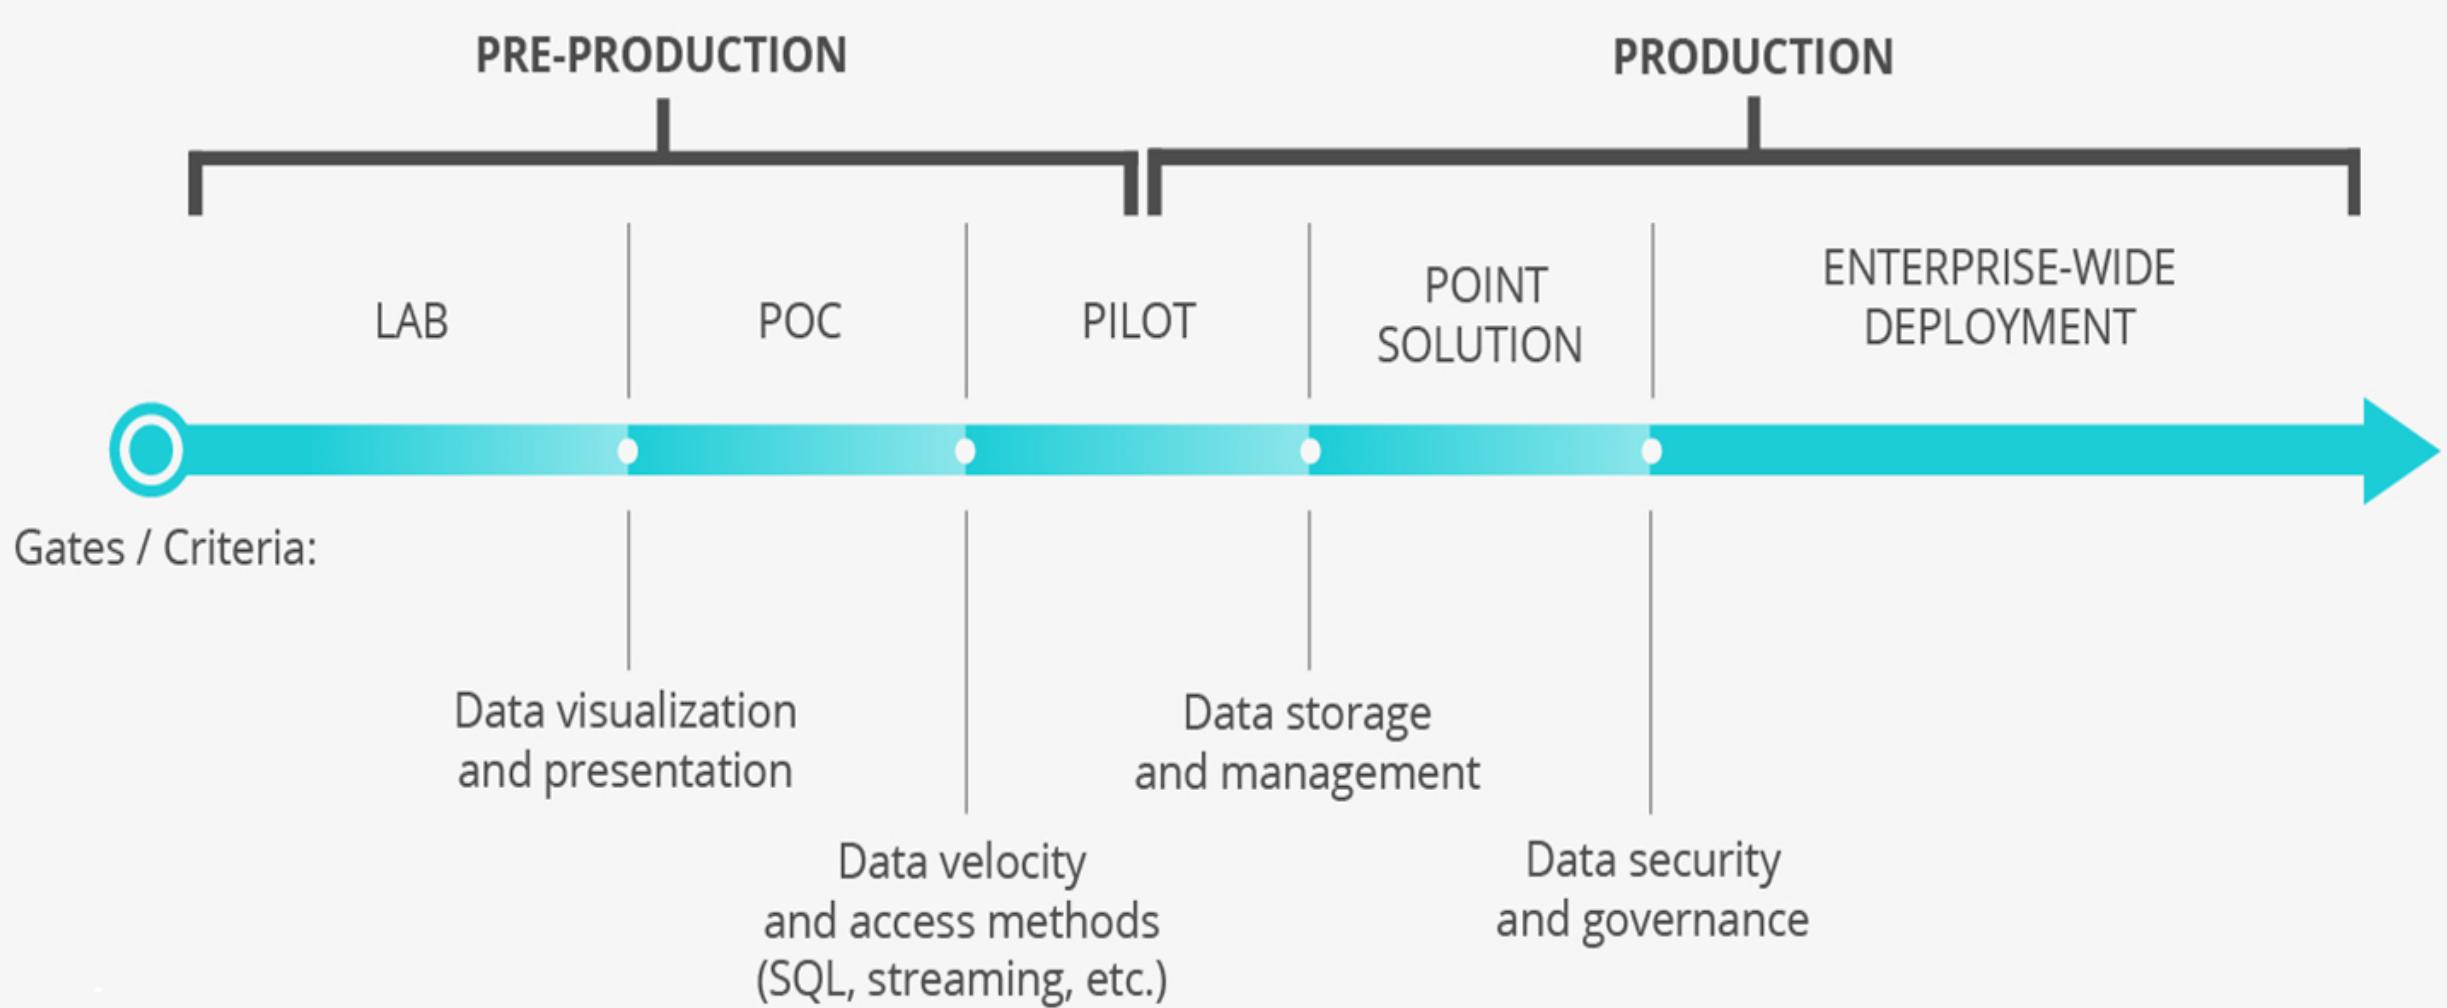
AD Cluster Manager

A

# Как корпорации «привыкают» к Hadoop



# Только 28% проектов в Продуктиве



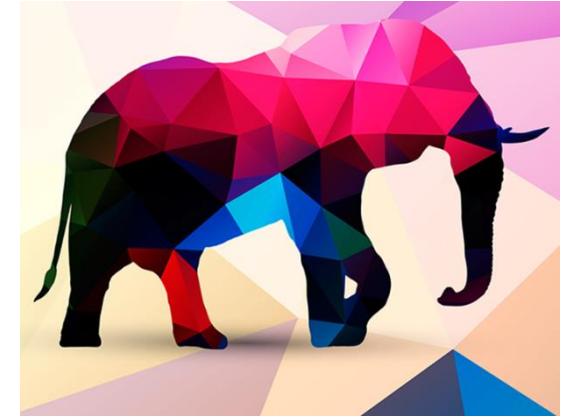
# Как не утонуть в проблемах эксплуатации open-source проектов/продуктов

Какие основные риски возникают?



# Основные мифы об Open Source

- Использование открытого ПО полностью бесплатно
- Нельзя построить бизнес-критичную систему на открытых решениях из-за отсутствия технической поддержки
- Качество открытого ПО хуже, потому что код для него может писать любой желающий
- Любой желающий может "собрать" из Open Source коробочный продукт и продавать его как свой
- На Open Source я могу сделать все, что не смог сделать на дорогих коммерческих продуктах



# Основные преимущества Open Source

- Высокая скорость разработки\быстрый старт
- Возможность внести вклад в развитие проекта
- Бесплатное использование
- Большое количество разработчиков на рынке (лояльность разработчиков)
- Возможность выбора
- Безопасность и прозрачность продукта



# На что обратить внимание

## SECURITY

Authenticate

Authorize

Audit

Setup Policies & Entitlements

Protect

Understand Risk Profile

## DATA GOVERNANCE

Profile

Classify

Collaborate

Understand Quality

Leverage Metadata

Provenance & Lineage

## OPERATIONS

Provision

Configure

Manage/Upgrade

Monitor

Scale

Perform

# Основные риски/проблемные зоны

- Сложность интеграции различных компонентов между собой
- Отсутствуют системы автоматического конфигурирования и мониторинга
- Часто отсутствуют элементы корпоративного ИБ
- Нет сформированных регламентов и сложившихся практик по обслуживанию/тех поддержки ( IT operations)
- Поддержка ИТ ландшафта в течении жизненного цикла( замена и апгрейд компонентов решения)
- «Голый» Open Source в Продуктиве



# Как снизить риски от внедрения Open Source решений

## ➤ Использование вендорских дистрибутивов на базе открытого ПО:

- Сочетает в себе все преимущества Open Source + закрывают риски по использованию Open Source в составе корпоративного ландшафта, гарантированная техническая поддержка, комплексное тестирование взаимодействия компонентов между собой.
- Наличие сформированных регламентов и методик поддержки и сопровождения в ИТ ландшафте
- Наличие практик информационной безопасности

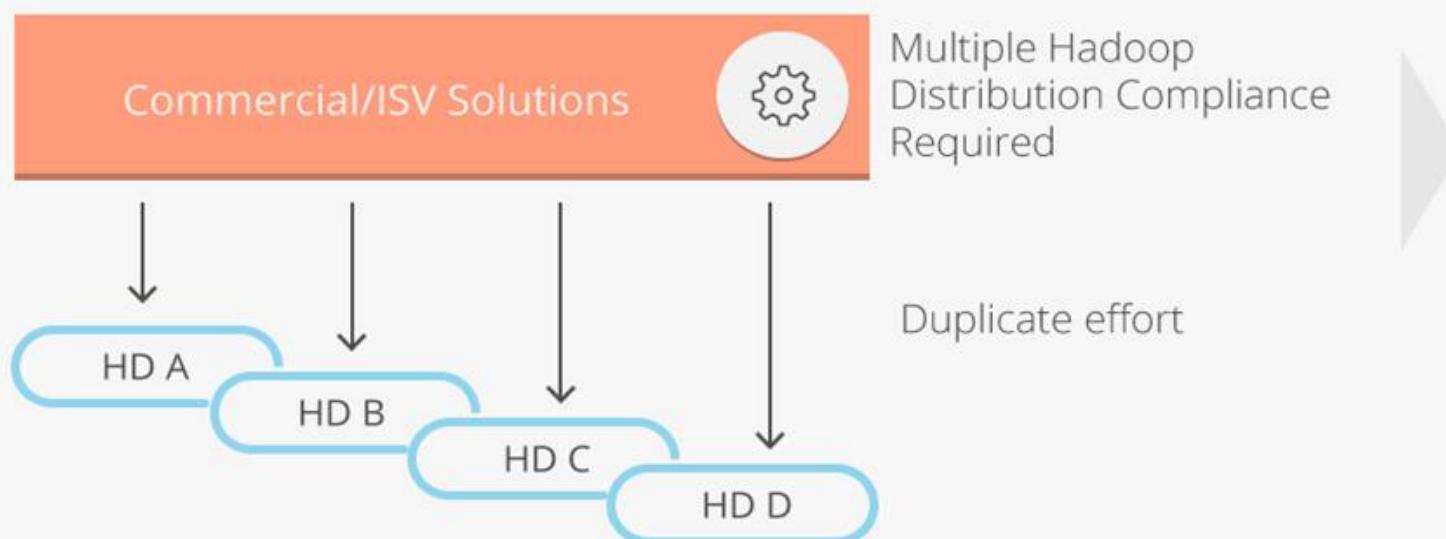


- Формирование собственной практики внутри компании по работе с Open Source ПО, «адаптация» OSS для использования в компании
- Отраслевые стандарты и ассоциации

# Стандартизация снижает сложность внедрения

## WITHOUT ODPI

Multi-distro certifications and regression testing increases ISV development, burden, and enterprise support costs



\*HD = Hadoop Distribution

## WITH ODPI

ODPi Interoperable Solutions



ODPi Runtime Compliant Platforms



ODPi Runtime Specification



# ODPi – крупнейшее мировое сообщество в области стандартов по работе с большими данными



ARENA DATA

Как сегодня компании могут эффективно  
работать и участвовать в open source проектах

и какая может быть выгода от такого участия ?



# Основные преимущества Open Source ( или зачем этим заниматься)

- Быстрый старт - особенно на этапе прототипа
- Возможность внести вклад в развитие проекта – возможность внести в проект именно то что вам нужно!
- Бесплатное использование продукта - при наличии собственной глубокой экспертизы
- Лояльность разработчиков – возможность привлекать и мотивировать сильных специалистов для работы с крупными Open Source проектами
- Прекрасная «школа» для разработчиков



# Основные формы участия

- Формирование внутренней практики по работе с OSS
- Разовые коммиты
- Работа в проектах под кураторством опытных разработчиков
- Постоянная плановая работа с РМС проекта, выделение отдельной группы для работы в проектах
- Участие в OSS сообществах и ассоциациях



# Как мы внедряем масштабные программные платформы данных в очень больших компаниях



# Несколько примеров использования OSS СУБД **Greenplum** в крупнейших проектах в России и СНГ



Яндекс.Такси



Билайн™

# Несколько примеров наших проектов



# Основные этапы и моменты в проектах

- Формирование и разработка целевой архитектуры
- Определение зон технологических рисков и формирование ТЗ на пилот для «отработки» этих рисков
  - Основные «проблемные» зоны :
    - функционал,
    - интеграция с существующим окружением,
    - производительность и масштабируемость,
    - ИБ
- Лечим от «технологического оптимизма / хадупной зависимости»
- Делаем пилот\прототип
- Формирование внутренних ИТ практик\регламентов\обучение команды
- Внедрение платформы\миграция\интеграция
- Масштабирование платформы и развитие
- Формирование практики и стратегии работы с OSS
- Совместная разработка «собственного» продукта

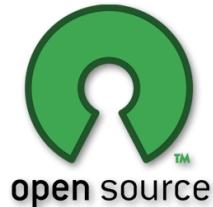


# ARENADATA

---

Переход от платформы данных к экосистеме цифровых  
сервисов

- ◆ Вносим вклад в проекты Apache Software Foundation:
  - ◆ Apache Ambari;
  - ◆ Apache Bigtop;
  - ◆ Greenplum Database;
  - ◆ Apache PXF.
- ◆ Являемся членами ODPi (Linux Foundation) с 2015 года наряду с другими крупными компаниями:



## Цифровая компания



# Гибкость платформы Arenadata

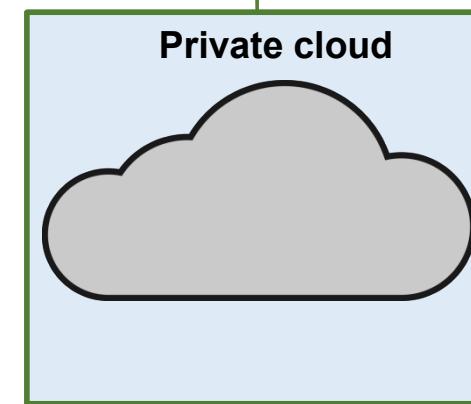
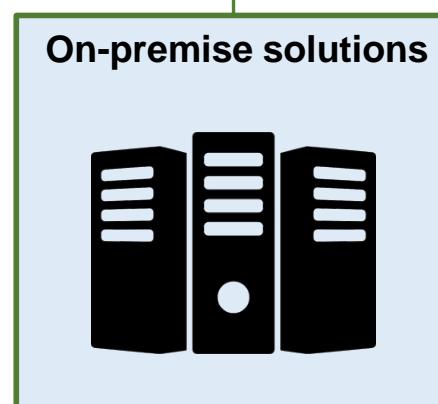
Уровень  
Приложений &  
Сервисов



Операционный  
уровень

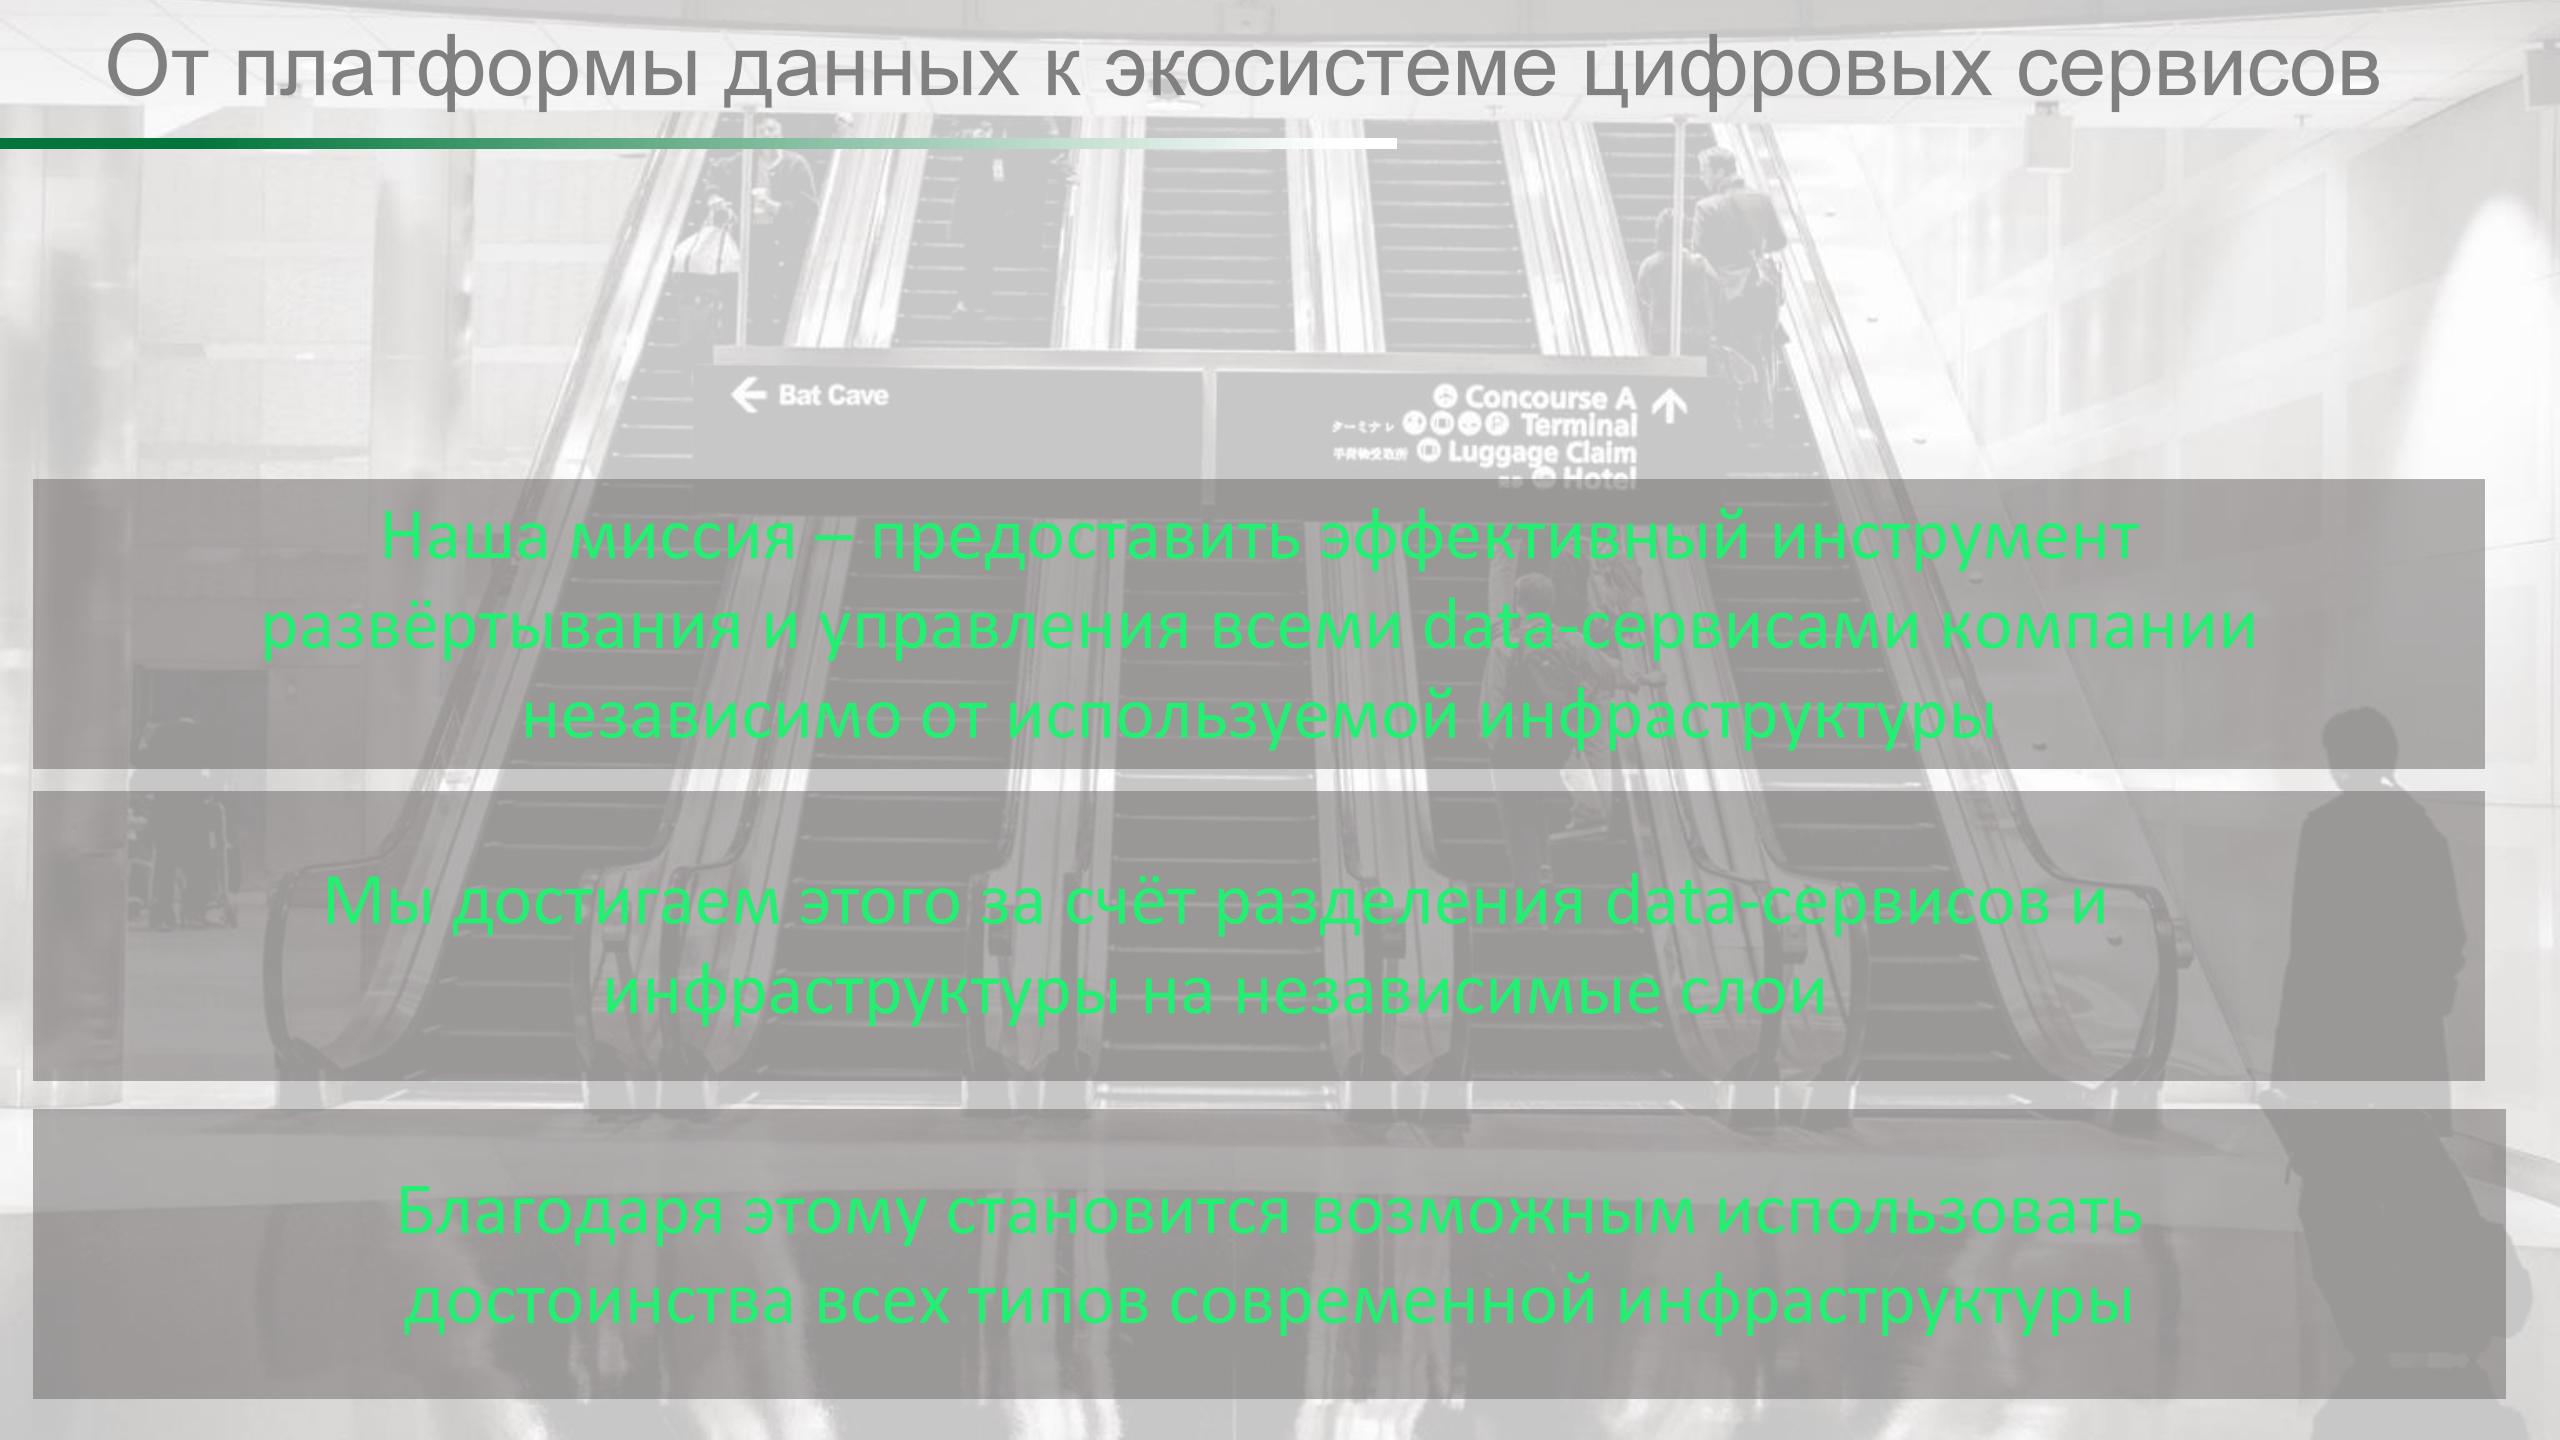


Уровень  
инфраструктуры



Разворачивается на ИТ-Инфраструктуре любого типа  
Готова для интеграции сторонних приложений

# От платформы данных к экосистеме цифровых сервисов

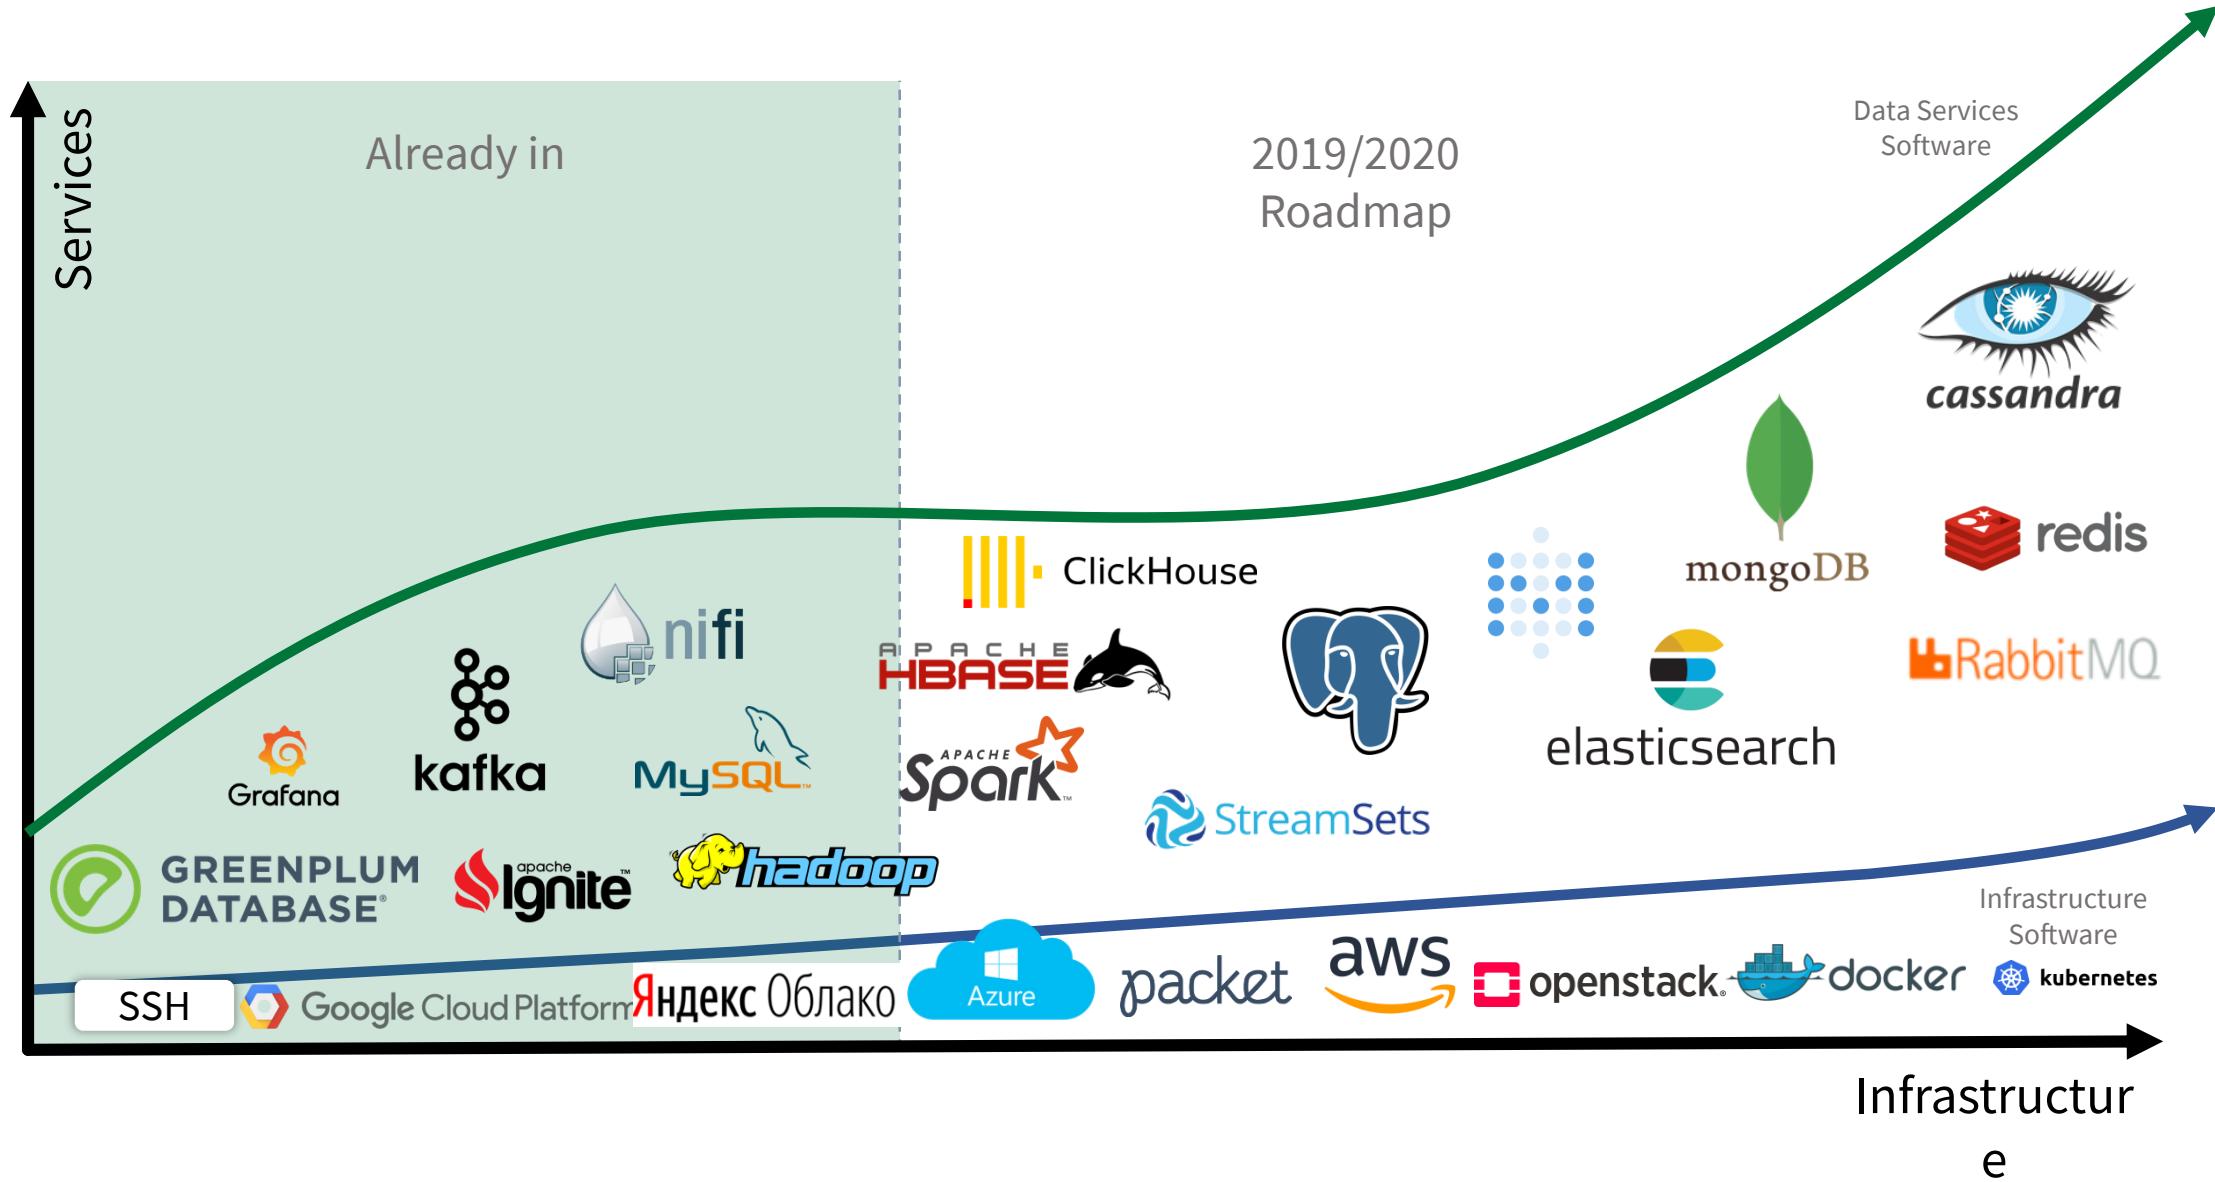


Наша миссия – предоставить эффективный инструмент развертывания и управления всеми data-сервисами компании независимо от используемой инфраструктуры

Мы достигаем этого за счёт разделения data-сервисов и инфраструктуры на независимые слои

Благодаря этому становится возможным использовать достоинства всех типов современной инфраструктуры

# Развитие экосистемы сервисов





ARENADATA