

Arenadata Hyperwave

Универсальная гибридная платформа для хранения, обработки
и анализа данных любой структуры и объёма



План презентации

1. О компании Arenadata
2. Обзор Arenadata Hyperwave
3. Экосистема Arenadata Hyperwave
4. Сравнение ADH vs Open Source
5. Платформа сбора и хранения данных Arenadata Enterprise Data Platform

О компании Arenadata

Arenadata

лидер в области платформ больших данных для цифровой трансформации

СТАБИЛЬНОСТЬ

ПАО Группа Arenadata:

- 9 лет на рынке
- 600+ сотрудников
- 6 млрд ₽ выручка '24
- 30 млрд ₽ капитализация

150+ КЛИЕНТОВ

- ВТБ, ПСБ, ГПБ, Т-Банк
- ГПН, Росатом, Норникель
- X5, Магнит, Ашан, Hoff
- Мегафон, МТС, НН.ru
- ФНС, ДИТ МСК, Росреестр

ПРОДУКТЫ

- Мы создаем **тиражируемые продукты**, которые внедряют наши партнеры и клиенты
- 170+ релизов в год
- Обеспечиваем совместимость с **upstream open source**

ONPREM & CLOUD

- On-premise и ПАКи
- Cloud: VK Cloud, Cloud.ru, Selectel, MWS, TP Cloud, K2 Cloud, Beeline Cloud
- Гетерогенные ландшафты

#DATA

Дата-платформа в доменах:

- **Аналитика, Транзакции, Интеграция, Data Governance**
- Техническая поддержка 1, 2 и 3 линии и сервисы от вендора

ЭКСПЕРТЫ

- 150+ технологических партнеров и интеграторов
- 4 000+ экспертов подготовлено в центре обучения Arenadata

ВКЛАД В OPENSOURCE

- **Greengage**: преемник Greenplum
- **ClickHouse**: #1 контрибутор в РФ
- **Greengage, Kyuubi, Spark, Kafka, SSM, PXF**: коммитим в ядро
- **ADCM, Picodata**: собственные open source-проекты
- Открытая онлайн [документация](#)

РЕГУЛЯТОРЫ

- Отечественные ОС
- Реестр Минцифры
- ФСТЭК УД4
- ГосТех, ГЕОП



Наш успех – доверие клиентов

150+ клиентов размещают свои хранилища, витрины, озера данных на продуктах Arenadata

Банки и страховые: **40+ клиентов**



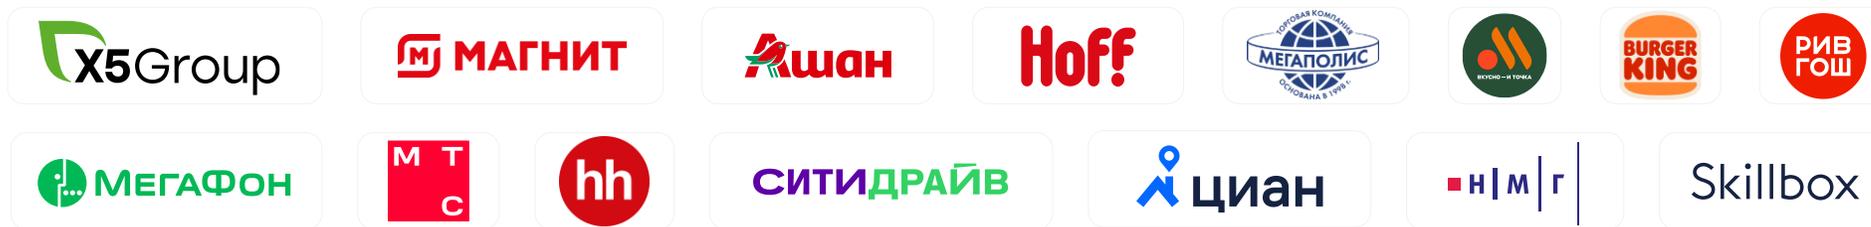
Промышленность, ТЭК, Транспорт: **40+ клиентов**



Госсектор: **30+ клиентов**



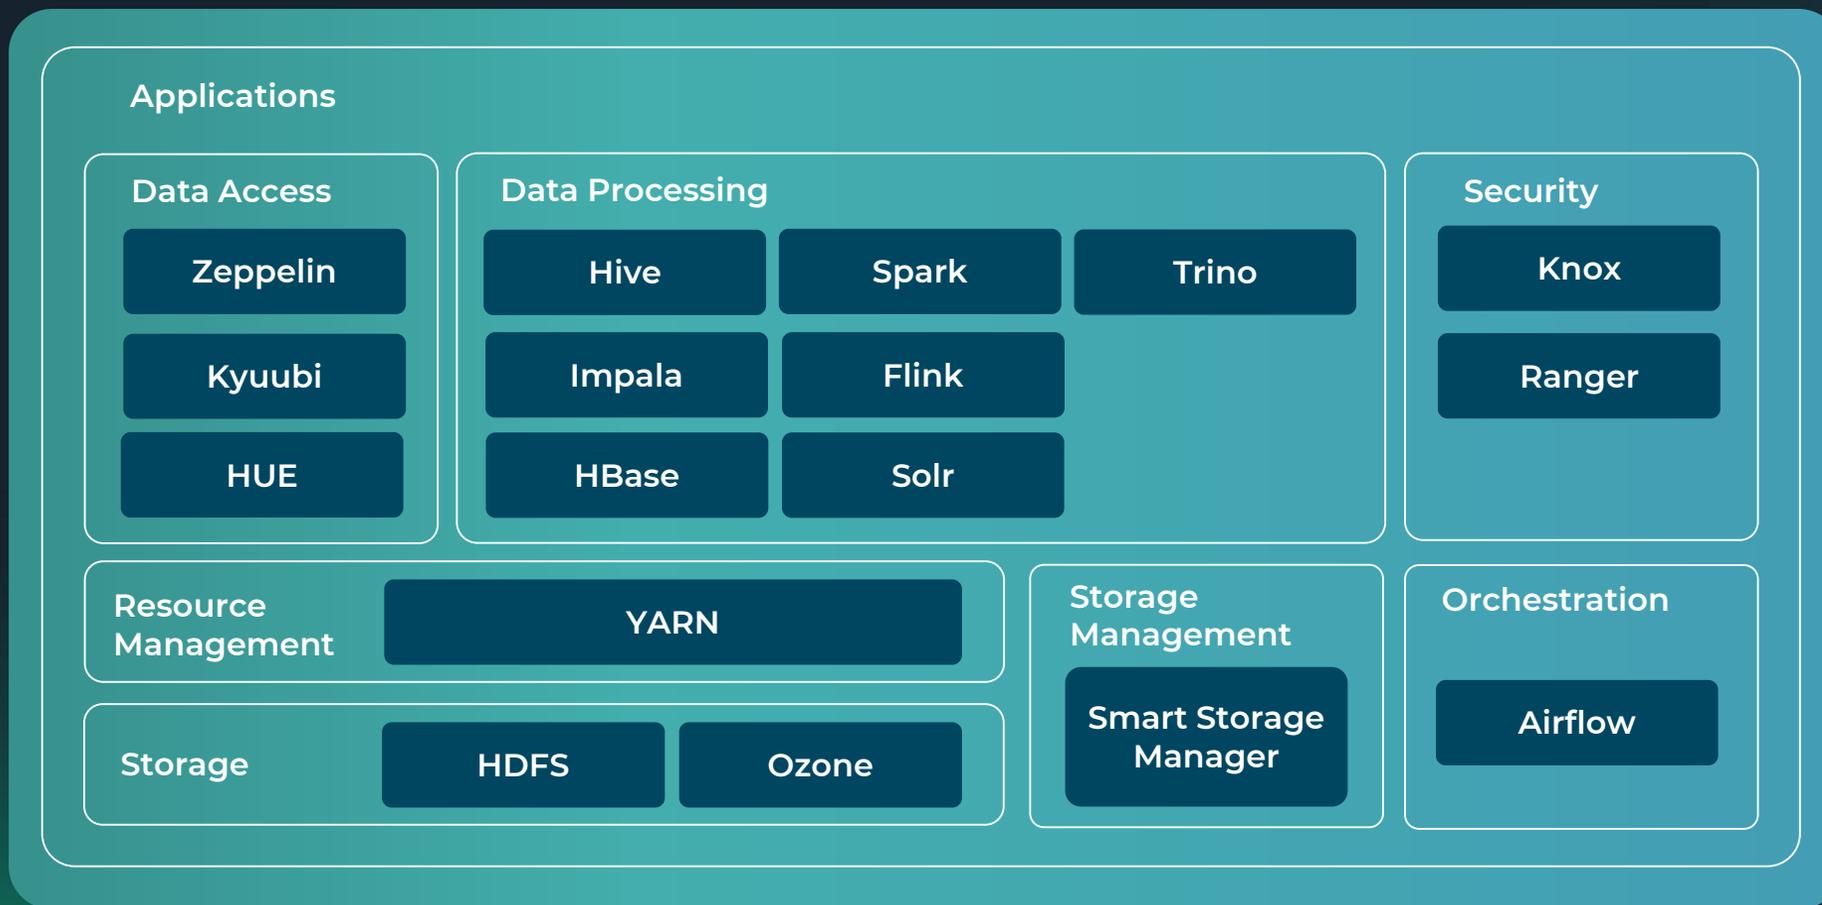
Retail, FMCG, Фарма, Telecom, Digital, Media: **30+ клиентов**



Обзор Arenadata Hyperwave

Гибридная платформа данных

Универсальная платформа для хранения, обработки и анализа данных любой структуры и объёма



Децентрализация
компонентов

Устранение жёсткой
привязки к hadoop-
сервисам

Гибридная
архитектура

Федеративный доступ
к данным

Развитие Observability

Основа Data Lake,
Lakehouse, Data Mesh

Технические возможности Arenadata Hyperwave

Хранение данных

- Распределённое отказоустойчивое хранение
- Объектное хранилище с S3-совместимым интерфейсом
- Поддержка колоночных форматов для аналитических нагрузок
- Табличный формат Iceberg с поддержкой ACID-транзакций
- Горизонтальное масштабирование до экзабайт данных
- Поддержка горячего/холодного хранения
- Автоматизация управления хранением данных (многоуровневое хранение, репликация, сжатие, настройка политик Erasure Coding и др.)

Обработка и анализ данных

- Multi Engine обработка данных
- Единая платформа для пакетной и потоковой загрузки и аналитики
- Открытые и проприетарные коннекторы ко всем популярным системам
- Интеграция с единым метастором
- Федеративные распределённые запросы к разнородным источникам
- Low-latency для OLAP-запросов поверх HDFS/Ozone/S3
- Поддержка полнотекстового, векторного и геопространственного поиска

Пользовательские интерфейсы

- Единые веб-интерфейсы для доступа ко всей платформе
- Интерактивная аналитика
- Совместимость с BI-инструментами
- Multitenant поддержка

Безопасность

- Централизованное управление RBAC-политиками
- Интеграция с LDAP/AD/Kerberos
- Колоночное маскирование
- Шифрование данных и чувствительных конфигураций
- Трассировка всех операций и централизованный аудит системы
- Сертификация для корпоративных сред

Решаемые задачи



Хранение, обработка и анализ данных любой структуры и объёма

- Распределённая обработка данных
- Системы управления документами и контентом
- Хранение и регистрация событий
- Данные датчиков, каталоги товаров
- Резервное копирование других СУБД



Построение озёр данных, lakehouse и data mesh

- Единый центр всех данных компании
- Быстрое развёртывание «песочниц» для пилотных проектов и проверки статистических гипотез
- Работа со всеми аналитическими инструментами в единой среде



Машинное обучение и искусственный интеллект

- Обучение моделей на больших данных
- Распределённое машинное обучение на базе Spark
- Эффективная эксплуатация моделей в SQL-среде с помощью встроенных функций Madlib



Импортозамещение и разгрузка систем зарубежных вендоров

- Миграция с иностранных систем (Oracle BDA, Cloudera)
- Прозрачная методика перехода, минимум рисков и сохранение всех преимуществ

Экосистема Arenadata Hyperwave

Архитектурные паттерны и сценарии
использования



Data Lake

Подход предполагает наличие выделенного хранилища данных для оперативной отчётности, отдельного решения для быстрых SQL-запросов и озера данных для дешёвого хранения исторических данных и удобной интеграции.



Интеграция данных

Сбор и согласование данных из разнородных источников (IoT-датчики, веб-логи, финансовые транзакции, соцсети) в едином озере.



Анализ больших данных

Предварительная обработка и хранение «сырых» данных в озере данных, глубокий статистический и BI-анализ — в корпоративном хранилище.



Аналитика логов

Хранение сырых лог-файлов в озере и последующая их агрегация в хранилище данных для корреляции событий и оповещений об инцидентах.

Lakehouse

Универсальная платформа, объединяющая мощь классического хранилища с гибкостью озера данных. Позволяет выполнять любые нагрузки – от батчевой аналитики до стриминговых вычислений и машинного обучения.



GenAI и LLM

GenAI и LLM используют огромные объёмы неструктурированных данных. ADH предоставляет инструменты и инфраструктуру для их обработки и выполнения сложных запросов.



Обнаружение и предотвращение мошенничества

Потоковая обработка транзакций и событий с низкой задержкой, применение ML-моделей на лету



Анализ больших данных

ADH может использоваться для обработки и анализа больших объёмов данных. Полученная информация ценна для анализа поведения пользователей, рыночных трендов и других показателей.



Интеграция данных

Интеграция данных из различных источников и форматов в единое хранилище помогает бизнесу устранить разрозненность информации и обеспечить её согласованное представление.

Data Mesh & Multitenancy

Data Mesh превращает данные в продукты, а Arenadata Hyperwave обеспечивает инфраструктуру для этого подхода: доменные команды работают с изолированными данными через единый каталог, сохраняя автономность. Мультитенантность реализована на всех уровнях, что позволяет безопасно делить платформу между командами, партнёрами и окружениями, соблюдая compliance и оптимизируя затраты.



Корпоративные Data Mesh-инициативы

Доменные команды развивают собственные хранилища в рамках единого каталога, сохраняя автономию и единообразие метаданных.



Compliance и управление доступом

Тонкая гранулярная настройка политик безопасности и аудита.



Безопасное разделение среды

Физическая или логическая изоляция кластеров под разные бизнес-юниты, партнёров или окружения. От разделения на уровне хранилища и ресурсов до физического выделения кластера под отдельный домен.

Экосистема Arenadata Hyperwave

Компоненты и сервисы



Компоненты ADH

ADH 3.2.4.3

ADH 3.3.6.1

ADH 3.3.6.2

ADH 4.0.0

ADH 4.1.0

| | | | | | | |
|---------------------|-----------------------|--------|--------|--------|--------|--------|
| Storage | HDFS | 3.2.4 | 3.3.6 | 3.3.6 | 3.3.6 | 3.4.2 |
| | Ozone | - | - | 1.4.1 | 1.4.1 | 2.0.0 |
| Resource Management | YARN | 3.2.4 | 3.3.6 | 3.3.6 | 3.3.6 | 3.4.2 |
| Coordination | ZooKeeper | 3.5.10 | 3.8.4 | 3.8.4 | 3.8.4 | 3.8.4 |
| Service Management | Smart Storage Manager | 1.6.0 | 2.0.0 | 2.0.1 | 2.1.0 | 2.2.0 |
| Data Access | Zeppelin | 0.11.1 | 0.11.1 | 0.11.1 | 0.11.2 | 0.11.2 |
| | Kyuubi | 1.8.1 | 1.9.0 | 1.9.0 | 1.10.1 | 1.10.2 |
| | HUE | - | 4.11.0 | 4.11.0 | 4.11.0 | 4.11.0 |
| Data Processing | Hive | 3.1.3 | 4.0.0 | 4.0.0 | 4.0.1 | 4.0.1 |
| | Spark2 | 2.3.2 | 2.3.2 | 2.3.2 | - | - |
| | Spark3 | 3.4.2 | 3.5.1 | 3.5.1 | 3.5.4 | 3.5.6 |
| | Spark4 | - | - | - | - | 4.0.0 |
| | Impala | 4.4.0 | 4.4.0 | 4.4.0 | 4.5.0 | 4.5.0 |
| | Flink | 1.18.1 | 1.19.1 | 1.19.1 | 1.20.1 | 1.20.2 |
| | Flink2 | - | - | - | - | 2.0.0 |
| | HBase | 2.4.17 | 2.5.8 | 2.5.8 | 2.5.8 | 2.6.3 |
| | Solr | 8.11.2 | 8.11.3 | 8.11.3 | 8.11.3 | 8.11.3 |
| | Sqoop | 1.4.7 | 1.4.7 | 1.4.7 | - | - |
| | Trino | - | - | 468 | 468 | 476 |
| Orchestration | Airflow2 | 2.6.3 | 2.6.3 | 2.6.3 | 2.6.3 | 2.6.3 |
| Security | Knox | 1.6.0 | 2.0.0 | 2.0.0 | 2.0.0 | 2.0.0 |
| | Ranger | 2.4.0 | 2.5.0 | 2.5.0 | 2.6.0 | 2.6.0 |
| | Kerberos | latest | latest | latest | latest | latest |
| Cluster Management | ADCM | latest | latest | latest | latest | latest |

Предыдущие версии

ADH 3.2.4.3

ADH 3.3.6.1

ADH 3.3.6.2

Текущая версия

ADH 4.0.0

Будущая версия

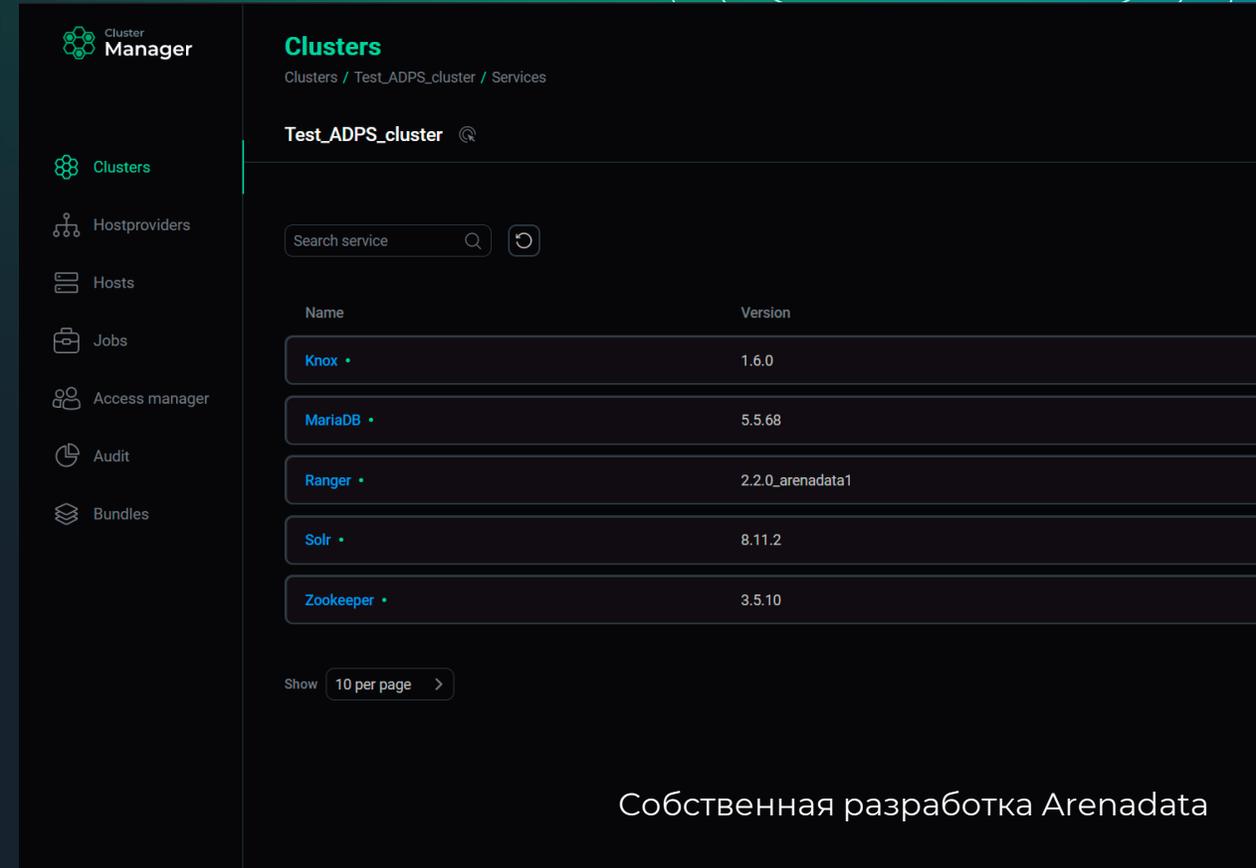
ADH 4.1.0



Система централизованного управления политиками безопасности кластера ADH включает:

- аутентификацию с использованием Kerberos, интеграцию с LDAP/Active Directory, FreeIPA, Samba
- интеграцию с Apache Ranger и Apache Knox для обеспечения безопасного доступа к кластерам Hadoop
- журналы аудита и отчёты

Поставляется как бесплатное дополнение к enterprise-редакции ADH



The screenshot displays the 'Cluster Manager' interface. On the left is a navigation sidebar with options: Clusters, Hostproviders, Hosts, Jobs, Access manager, Audit, and Bundles. The main content area is titled 'Clusters' and shows the path 'Clusters / Test_ADPS_cluster / Services'. Below this is a search bar for services and a table listing installed services for the 'Test_ADPS_cluster'.

| Name | Version |
|-----------|------------------|
| Knox | 1.6.0 |
| MariaDB | 5.5.68 |
| Ranger | 2.2.0_arenadata1 |
| Solr | 8.11.2 |
| Zookeeper | 3.5.10 |

At the bottom of the interface, there is a 'Show 10 per page' dropdown menu.

Собственная разработка Arenadata

Функции безопасности Arenadata Platform Security

Комплексный подход к безопасности, включающий защиту периметра, управление доступом на основе политик, авторизацию и безопасный доступ к платформе и её сервисам.

Защита конфиденциальных данных и соответствие нормативным требованиям



Безопасность периметра

- Apache Knox
- Gateway



Аутентификация

- Kerberos
- LDAP/AD
- FreeIPA
- Samba
- MIT KDC



Защита данных

- SSL
- Шифрование RPC
- Шифрование at Rest



Аудит и мониторинг

- Запросы доступа
- Операции обработки данных
- Изменение данных



Авторизация

- Контроль доступа ко всем сервисам дистрибутива
- Контроль доступа на уровне баз данных, таблиц, столбцов для наборов данных SQL-движков
- Контроль доступа Knox
- Контроль доступа к коллекциям Solr

Impala: распределённая система исполнения SQL-запросов



Impala обеспечивает быстрые интерактивные SQL-запросы к данным, хранящимся в HDFS, HBase или S3-хранилище. Является унифицированной платформой для запросов в режиме реального времени или пакетных запросов.

Высокая скорость обработки запросов

Низкая задержка и высокий уровень параллелизма позволяет эффективнее решать задачи self-service аналитики и ad-hoc запросов

Простое внедрение в имеющуюся инфраструктуру

Impala использует те же метаданные, синтаксис SQL (Hive SQL) и драйвер JDBC, что и Hive

Оптимизация ландшафта

Благодаря локальной реализации отдельных сценариев ad-hoc и self-service аналитики

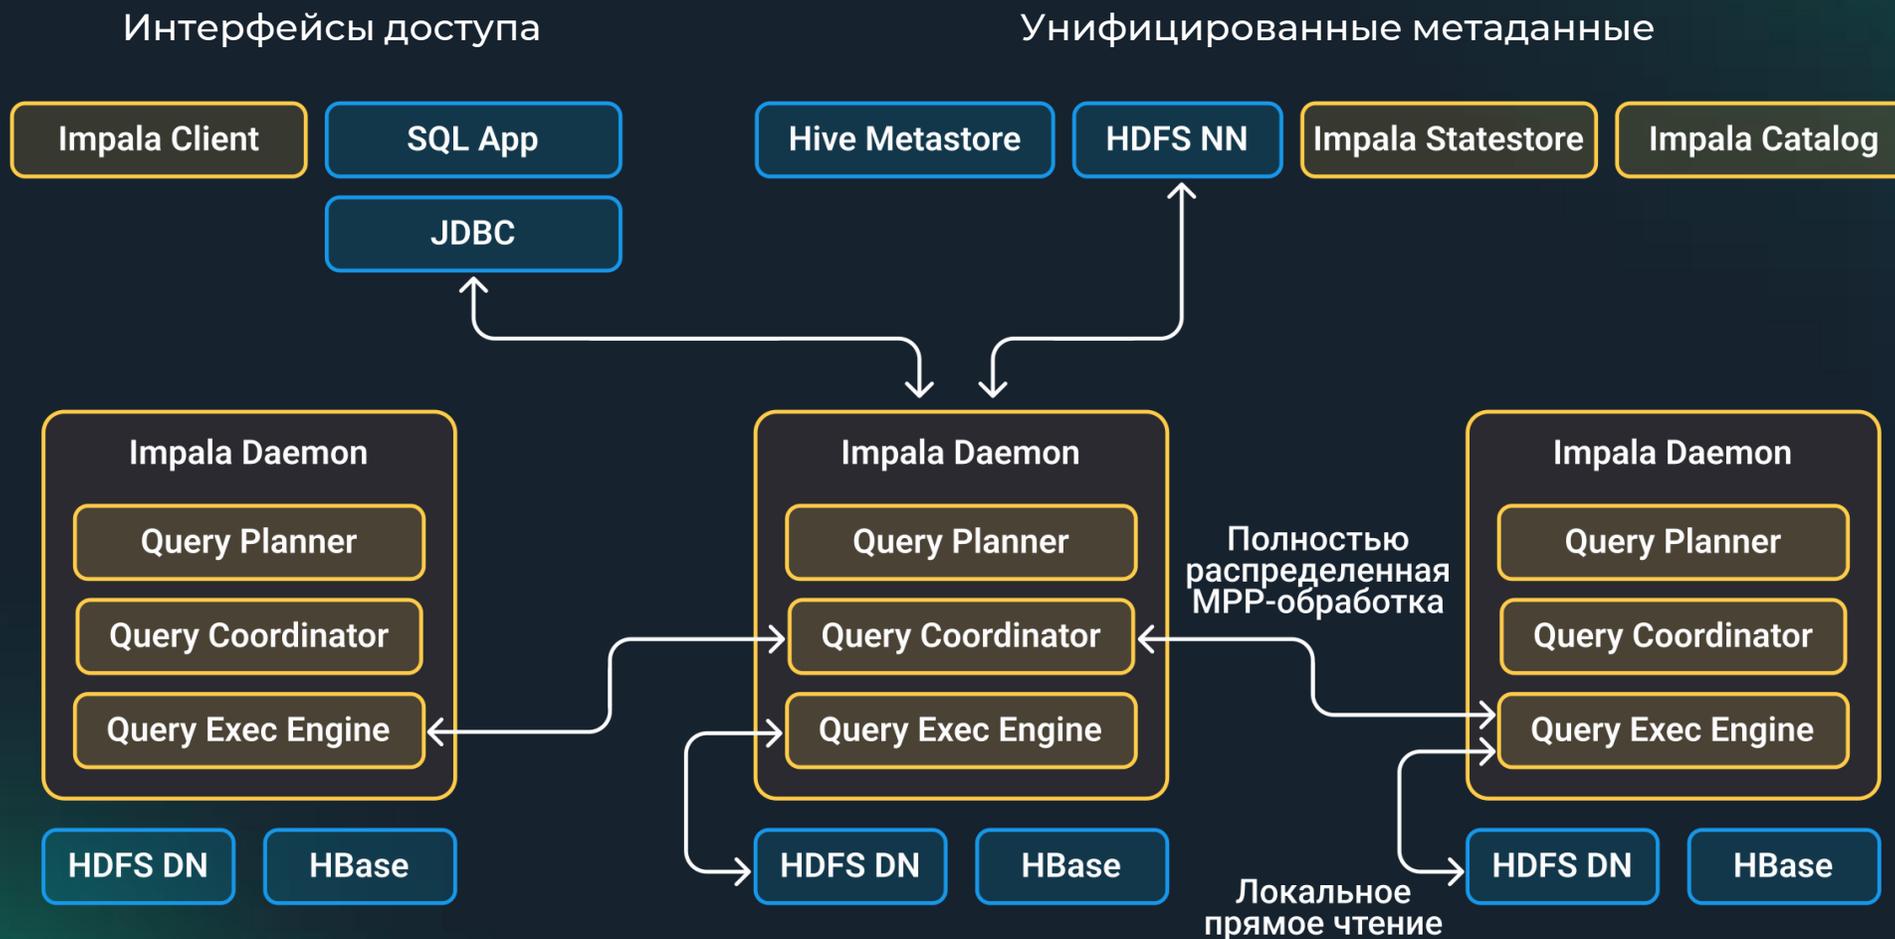
Снижение стоимости обработки данных

Достигается за счёт оптимального использования аппаратного обеспечения

Масштабирование аналитической нагрузки

Развёртывание Impala вне основного кластера позволяет исключить конкуренцию за аппаратные ресурсы

Архитектура Impala



Почему Impala? Технические аргументы



Быстрый SQL – ELT на больших данных

(TPC-DS/H SF>5000)

- MPP-архитектура на Hadoop
- Механизм Short-Circuit (только C++ библиотеки)
- Кэширование данных
- Кэширование метаданных
- Вычисления в памяти



Перспективный open source проект

- Активно развивается
- Hadoop Native (HDFS, Ozone)
- Проверенный production ready сервис



Конкурентный доступ – Ad Hoc-analysis

- Минимальная утилизация ОП
- Механизм кэширования данных ОС

Excluding merges, 22 authors have pushed 63 commits to master and 69 commits to all branches. On master, 292 files have changed and there have been 118,117 additions and 10,214 deletions.



apache / impala

Варианты развёртывания Impala

1. Совместно с HDFS на одном узле данных
2. Отдельный аналитический кластер Impala

1

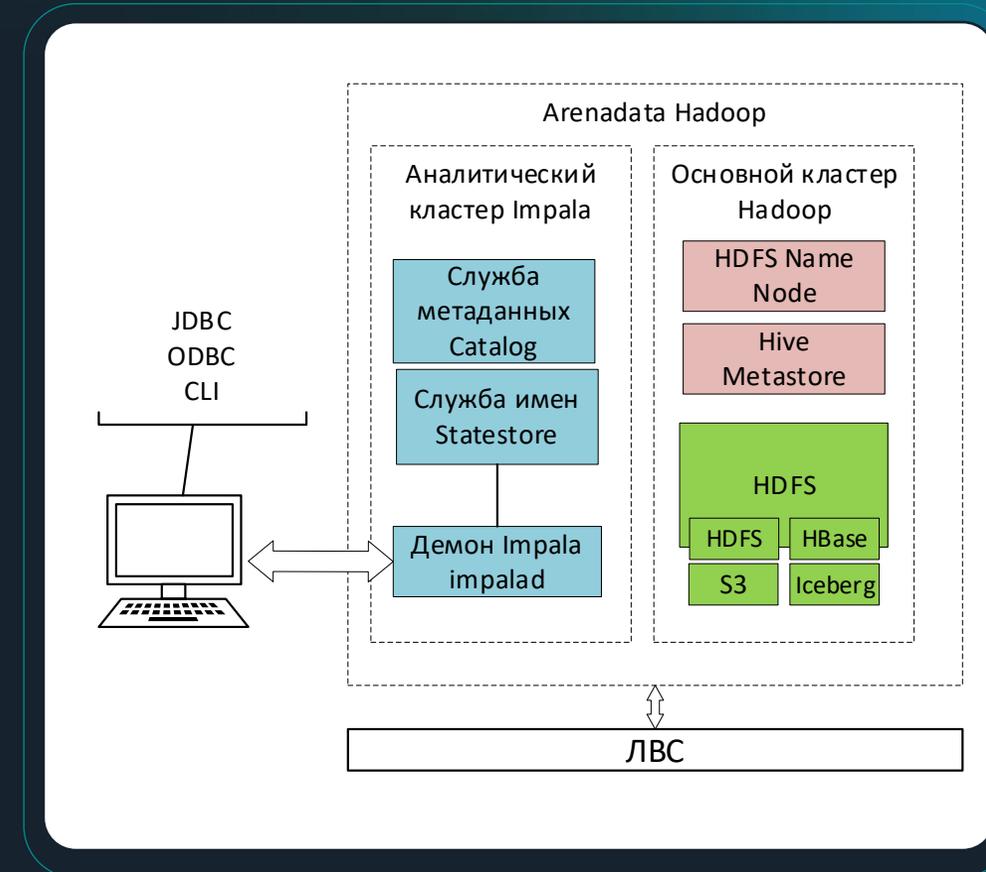
Совместное с HDFS развёртывание это:

- максимально производительный MPP
- использование преимуществ механизма прямого доступа к блокам данных (Short-Circuit) и HDFS cache

2

Развёртывание отдельного аналитического кластера Impala позволит:

- использовать существующую инфраструктуру хранения и обработки
- дополнить производственный кластер быстрой Ad Hoc-аналитикой
- ускорить критические ELT-процессы



Smart Storage Manager: интеллектуальное управление данными

Температурное хранение данных

Оптимизация управления данными в зависимости от их востребованности:

- перемещение наиболее горячих данных в кэш
- перемещение горячих данных в SSD
- архивация холодных данных

Настройка политик Erasure Coding и сжатия данных

- гибкая настройка включения Erasure Coding и управление файлами с разными политиками EC с помощью правил
- сжатие данных в HDFS без ограничения доступа к ним для внешних приложений

Асинхронная репликация

Репликация данных между Hadoop-кластерами или между Hadoop-кластером и облачным хранилищем:

- отслеживание изменений данных
- синхронизация в реальном времени
- реализация сценариев аварийного восстановления

Оптимизация работы с небольшими файлами

- сжатие небольших файлов в файл-контейнер, хранящийся в HDFS
- данные доступны для приложений верхнего уровня

80%

вычислительных
нагрузок приходится
на обработку

20%

данных

Smart Storage Manager: преимущества сервиса

- Снижение стоимости хранения холодных данных
- Повышение производительности чтения горячих данных
- Простая настройка и управление функцией асинхронной репликации
- Снижение накладных расходов и повышение производительности записи и чтения небольших файлов HDFS
- Экономия места в хранилище



Оптимизация
затрат

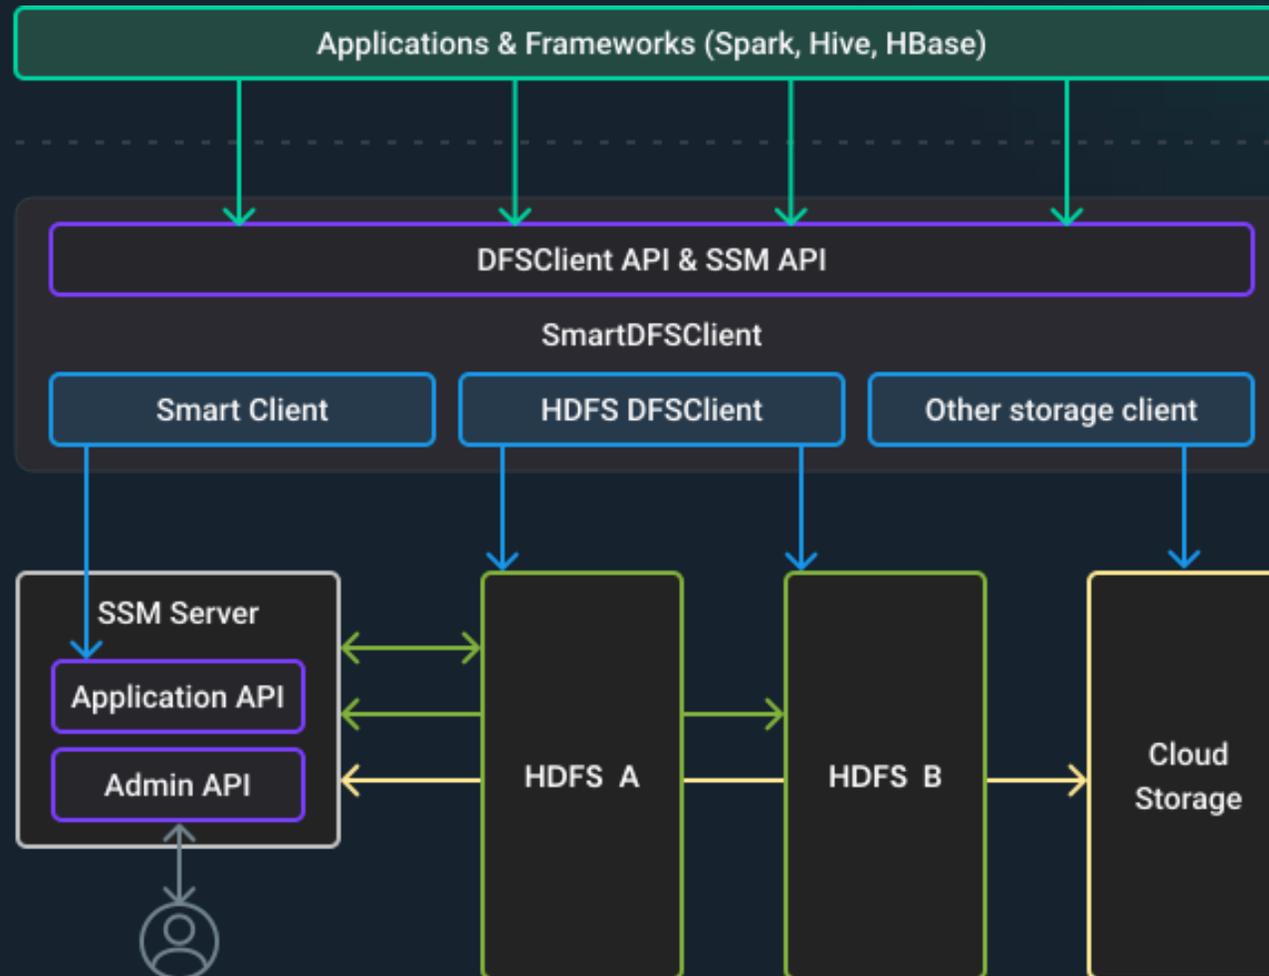


Повышение
производительности

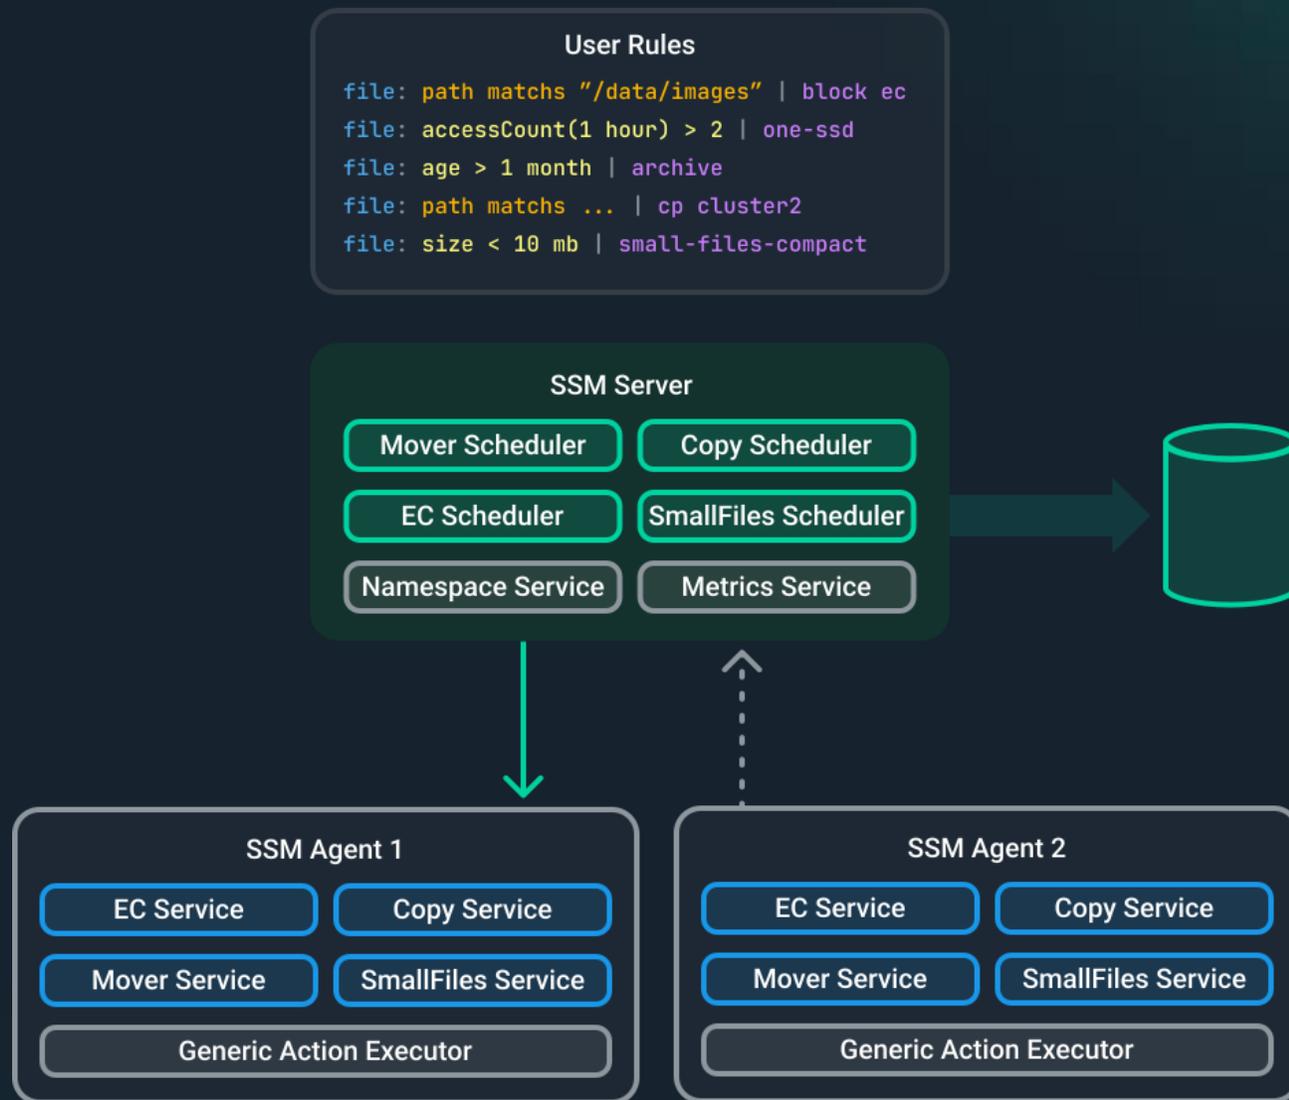


Надёжность

Архитектура Smart Storage Manager



Взаимодействие компонентов Smart Storage Manager



Кyuubi: SQL gateway для Data Lake и Lakehouse



Кyuubi — распределённый многопользовательский шлюз для предоставления SQL для Data Lake и Lakehouse.

Кyuubi создает распределённые механизмы SQL-запросов поверх различных вычислительных платформ, например, Apache Spark, Flink, Hive, Impala и др., чтобы получать и обрабатывать большие наборы данных из разнородных источников.

Основные возможности



Многопользовательский доступ

Сквозная поддержка доступа нескольких пользователей к данным через единую систему аутентификации и авторизации



Высокая доступность (HA)

Балансировка нагрузки через ZooKeeper обеспечивает высокую доступность Enterprise-уровня и неограниченно высокий уровень параллелизма клиентов



Несколько рабочих нагрузок

Поддержка разнородных рабочих нагрузок в рамках одной платформы, одной копии данных и одного интерфейса SQL

Сферы применения Кууби



Интерактивная аналитика

- Быстрая аналитика для интерактивного анализа больших данных
- Распределённые механизмы SQL-запросов поверх различных вычислительных платформ (Spark, Flink, Impala и др.)
- Доступ через JDBC/ODBC
- Возможность генерации запросов через SQL или инструменты BI
- Совместное использование ресурсов и быстрый отклик за счёт распараллеливания запросов



Пакетная обработка

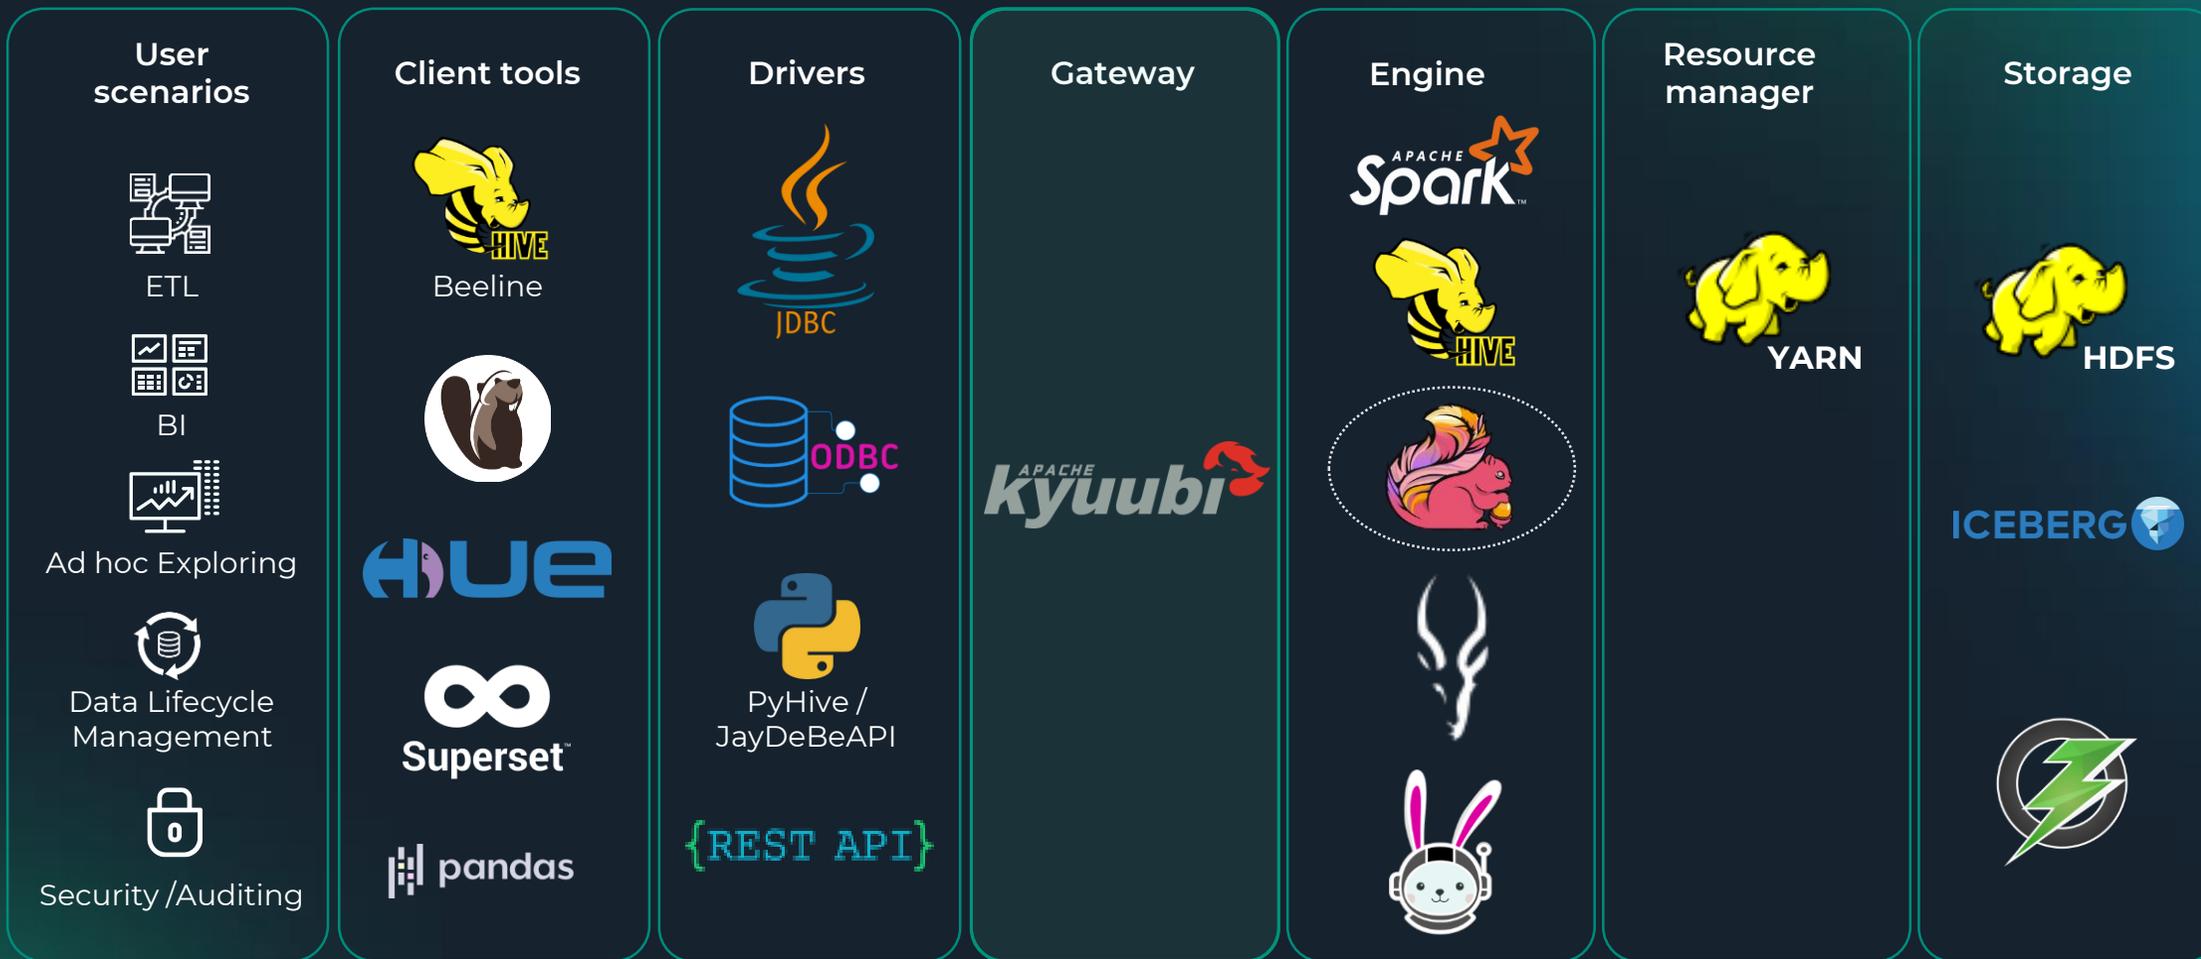
- Кууби предоставляет интерфейс SQL, удобный для пакетной обработки ETL
- Кууби и его движки работают с многочисленными источниками данных независимо от хранилища
- Изоляция вычислительных ресурсов



Data Lake & Lakehouse

- Возможность выполнения запросов к традиционным хранилищам (Hive/HDFS) и современным озёрам данных
- Централизованная картина данных
- Возможность запрашивать разнородные источники данных
- Аутентификация и авторизация (поддержка Kerberos)

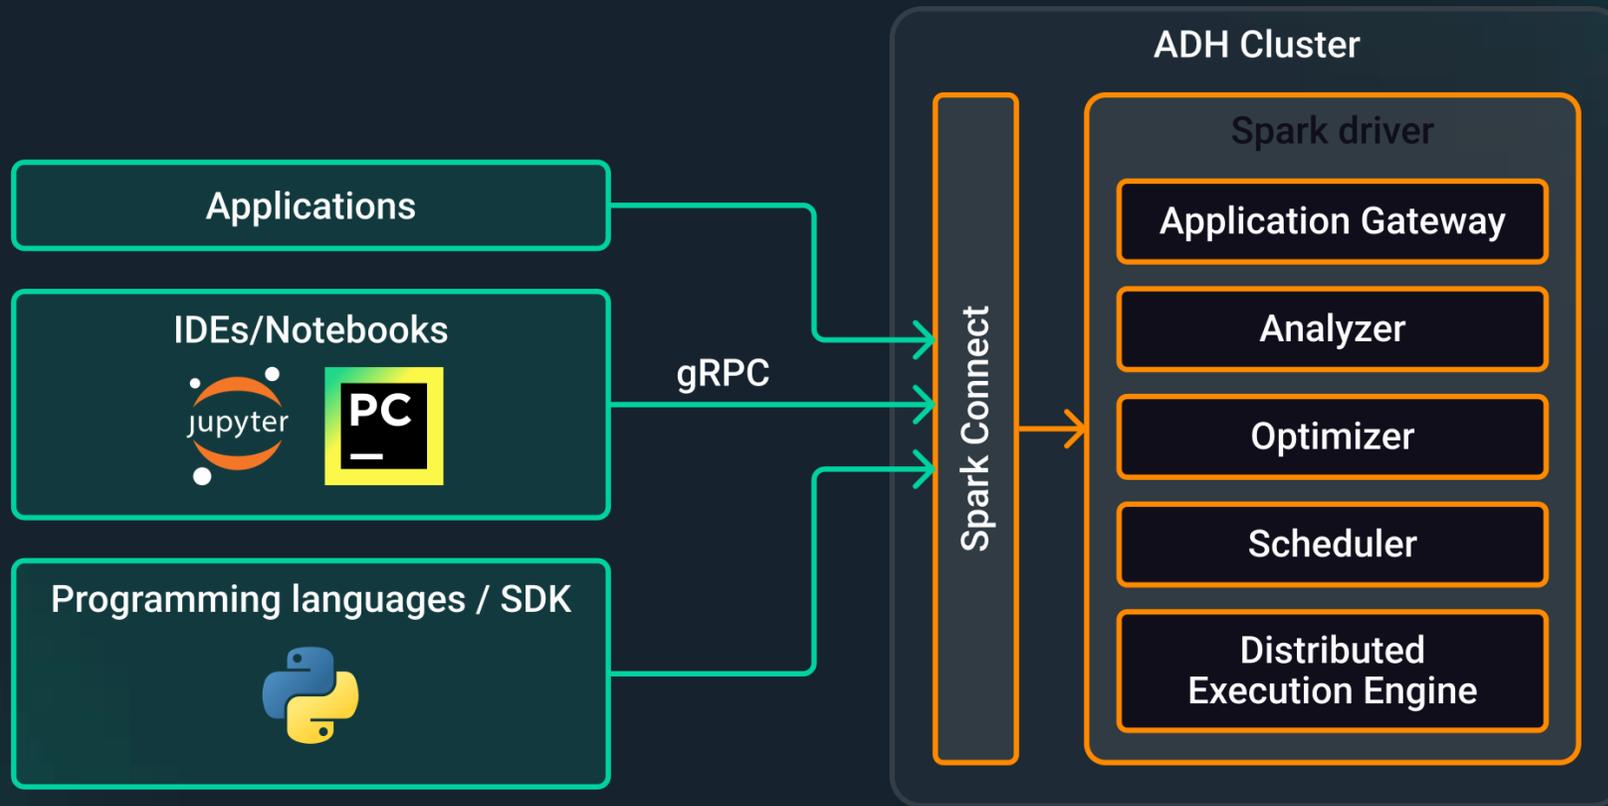
Кууби: место в платформе данных



В разработке

Spark Connect: удалённое управление кластером Spark

Spark Connect — компонент сервиса Spark3, который, выполняя функции тонкого клиента, обеспечивает удалённое подключение к кластерам Spark. С помощью Spark Connect можно удалённо управлять кластером Spark, например, используя привычную IDE на обычном пользовательском ноутбуке



Верхнеуровневая архитектура Spark Connect

HUE: веб-интерфейс для анализа данных



HUE (Hadoop User Experience) позволяет пользователям запрашивать, находить и анализировать имеющиеся данные без потери контекста. В дистрибутиве ADH он содержит предустановленные интерпретаторы SQL для Impala, Hive, Kyuubi и Spark SQL.

Для кого: бизнес-аналитики, дата-инженеры и дата-сайентисты, администраторы баз данных, SQL-разработчики

Основные преимущества



Низкий порог входа

Интеллектуальные компоненты автозаполнения и редактор SQL-запросов упрощает работу с источниками данных



Универсальность

HUE подключается практически к любой СУБД или хранилищу данных через нативные коннекторы Thrift или SQLAlchemy, которые необходимо добавить в ini-файл



Функциональность

Файловый браузер для создания, копирования, перемещения файлов и директорий внутри HDFS, автоматизированный scheduler и платформа для разработки

Интерфейс HUE

The screenshot shows the HUE interface with a query editor on the left and a table of results on the right. The query is:

```

15 WHERE a.key = 'shipping' and a.zip_code = '76710';
16
17
18
19 -- Compute total amount per order for all customers
20 SELECT
21   c.id AS customer_id,
22   c.name AS customer_name,
23   o.order_id,
24   v.total
25 FROM
26   customers c,
27   c.orders o,
28   (SELECT SUM(price * qty) total FROM o.items) v;
    
```

The table of results (106 rows) is as follows:

| | customer_id | customer_name | order_id | total |
|----|-------------|--------------------|----------|-------|
| 1 | 75012 | Dorothy Wilk | 4056711 | 918 |
| 2 | 75012 | Dorothy Wilk | J882C2 | 96 |
| 3 | 17254 | Martin Johnson | I72T39 | 18 |
| 4 | 12532 | Melvin Garcia | PB6268 | 68 |
| 5 | 12532 | Melvin Garcia | B8623C | 2507 |
| 6 | 12532 | Melvin Garcia | R9S838 | 1278 |
| 7 | 42632 | Raymond S. Vestal | HS3124 | 1944 |
| 8 | 42632 | Raymond S. Vestal | BSS902 | 2798 |
| 9 | 77913 | Betty J. Giambrone | DN8815 | 1320 |
| 10 | 77913 | Betty J. Giambrone | XR2771 | 4315 |

The screenshot shows the HUE interface with a query editor on the left and a bar chart visualization on the right. The query is:

```

1 select startstation,
2 count(*) as trips
3 from '201402_trip_data'
4 group by startstation,
5 endstation
6 order by trips desc
7 ;
8
    
```

The bar chart shows the number of trips for different startstations. The Y-axis is labeled 'trips' and ranges from 0 to 1.33k. The X-axis lists the startstations. The bars are colored as follows: Harry Bridges Plaza ... (blue, ~1.33k), Townsend at 7th (green, ~1.2k), San Francisco Caltr... (grey, ~1.1k), Market at Sansome (pink, ~0.8k), and Embarcadero at San... (teal, ~0.8k).

Iceberg: открытый формат таблиц для больших хранилищ данных



Apache Iceberg позволяет работать с файлами в data lake как со структурированными таблицами через SQL-запросы.

Обеспечивает ACID-транзакции, перемещение во времени (time travel), изменение схемы (schema evolution), изменение партиции (partition evolution) и другие возможности работы с данными.

Основные преимущества



Совместимость

Работает поверх ORC, Avro или Parquet и легко интегрируется с популярными движками Spark, Impala, Hive и др. Работает с любым облачным хранилищем и снижает нагрузку в HDFS.



Масштабируемость

Предназначен для огромных таблиц с десятками петабайт данных. Позволяет обрабатывать большие объёмы данных без потери производительности.



Целостность

Благодаря атомарности, консистентности и изолированности транзакций, операции в data lake, включая параллельную запись, не приведут к ошибкам или повреждению данных.

Основные возможности таблиц Iceberg

Выражения SQL

Iceberg поддерживает множество SQL-операций, которые позволяют выполнять такие задачи, как обновление строк, объединение данных, целевые удаления и др.

Изменение схемы таблицы

Изменение схемы таблиц влияет только на метаданные, а не на файлы данных. Это позволяет быстро добавлять, удалять, обновлять, реорганизовывать и переименовывать столбцы.

Изменение партиции

В отличие от стандартного партиционирования, таблицы Iceberg позволяют изменять схему партиционирования данных без перезаписи всех данных.

Снепшоты

Снепшоты позволяют сохранить состояние таблицы в конкретный момент. Iceberg ведет лог созданных снепшотов, что позволяет выполнять запросы time travel.

Перемещение во времени и откат изменений

Функция «перемещения во времени» позволяет выполнять запросы к более ранним версиям таблиц. Функция отката изменений позволяет пользователям восстанавливать состояние таблицы в определенный момент времени.

Транзакционная согласованность

Iceberg поддерживает ACID-транзакции, что обеспечивает безопасные параллельные записи в кластере и предотвращает влияние операций записи на операции чтения. Когда происходят изменения, Iceberg генерирует новую, неизменяемую версию файлов данных и метаданных таблицы.

Быстрое выполнение запросов

Iceberg повышает скорость выполнения запросов за счёт возможности организации инкрементальной обработки данных, быстрого планирования сканирования и фильтрации неактуальных данных.

Ozone*: новое поколение хранилища для платформы больших данных

Масштабируемое распределённое объектное хранилище



Масштабируемость

Предназначен для работы с миллиардами небольших файлов (в отличие от файловой системы HDFS, ориентированной на хранение файлов большего размера)



Высокая доступность

Отказоустойчивость и быстрое восстановление работы системы после сбоя без потери данных



Поддержка нескольких протоколов

Поддерживает работу как со стандартным HDFS-протоколом, так и S3 API



Лучшие гарантии консистентности

Достигается путём использования консенсус-протоколов, включая RAFT



Безопасность

Поддержка Kerberos, Transparent Data Encryption и Ranger для управления безопасностью платформы

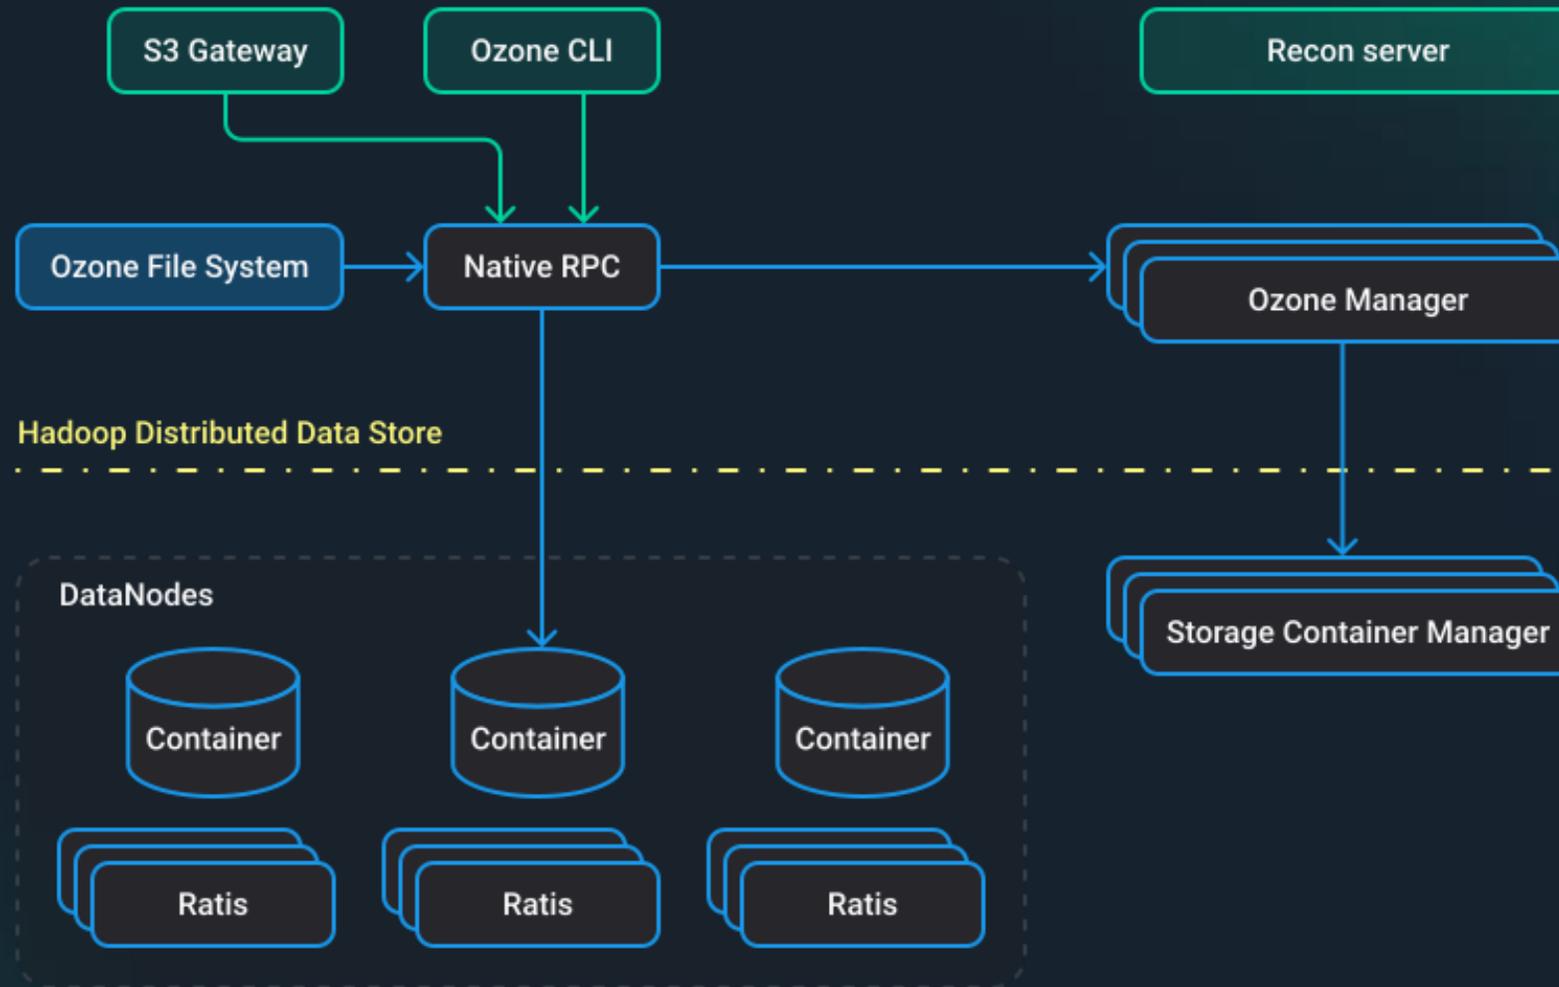


Совместное развёртывание

Может работать вместе с HDFS на одних и тех же хостах

* Поставляется в составе enterprise-редакции ADH

Архитектура Ozone



Сравнение ключевых возможностей HDFS и Ozone

| | HDFS | Ozone |
|--|---|---|
| Модель данных | Файловое хранилище с иерархической структурой | Хранилище объектов, работает с неструктурированными данными и оптимизировано для облака |
| Репликация данных | Репликация данных между узлами DataNode для предоставления отказоустойчивости | Программно определяемое хранилище, позволяет настраивать политики репликации и обеспечивать избыточность данных |
| Масштабируемость | Хорошая масштабируемость для больших задач по обработке данных | Разработан с целью предоставить ещё более хорошую масштабируемость, чем в HDFS |
| Управление пространством имён | Единое пространство имён для всего кластера | Несколько пространств имён для различных задач |
| Хранилище объектов | нет | да |
| Поддержка S3 и других протоколов хранилищ объектов | нет | да |
| Управление доступом | Права в стиле POSIX | Права в стиле S3 и управление доступом на уровне бакета |
| Аутентификация и авторизация | Kerberos | Kerberos, Ozone Token |
| Согласованность данных | Согласованность рано или поздно достигается | Высокая согласованность за счёт таких протоколов, как RAFT |

Области применения HDFS и Ozone

HDFS

Рабочие нагрузки с меньшими требованиями к хранению небольших объектов без возможности их объединения

Файловая система по умолчанию со следующими преимуществами:

- поддержка хранения большого количества данных
- быстрое определение и реагирование на аппаратные сбои
- поддержка потоковой передачи данных
- упрощённая модель согласованности
- высокая отказоустойчивость и лёгкость восстановления
- предназначена для коммерческого оборудования

Ozone

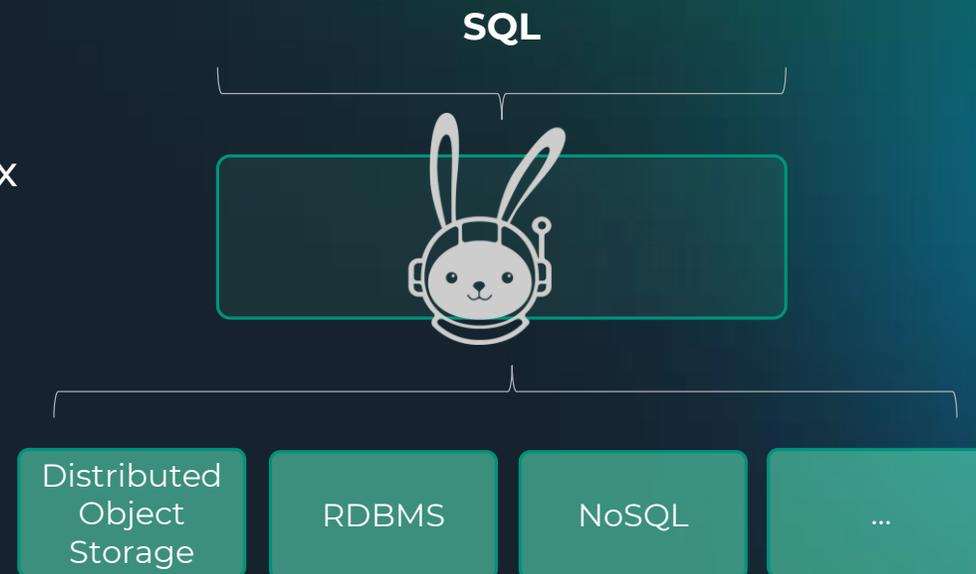
Среды, где требуется масштабируемость для небольших файлов и совместимость с S3

Новое поколение хранилища для платформы больших данных:

- высокая согласованность данных
- разработано для хранения более 100 миллиардов объектов в одном кластере
- отличная масштабируемость благодаря многоуровневой архитектуре
- столь же высокая отказоустойчивость и лёгкость восстановления, как у HDFS
- может работать вместе с HDFS на одних и тех же хостах

Trino: единая точка доступа для запросов к хранилищам и озёрам данных

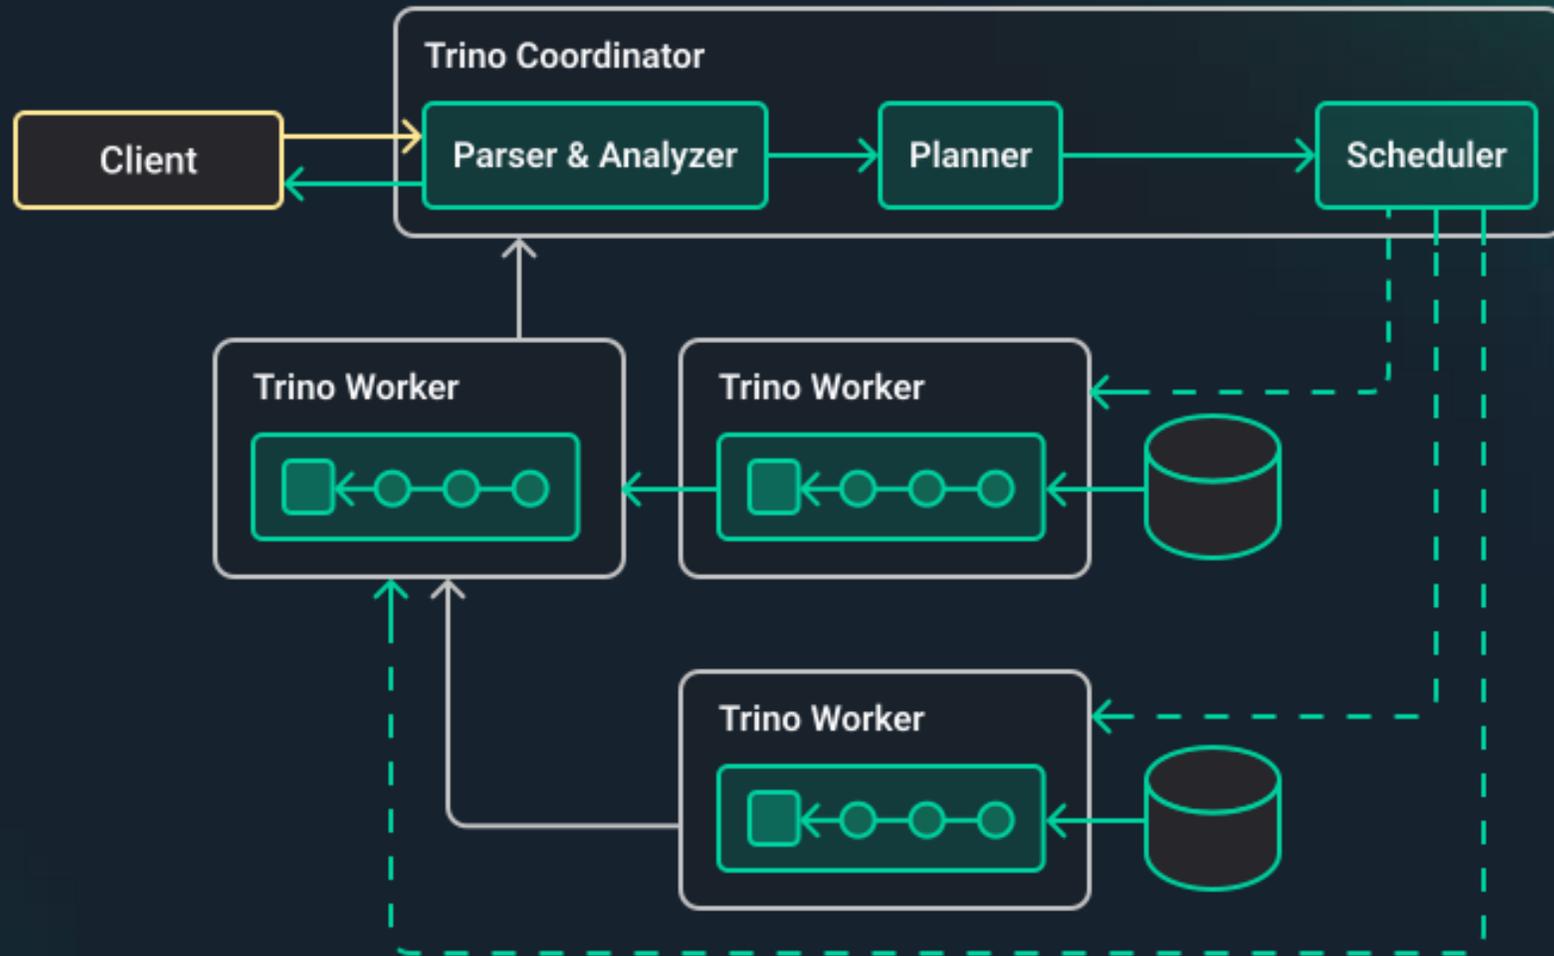
Trino — инструмент для обработки огромных объёмов данных с использованием распределённых федеративных запросов. Позволяет запрашивать разрозненные источники данных в одной системе с помощью одного и того же SQL — объектные хранилища, базы данных, файловые системы — в одном запросе



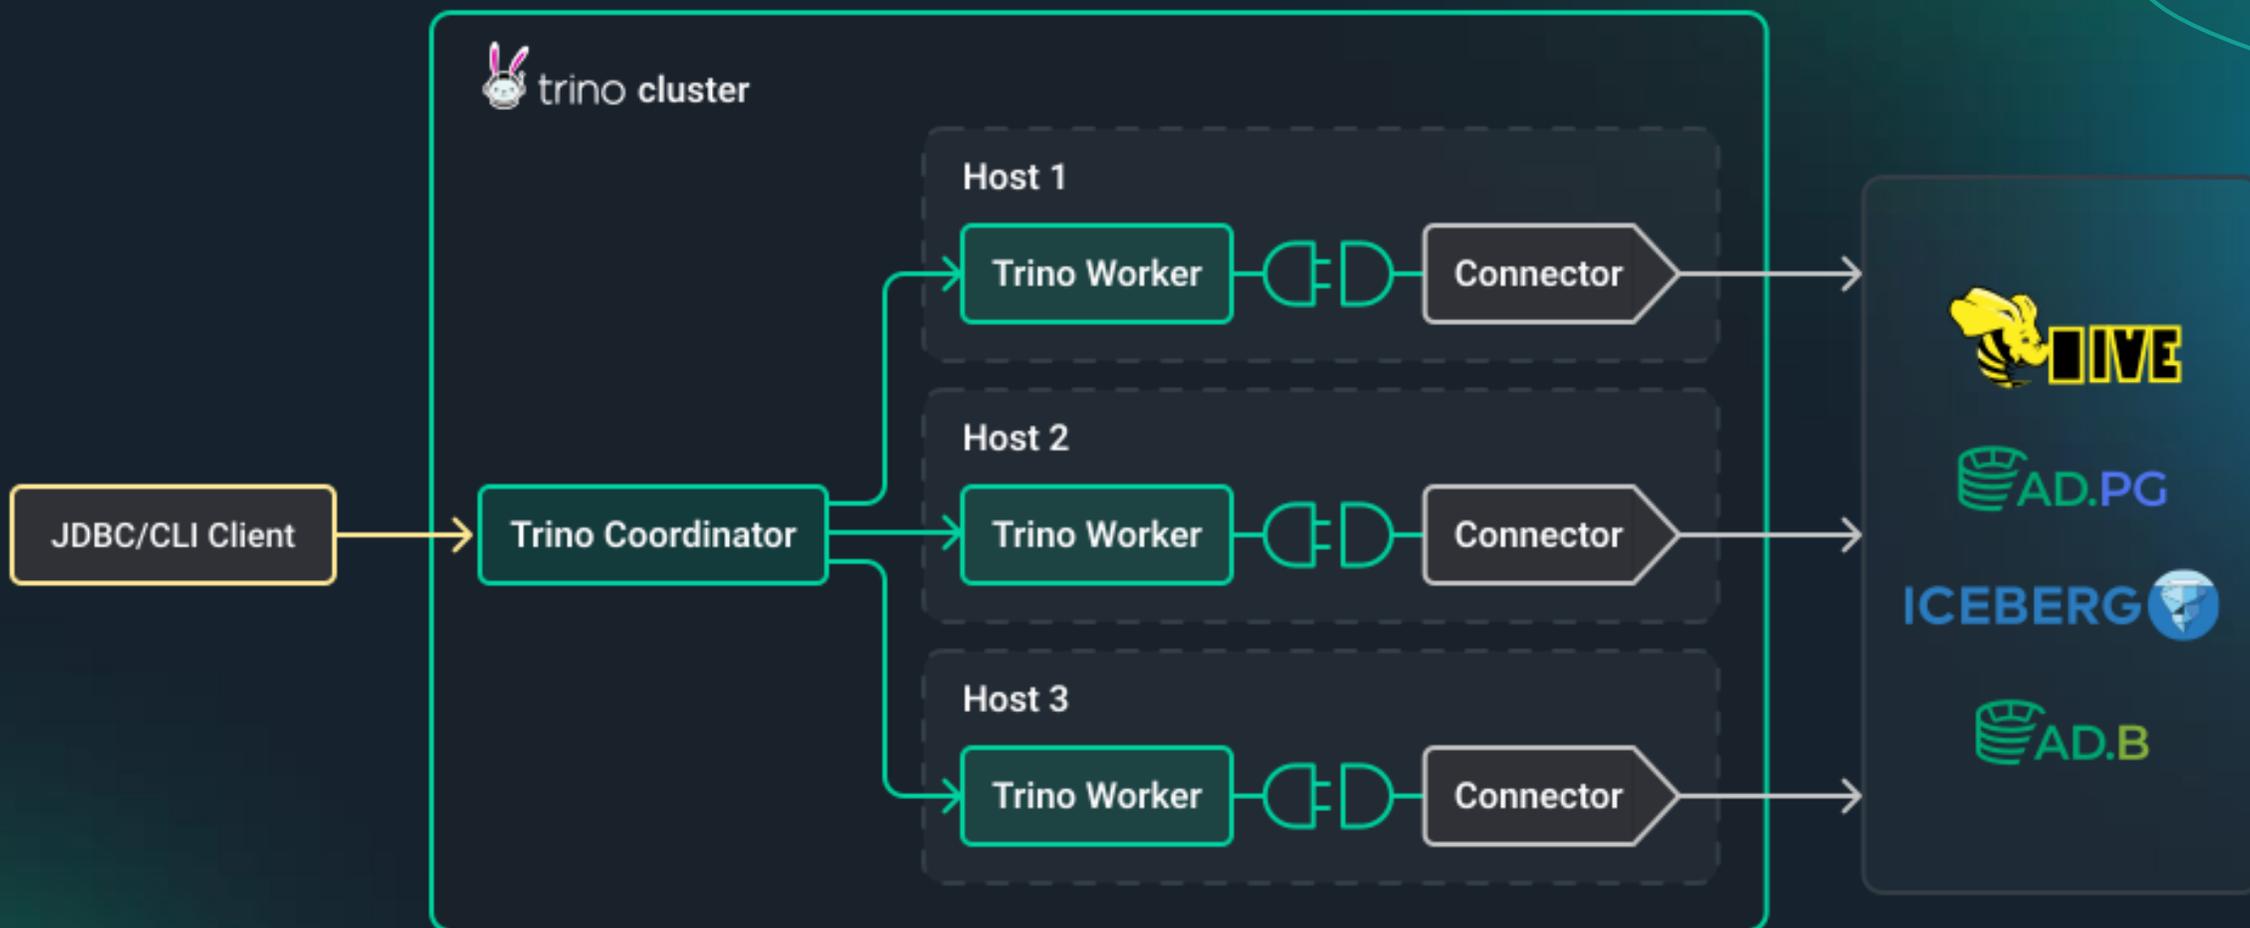
Основные преимущества

- перенос аналитической нагрузки из дорогих в обслуживании и трудно масштабируемых КХД в озёра данных
- уменьшение дублирования данных
- новые сценарии анализа данных при сокращении расходов на инфраструктуру

Архитектура Trino



Коннекторы в Trino



Trino UI

Clusters 18 Dec 2024 09:54:12 UTC

Clusters / adh trino / Services / Trino / Info

adh trino Overview **Services** Hosts Mapping Configuration Import

Trino 466_arenadata1 2 / 2 successful components Actions Delete

Primary configuration Configuration groups Action host groups Components **Info**

Documentation: <https://trino.io/docs/461/index.html>

Web links

Trino Coordinator @ av-adh-backup-1.ru-central1.internal:

- Web interface: <http://av-adh-backup-1.ru-central1.internal:18188>

Панель мониторинга Trino

CLUSTER OVERVIEW VERSION: 3.3.6_ARENADATA1-126-G07BA16E-DIRTY ENVIRONMENT: ADH UPTIME: 4.09h Log Out

| | | |
|-----------------------------|------------------------------------|-----------------------------------|
| RUNNING QUERIES 1 | ACTIVE WORKERS 2 | ROWS/SEC 3.26M |
| QUEUED QUERIES 0 | RUNNABLE DRIVERS 2.73 | BYTES/SEC 30.5M |
| BLOCKED QUERIES 0 | RESERVED MEMORY (B) 279M | WORKER PARALLELISM 0.64 |

QUERY DETAILS

User, source, query ID, query state, resource group, error name, or query text

State: Running Queued Finished Failed Sort Reorder Interval Show

20241218_182800_00003_4n4ht 9:28pm **RUNNING (53%)**

admin
DBeaver 24.0.5 - SQLEditor <Script...>
non-spoiled
global

155 5 56
3.14s 3.17s 8.21s
356MB 1.83GB 1.47G

```
SELECT
t1.client_mdm_id,
t1.customer_contract_sk,
t1.customer_contract_num,
SUM(t1.coverage_amount_rub * t2.coverage_amount_rub) AS total_coverage_amount_rub,
SUM(t1.coverage_amount_curr * t2.coverage_amount_curr) AS total_coverage_amount_curr,
...
```

Ссылка на веб-интерфейс Trino в веб-интерфейсе ADCM

Arenadata Hyperwave vs «Ваниль»

Преимущества Arenadata Hyperwave
в сравнении с Open Source



Преимущества Arenadata Hyperwave в сравнении с Open Source



Качественная сборка совместимых компонентов

Дистрибутив ADH включает последние стабильные версии компонентов экосистемы Hadoop и ряд других OSS инструментов и проприетарных решений. Самостоятельная сборка сопоставимой по функциональности платформы требует существенных вложений в RnD, либо будет выполнена без оглядки на совместимость, что скажется на стоимости эксплуатации и повлечёт за собой простои.



Универсальный оркестратор гибридного ландшафта

Предоставляем Arenadata Cluster Manager, универсальный инструмент для установки, настройки и обновления всех продуктов Arenadata на любой инфраструктуре с удобным и современным графическим интерфейсом.



Дополнительные возможности Enterprise версии

Высокопроизводительные коннекторы позволяют интегрировать Arenadata Hyperwave с другими продуктами Arenadata и с внешними системами.



Техническая поддержка от вендора с SLA, подтверждённым контрактом

Гарантии на поддержку платформы от вендора, включая штрафы, указанные в договоре, в сравнении с мотивацией команды собственных экспертов.



Безопасность

Единая, интегрированная во все компоненты платформы, система безопасности Arenadata Platform Security на базе Kerberos, Ranger и Knox — в сравнении с частным решением, которое нужно постоянно дорабатывать и обновлять.

Преимущества Arenadata Hyperwave в сравнении с Open Source



Набор типовых пакетных сервисов по планированию, установке и аудиту системы

Вам не придётся самостоятельно проводить оценку оборудования для решения поставленной задачи. Наши специалисты настроят Arenadata Hyperwave (удалённо или on-site), проведут аудит системы и помогут определить дальнейшие шаги.



Пакет утилит для полной офлайн-установки

Arenadata Hyperwave включает набор инструментов для автоматической установки и настройки компонентов, как на «чистом железе», так и в облаке. Средства мониторинга и управления конфигурацией кластера позволяют оптимизировать производительность для всех компонентов системы.



Российское ПО

Продукт внесён в реестр сертифицированных средств защиты информации ФСТЭК России (по 4 УД) и в реестр отечественного ПО.



Документация

Оригинальная документация на русском и английском языках поможет облегчить процесс планирования, установки и настройки кластера.

Коннекторы в платформе

ADB Spark Connector

Обмен данными между Apache Spark и Arenadata DB

Интеграционное решение обеспечивает высокоскоростной параллельный обмен данными между Spark3 и DWH на базе Arenadata DB (ADB)

ADQM Spark Connector

Обмен данными между Apache Spark и Arenadata QuickMarts

Многофункциональный коннектор с поддержкой параллельных операций чтения/записи между Spark3 и Arenadata QuickMarts (ADQM)

Возможности:

- высокая скорость передачи данных
- автоматическое формирование схемы данных
- гибкое партиционирование
- поддержка push-down операторов
- поддержка batch-операций

Arenadata EDP



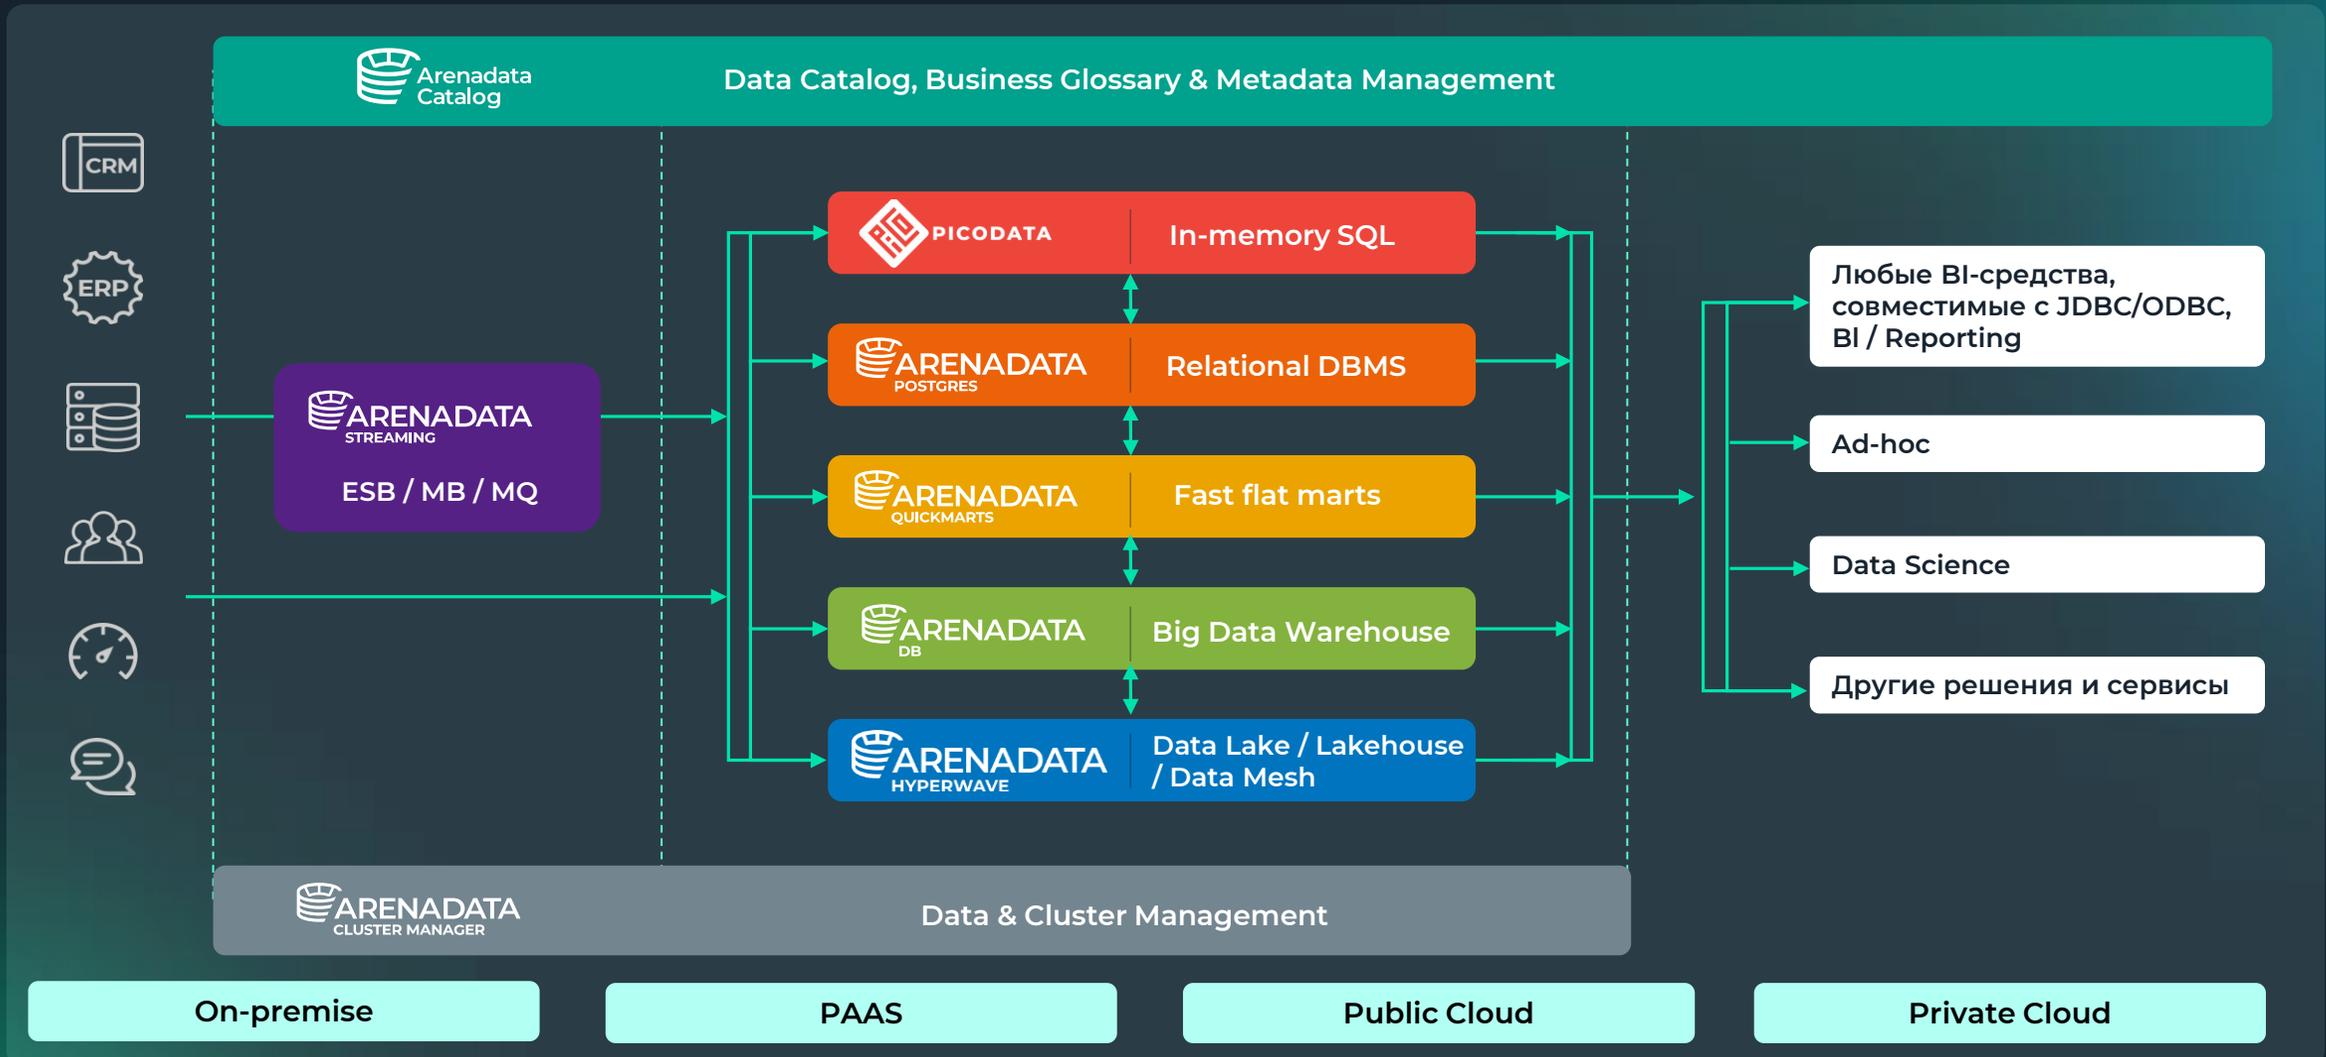
Arenadata Enterprise Data Platform

Источники

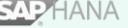
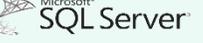
Транспорт

Хранение и представление данных

Использование и визуализация



Миграция с иностранных решений

| | | |
|--|---|--|
| Управление данными и качество данных |  Informatica  alteryx  Alation  Collibra  ATAKAMA  IBM |  ADC CLEAN DATA |
| Базы данных в памяти (резидентные СУБД) |  GridGain  redis  HAZELCAST |  PICODATA |
| Аналитические СУБД в режиме реального времени (аналитические СУБД) |  Microsoft SQL Server |  AD.QM |
| Хранилища данных (аналитические СУБД) |  VERTICA  Pivotal Greenplum  teradata  SAP HANA  ORACLE EXADATA |  AD.B |
| Озёра данных, lakehouse, data mesh |  CLUSTERA  ORACLE BIG DATA APPLIANCE |  AD.H |
| Потоковая передача (загрузка) данных |  kafka  APACHE nifi |  AD.S |
| Транзакционные базы данных (СУБД общего назначения) |  ORACLE DATABASE  IBM DB2  Microsoft SQL Server |  AD.PG |

Единая платформа, объединяющая востребованные продукты мирового уровня и позволяющая эффективно замещать целый комплекс решений ушедших зарубежных компаний

Каждый добавляемый компонент платформы доработан, чтобы стать её частью

| | |
|---|--|
|  AD.B Big Data Warehouse |  |
|  AD.H Data Lake / Lakehouse / Data Mesh |     |
|  AD.QM Fast flat marts |  |
|  AD.PG Relational DBMS |  |
|  PICODATA In-memory SQL | Tarantool |
|  AD.S ESB/MB/MQ |   |
|  AD.CM Data & Cluster Management |  |
|  ADC Data Catalog |  |



Обязательный перечень задач для каждого компонента:

Выполнить статистический анализ кода

Выполнить интеграцию с модулем мониторинга

Проверить работоспособность заявленного функционала

Подобрать персонал поддержки, подготовить и обучить архитекторов и разработчиков

Разработать коннекторы для взаимодействия с другими компонентами платформы

Сформировать дорожную карту доработок продукта

Мы осуществляем безопасную разработку



Используем инструменты и методики:

- ✓ Статические анализаторы исходного кода
- ✓ Поиск секретов в исходном коде
- ✓ Безопасность в образах контейнеров
- ✓ Анализатор зависимых компонентов
- ✓ Средства динамического анализа



Разработка в соответствии с ГОСТ Р 56939-2016 «Разработка безопасного программного обеспечения»



Применяются международные практики OWASP Application Security Verification Standard



Разработаны и внедрены правила для каждого языка программирования

Enterprise Multi-cloud платформа данных

Виды развёртки любых компонентов платформы Arenadata EDP:

01

в облаке

02

на bare-metal-оборудовании

03

гибридная ИТ-инфраструктура
или multi-clouds



Многоуровневая система технической поддержки

Варианты технической поддержки

24/7

доступность поддержки

600+

кластеров на поддержке

400+

заявок в месяц

99%+

соблюдение SLA в 2024

50+

технических экспертов

Гарантийное
обслуживание

Режим работы
над обращениями 8x5

Анализ проблем
в рамках поступивших
инцидентов

Предоставление
обновлений ПО

Доступ к базе знаний
по решению
инцидентов

Базовая
техническая
поддержка

Режим работы
над обращениями 24x7
для Prod

Диагностика
и предоставление
обходного решения

Предоставление
обновлений ПО

Консультации
по особенностям ПО

Анализ проблем
в рамках поступивших
инцидентов

Решение инцидентов
в рамках SLA

Доступ к базе знаний
по решению
инцидентов

Премиальная
техническая
поддержка

Услуги, включающие сервисы Базовой технической поддержки и учитывающие индивидуальные потребности Заказчика

Вендорский консалтинг Arenadata

Минимизация рисков, максимизация отдачи от инвестиций, оперативное устранение проблем

Технический аудит

Комплексный аудит для анализа узких мест кластера. Детальный разбор и рекомендации по изменениям от архитекторов Arenadata позволяют сформировать среднесрочную стратегию эксплуатации



Производительность

Комплекс тактических услуг по оптимизации использования ресурсов, настроек ресурсных групп, настроек резервного копирования, адаптации сайзинга к изменяющейся нагрузке и оптимизации прикладных запросов



Технический аккаунт-менеджмент

ТАМ-команда, состоящая из архитектора-эксперта, руководителя проектов, аналитиков и инженеров. Постоянная команда идёт с заказчиком рука об руку и использует свой опыт для значительного снижения проектных и технических рисков, возникающих в ходе внедрения и эксплуатации сложных систем



Программа приоритетного внимания

Наблюдения истории развития ландшафтов данных наших клиентов позволили выстроить эталонный сервисный путь ландшафта данных для крупных заказчиков с учётом характера и интенсивности потребления услуг



Надёжный старт

Комплекс услуг по развёртыванию ПО Arenadata



Удобная и понятная онлайн-документация мирового уровня



Не копируем, а создаём



Обеспечиваем поддержку разных устройств



Сами разрабатываем примеры



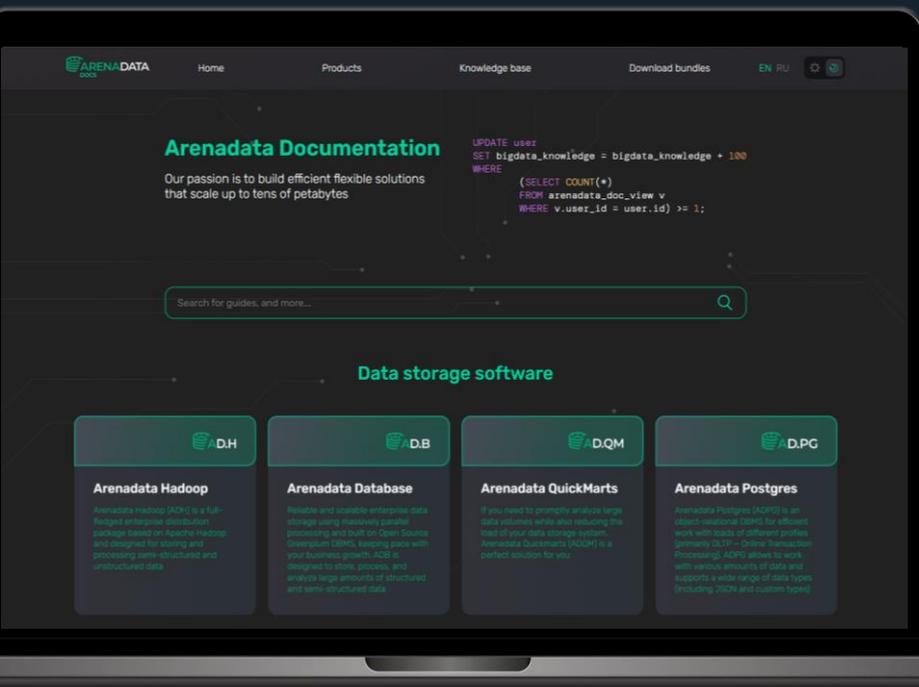
Проводим экспертную проверку архитекторами и аналитиками



Разрабатываем дизайн архитектурных диаграмм



Не переводим, а пишем на русском и английском языках



[Перейти на сайт с документацией](#)

ЗНАНИЯ ИЗ ПЕРВЫХ РУК:

С сертификацией и присвоением статуса
Arenadata Certified Specialist



Знания из первых рук

Преподаватели — практикующие специалисты, имеющие за плечами богатую экспертизу и значительное количество реализованных бизнес-кейсов

[Узнать подробнее о курсах](#)



Практика от экспертов

Все курсы построены на реальных кейсах и практических примерах, а лабораторные работы проходят на стендах, симулирующих рабочую среду



16 учебных программ по 8 направлениям

- Архитектура платформы данных
- Курсы по Arenadata DB
- Курсы по Arenadata Hyperwave
- Курсы по Arenadata QuickMarts
- Курсы по Arenadata Streaming
- Курсы по Arenadata Postgres
- Курсы по Picodata
- Курсы по Arenadata Catalog

ОСТАВАЙТЕСЬ НА СВЯЗИ



Наши новости
в телеграм-канале

