


# Гибридная платформа данных ANG Platform

Большие данные - большие возможности

2025


# Эволюция цифровизации: путь от интуиции к аналитике



# Data Driven: как данные меняют правила игры в бизнесе

## Эффективное управление

- Стратегические решения на основе данных, а не интуиции.
- Оперативная корректировка действий в реальном времени.



## Оптимизация бизнеса



- Улучшение и автоматизация бизнес-процессов на основе аналитики.
- Создание цифрового двойника своего бизнеса

## Скорость и точность

- Сокращение времени на принятие решений.
- Прогнозные модели для предсказания трендов и рисков.



## Корпоративная культура



- Формирование единого подхода к управлению.
- Развитие Data Driven-мышления на всех уровнях компании.

# Процессы DATA Driven

2

## Обработка данных

Превращение «сырых» данных в полезную информацию: анализ для нахождения закономерностей, визуализация для ясности и принятие решений.



1

## Сбор данных

Получение данных из различных источников: анализ на качество и полноту, визуализация для первичной оценки и принятие решений по оптимизации сбора.



5

## Принятие решений

Использование результатов анализа и визуализации для формирования стратегий и действий.

3

## Анализ данных


Исследование и интерпретация данных для выявления закономерностей, трендов и полезной информации.



4

## Визуализация данных

Представление данных в графическом виде (диаграммы, дашборды) для упрощения восприятия и анализа.





# Отрасли применения Big DATA

**E-Commerce**

**Страхование**

**Телекоммуникации**

**Производство**

**Госсектор**

**Банки и Финансы**

**Медицина**

**Логистика**

# Современные архитектурные парадигмы

## Место платформы Argument



### DATA WAREHOUSE и MPP СУБД

- Высокое ТСО
- Отсутствие потоковой обработки
- Нужен Data Lake для кейсов снижения ТСО, ML-кейсов, не табличных данных
- Дорого масштабируется (compute и storage вместе)
- Деградация производительности (> 500Тб, > 200 польз.) -> добавь еще 1н кластер + репликацию



### DATA LAKE Экосистема Hadoop

- Низкое ТСО
- НЕ поддерживаются транзакции out-of-the-box и НЕ обеспечивается консистентность данных
- Плохо масштабируется (compute и storage вместе)
- Сложность обслуживания – много компонентов
- Производительность сильно зависит от сборки



### LAKEHOUSE Функционал MPP DWH с уровнем масштабирования облачного Data Lake

- Минимальное ТСО
- Пакетная и потоковая обработка
- Дешево масштабируется (compute и storage раздельно)
- Изоляция ресурсов и задач
- Гибридная архитектура (cloud, on-premise)



**ARGUMENT**

BIG DATA - BIG OPPORTUNITIES

# Почему традиционные подходы к данным больше не работают?

## Парадигма "Данные как продукт" (DaaP)

Дата-сеты как самостоятельные продукты, адаптированные под потребности пользователей.



Необходима революция  
в хранении и обработке данных

### Экономические проблемы

- Дорогое оборудование и высокооплачиваемые специалисты  
→ падает маржинальность.
- Множественные хранилища  
→ рост расходов на разные типы данных, интеграцию разнородных ИТ-систем, обслуживание данных разными командами для разных групп пользователей.

### Риски "перегруза" данными

- Потеря контроля: усложнение моделей, связей и качества.
- **Данные = риск**, если им нельзя доверять.

### Запрос на инновации

Цифровизация требует:

- Real-time аналитики
- AI/ML-решений.

**ПРОБЛЕМА:**  
текущие подходы  
экономически неэффективны.

# Cloud Native – новый стандарт корпоративных решений



## Kubernetes

- Централизованное управление контейнерами и оркестрация
- Гибкое распределение вычислительных ресурсов
- Автоматическое масштабирование приложений
- Балансировка нагрузки между узлами
- Автоматизация развертывания приложений
- Мониторинг состояния подов и узлов
- Обеспечение отказоустойчивости системы



## S3 (Storage)

- Унифицированное хранилище данных
- Масштабируемое хранение информации
- Надежный доступ к данным
- Оптимизация затрат на хранение

# Почему Argument? Ключевые преимущества платформы

## Единая платформа для работы с данными

Open Source решение для сбора, обработки и анализа данных.



Все, что нужно для работы с данными в одном решении

## Быстрый переход на Data Driven

- Готовые инструменты для внедрения управления на основе данных.
- Снижение времени на адаптацию и обучение.

## Масштабируемость под любые задачи

- Гибкость инфраструктуры – от стартапов до крупных предприятий.
- Инструменты для роста без ограничений.

## Безопасность корпоративного уровня

- Соответствие Enterprise Security стандартам.
- Защита данных на всех этапах.

## Полный контроль данных

- Оркестрация всех процессов: от хранения до аналитики.
- Интеграция с существующими ИТ-системами.

## All-in-one: простота и эффективность

- Минимизация ручных усилий за счет автоматизации.
- Согласованная работа всех модулей.

# Преимущества решения



## Стоимость владения (TCO)

- Низкая стоимость хранения данных (дешевле, чем HDFS)
- Быстрые вычислительные движки (быстрее, чем Greenplum)
- Гибридная архитектура (PROD on-premise, DEV/TEST/QA on- cloud)
- Нужна одна команда для администрирования всей платформы



## Оперативность данных & Time to Market

- Динамическое управление кластерами в зависимости от профиля нагрузки
- Высокая доступность данных из единого защищенного хранилища для любых инструментов системы.



## Унификация платформы

- Объединение принципов подходов Lakehouse и Data Mesh
- Одна среда для всех задач Data Engineer и Data Science



## Открытые форматы данных / API

- Apache Iceberg – как основной формат организации данных
- Гибкая совместимость с компонентами современной ИТ экосистемы от стриминга/CDC до BI
- Простота миграции данных - как между инструментами/БД, так и в облако

# Функциональные возможности ANG



Поддержка гибридной архитектуры (public / private cloud, on-premise) и модели multitenancy – виртуальные compute кластера над одними и теми же данными



Оркестрация и управление ресурсами средствами Kubernetes



Возможность пакетной и потоковой обработки данных



Поддержка открытого формата хранения табличных данных Iceberg



Разделение ресурсов для хранения данных и вычислительной среды



Единое хранилище данных для всех инструментов с единой ролевой моделью доступа



В основе Open Source вычислительные движки Apache Impala, Apache Spark, Trino



Соответствует требованиям информационной безопасности

# **Argument: единая платформа для преобразования данных в бизнес-ценность**

## **1 Единый источник истины**

Извлечение и преобразование данных из любых источников с подготовкой к аналитике.

## **2 Централизованное управление данными**

Аккумуляция, хранение и готовность данных для глубокого анализа.

## **3 Автоматизация рабочих процессов**

Сокращение времени выполнения задач за счет интеграции и автоматизации.

## **4**

## **Безопасность на уровне Enterprise**

Защита конфиденциальных данных с помощью шифрования и строгой аутентификации.

## **5**

## **Интеллектуальная аналитика**

Аналитика позволяет лучше понимать рынок, выявлять тренды и прогнозировать будущие изменения.

## **6**

## **Конкурентное преимущество**

Адаптация к изменениям рынка и рост стоимости цифровых активов компании.

# Argument для IT-руководителя: ключевые преимущества

## RU Безопасность и соответствие

- Отечественная разработка (в реестре Российского ПО)
- Регулярные проверки на уязвимости
- Команда разработчиков в РФ



01

## Производительность

- Высокая скорость работы (современные технологии)
- Единая веб-консоль для управления всеми модулями



03

## Гибкость интеграций

- Подключение любых источников данных через API
- Миграция с других платформ (включая ушедшие с рынка)
- Работа в облаке или закрытом контуре



02

## Экономическая эффективность

- Оптимальная стоимость владения
- Гибкие лицензии (платите только за нужные инструменты)
- Бесшовное масштабирование функционала



04

## Поддержка

Квалифицированная техподдержка доступна 7 дней в неделю 24 часа в сутки




05

# ANG Platform



# ANG Platform базовая архитектура



# Характеристики платформы



**ARGUMENT**  
BIG DATA - BIG OPPORTUNITIES

Гибкое и эффективное распределение вычислительных мощностей над единым слоем данных

## Основные компоненты

- Data Lake
- Analytical DWH
- Lakehouse



Spark




## Преимущества

- Гибкое распределение вычислительных мощностей
- Поддержка JupyterHub и SQL web-ноутбуков

## Функции


- ETL-движок (витрины данных для моделирования/отчетности/приложений)
- SQL-движок для BI-инструментов и self-service анализа данных
- Ad-hoc анализ данных: SQL web-ноутбук Hue с широкими функциональными возможностями  
Использование "толстого" SQL-клиента через JDBC или ODBC
- JupyterHub



# Стратегия развития платформы ANG




## Road map



# Варианты установки

## Продукт



### Argument Next Gen

для компаний со средними и большими объемами данных до десятков петабайт, которые уже используют и развиваются Data Driven подход.

## Версии размещения



### Облачный доступ (Cloud)

Разместите сервер в облачном ЦОД для оптимизации затрат на инфраструктуру и доступа к данным из любой точки мира.



### Локальный доступ (On-Premise)

Установите ПО на свой собственный сервер и работайте абсолютно независимо, даже в закрытом контуре.

# ANG Platform – модули



## Argument Cluster Console

веб-интерфейс развертки, администрирования и конфигурирования компонентов системы



## Argument Object Storage

система хранения данных, включающая себя компоненты как для хранения данных в табличном формате, так и компоненты объектного хранения



## Argument Data Processing

контейнеризированная система обработки данных на основе систем распределенных вычислений Spark, Trino, Impala, покрывающая все известные подходы к обработке данных.



## Argument Client Tools

набор инструментов для пользовательского доступа к данным и их визуализации



## Argument Monitoring

система мониторинга состояния компонентов кластеров по огромному количеству метрик



## Argument Streaming

Пакет компонентов для обработки потока данных для аналитики в реальном времени и других сценариев обработки данных



## Argument Data Base

компонент, реализующий функции горячего слоя хранения на основе ClickHouse, Redis, OpenSearch



## Argument ML / AI Lab

компоненты для работы с моделями ML и LLM



## Argument Security Tools

набор инструментов для реализации аудита действий пользователей и разграничения доступа к данным

# Предпосылки использования S3 object storage и Kubernetes

## Проблемы традиционных решений

### HDFS

- Объединенные ресурсы для хранения данных и вычислительных мощностей
- Проблемы маленьких файлов и большого количества файлов (Namespace Федерации на практике не используются)
- Избыточный дисковый объем - фактор репликации 3 (ECC на практике не используется)
- Не поддерживается публичными облаками
- Ozone частично решает проблемы, но все еще в beta

### MPP

- Объединение ресурсов для хранения данных и вычислительных мощностей
- Проблемы одной узкой части/запроса -> проблемы всего кластера
- Движок ориентирован на full scan (индексы поддерживать «дорого») -> приводит к удорожанию дисковой подсистемы
- RAID-10 SSD/NVMe диски ZTD каждый
- Типовой MPP 6TB на узел vs. HDFS/S3 30-50TB на узел

### YARN

- Отсутствие возможности разделения ресурсов для разных профилей нагрузок
- Часть сервисов просто не может работать в YARN
- YuniKorn (эволюция YARN для контейниризации) ушел в сторону работы над k8s

## Преимущества S3 и Kubernetes

### S3 Object Storage


- Индустримальный стандарт, поддерживаемый большинством инструментов и движков
- Текущий мейнстрим
- S3 Select – фильтр данных на уровне хранилища
- Доступен в любом публичном облаке
- On-premise решение: Minio (выбор для аналитических задач, в отличие от CEPH, который ориентирован на универсальные облачные решения)

### Kubernetes

- Индустримальный стандарт для управления вычислительными ресурсами
- Подходит для любого облачного окружения
- Развитая экосистема с готовыми решениями (helm charts/CRD)
- Быстрое развертывание виртуальных кластеров (<5 минут)
- Масштабируемость и единые инфраструктурные сервисы
- On-premise решение: Отдельный кластер k8s для аналитики, поддержка нескольких кластеров, возможность использования "ванильного" Kubernetes или других дистрибутивов

# Преимущества Iceberg

- Соответствие требованиям ACID - целостность данных и согласованность обновлений
- Эволюция схемы хранения – любые изменения без пересоздания объекта
- Продвинутое партиционирование – скрытое партиционирование (разбиение на бакеты по выражениям без необходимости создавать вычисляемые поля), движки видят и используют скрытые партиции, изменение секционирования «на лету»
- Механизмы просмотра прошлых версий и отката на прошлые версии данных (time travel)
- Автоматическая оптимизация – сжатие, параллелизм UPDATE MERGE DELETE для Spark
- Поддержка потоковой передачи данных и микро-батчей
- Ближайшие альтернативы – Apache Hudi, Delta Lake



# Почему ANG ?

## Минимальное ТСО

- Минимизация стоимости хранения данных за счет разделения compute и storage
- Перевод CapEx в OpEx у облачных провайдеров



## Парадигма Lakehouse

- Объединение архитектурных принципов DWH и Data Lake – современный гибкий подход к организации хранения и аналитики



## Гибридная архитектура

- Экономия расходов за счет возможности разворачивания платформы в облаках (private cloud) и на ресурсах Заказчика (on-premise) как следствие самая выгодное соотношение стоимости на производительность



## Миграция и импортозамещение

- ANG обеспечивает полноценное замещение сервисов Cloudera





# Контакты



[ang-platform.ru](http://ang-platform.ru)  
[argumentdata.ru](http://argumentdata.ru)



[info@argumentdata.ru](mailto:info@argumentdata.ru)

