

# ХРАНИЛИЩА ДАННЫХ НА СЛУЖБЕ ВІ



Алексей  
Еремихин



Александр  
Крашенинников

Руководим разработкой VI в Badoo

badoo\_tech



A world map in a dark blue color with numerous small red dots scattered across the continents, representing global locations. The map is centered in the background.

> 550 000 000

people all over the world  
use our apps

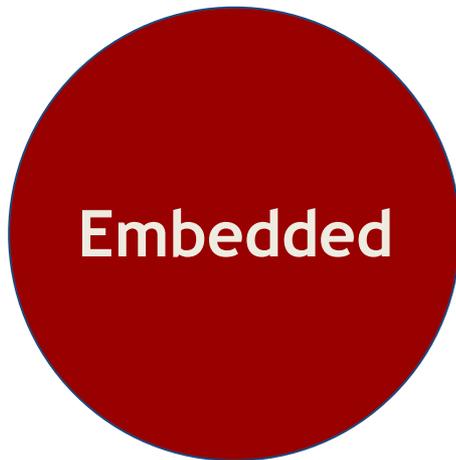
# План доклада

- Что такое BI
- Хранилища данных
- Задача ETL
- Обработка потока событий
- Cross-database bridge

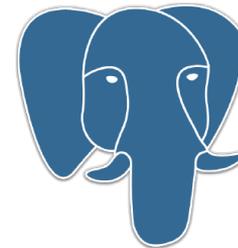
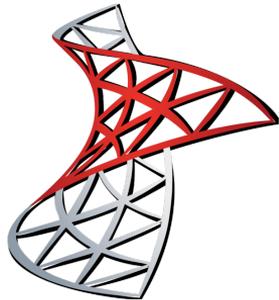
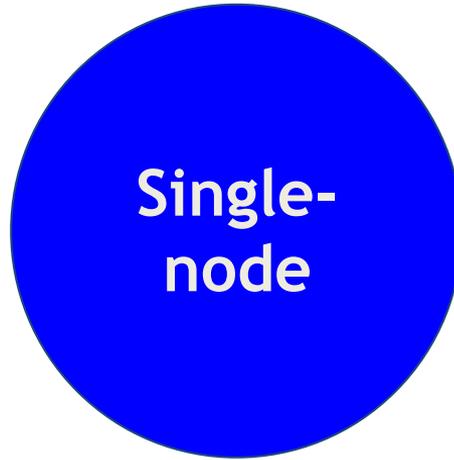
# Что такое BI

- Люди делающие графики из данных
- BI обеспечивает работу с данными
- А данные в хранилищах

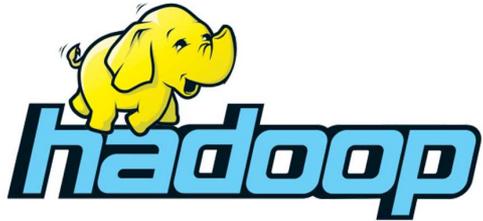
# Хранилища данных: Embedded



# Хранилища данных: Single-node



# Хранилища данных: Clustered

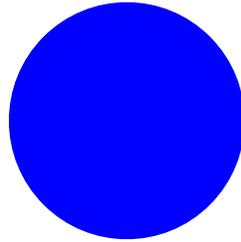


# Размеры и сложность баз

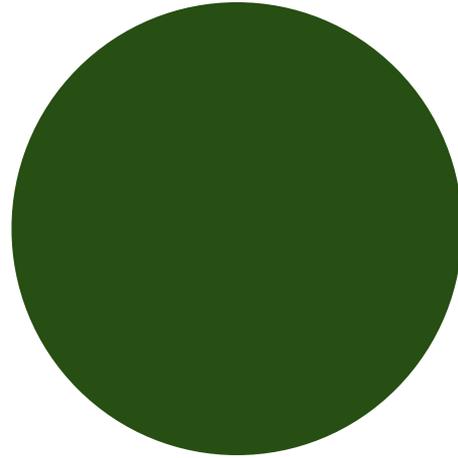
Embedde  
d



Single-node



Clustered

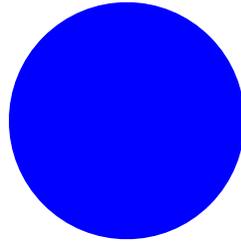


# Размеры и сложность баз

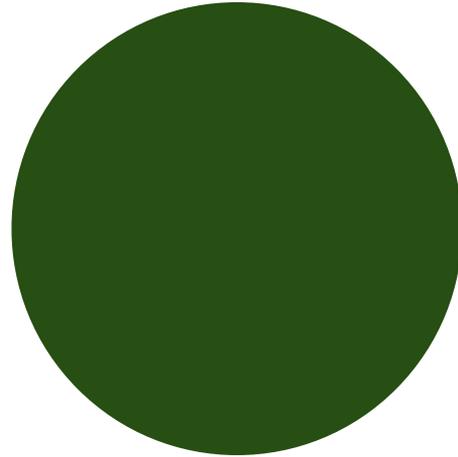
Embedde  
d



Single-node



Clustered

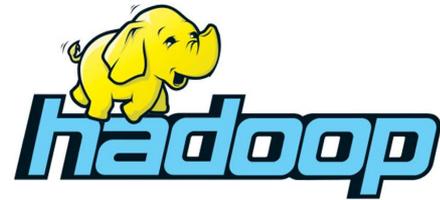


# Поговорим об ЭТИХ базах

Single-node



Clustered



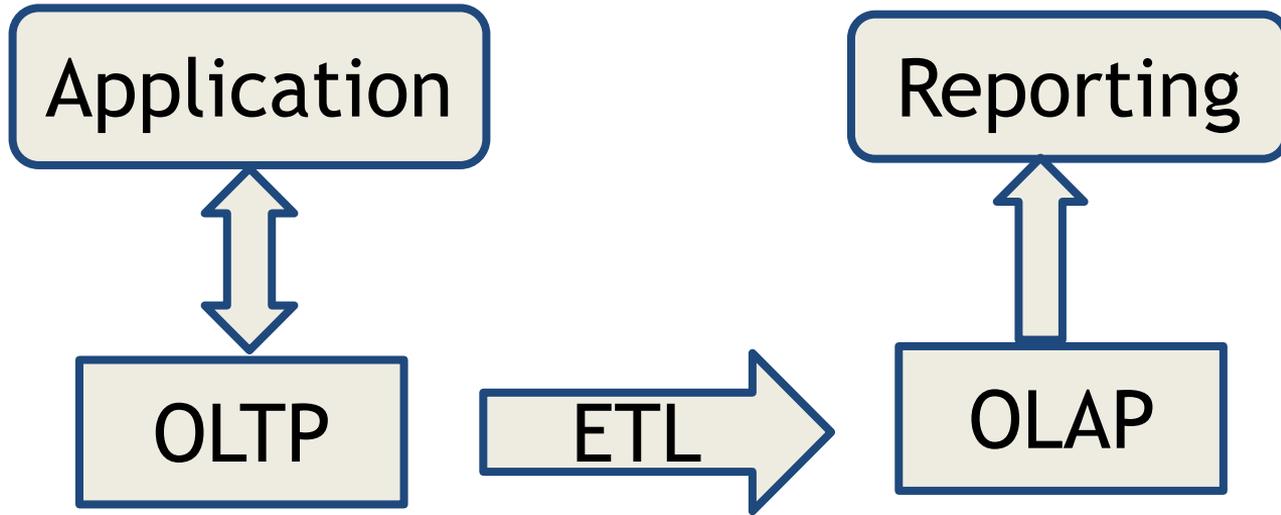
# Классический ETL

Extract

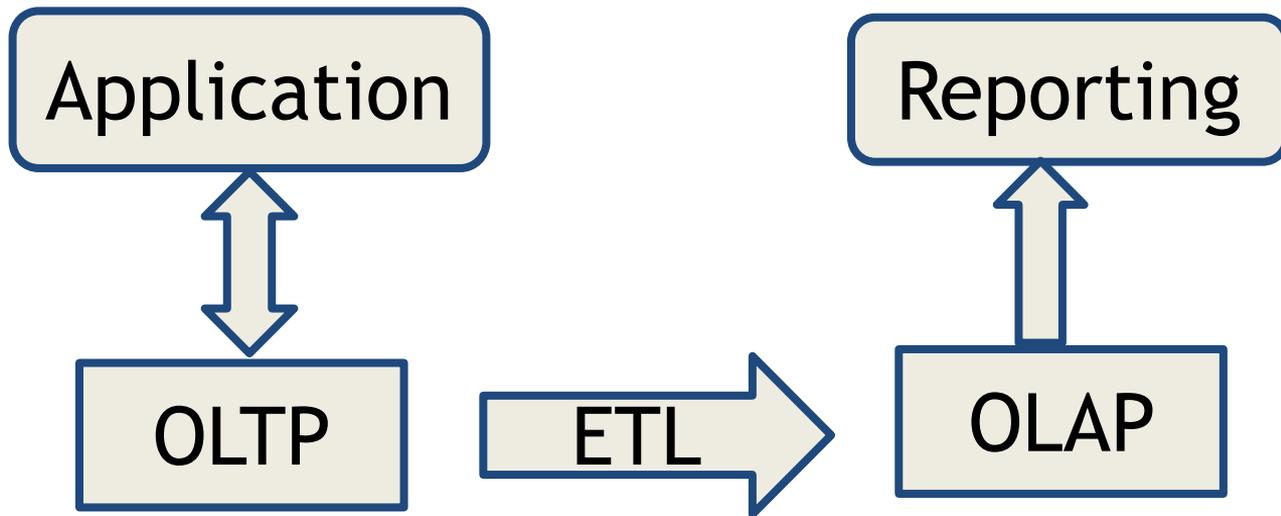
Transform

Load

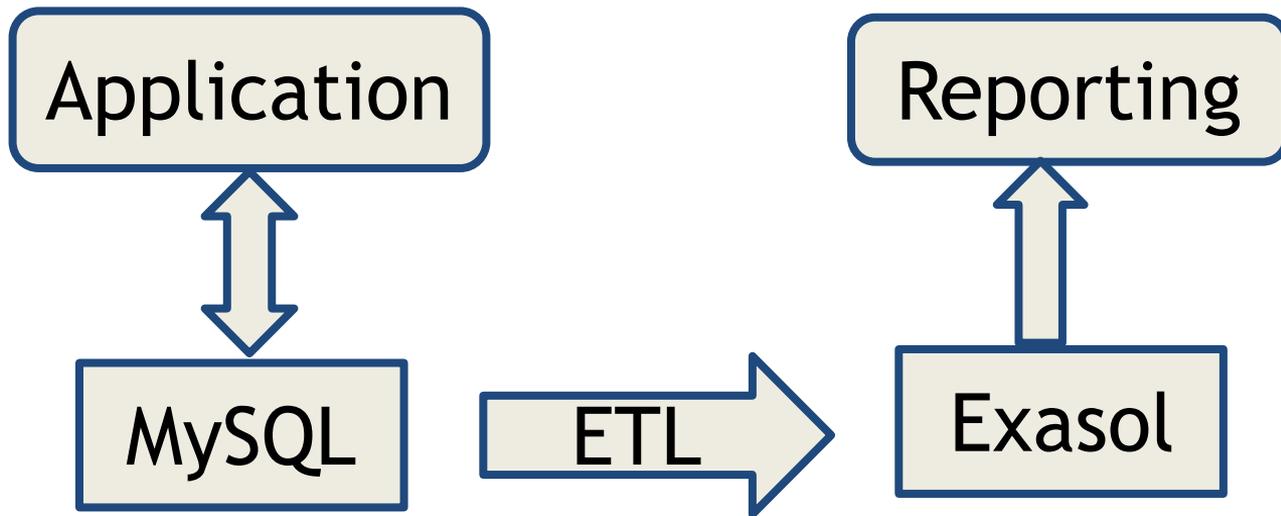
# Что такое ETL



# Непонятно!



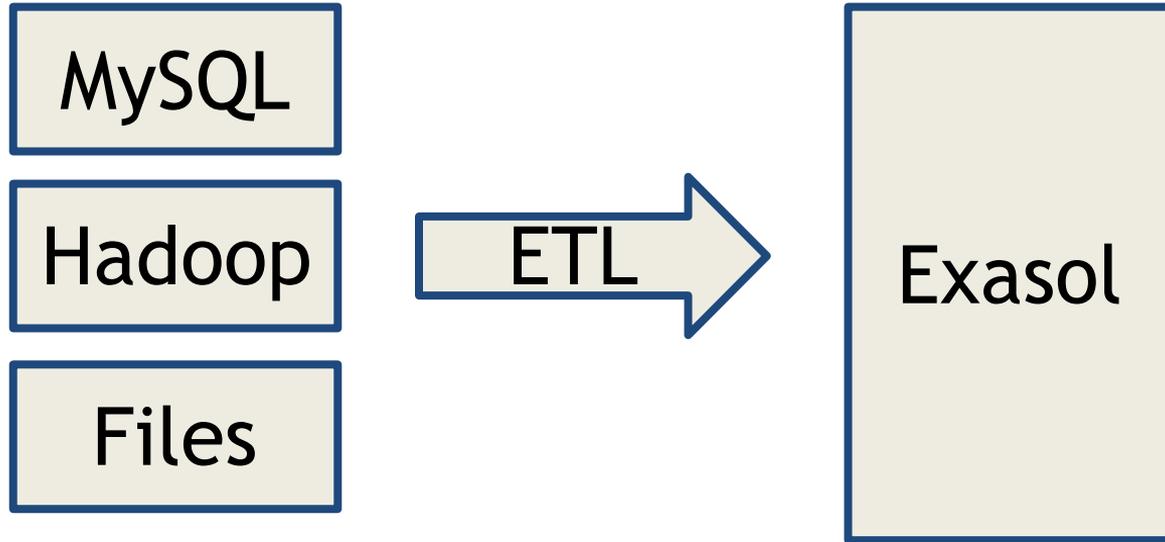
# Непонятно!



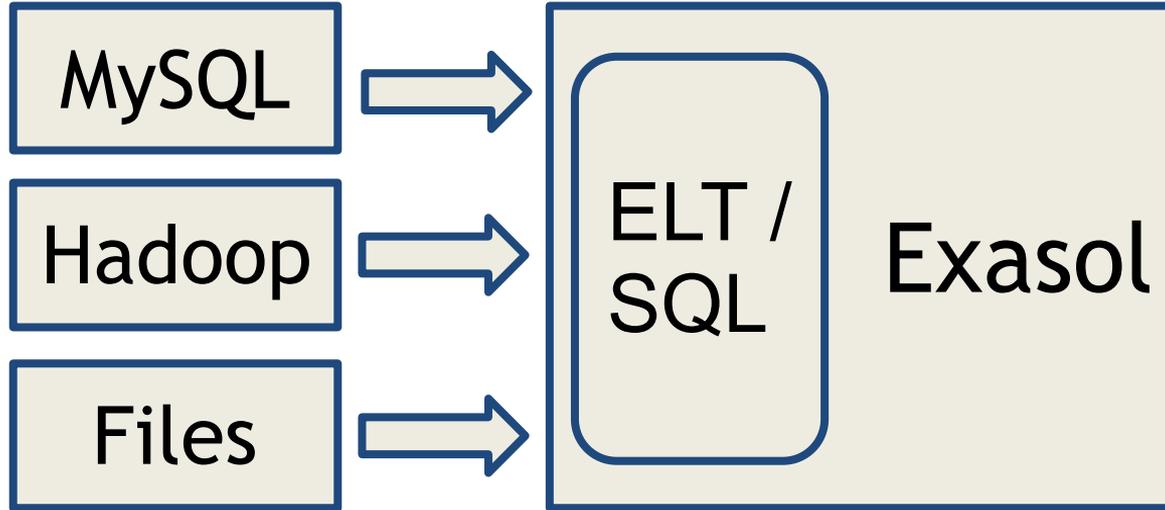
# Что такое ETL?



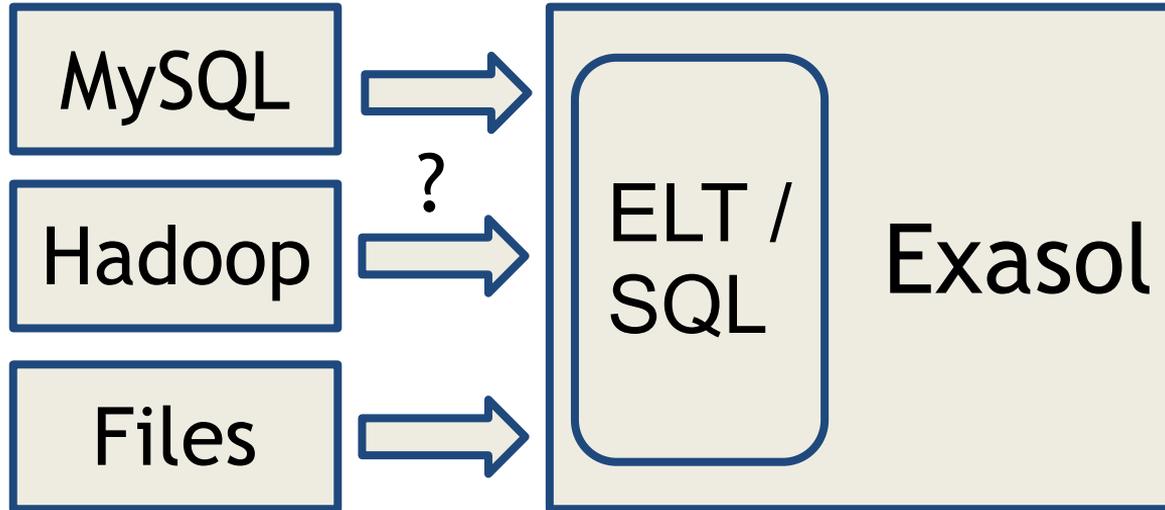
# ETL большого проекта



# ETL => ELT



# Какой формат?



# Формат TSV

- Почти как CSV (comma-separated), только tab-separated

# Формат TSV

- Почти как CSV (comma-separated), только tab-separated
- Нет проблем с экранированием запятых и кавычек

# Формат TSV

- Почти как CSV (comma-separated), только tab-separated
- Нет проблем с экранированием запятых и кавычек
- В BI табы и переводы строк встречаются редко

# Формат TSV

- Почти как CSV (comma-separated), только tab-separated
- Нет проблем с экранированием запятых и кавычек
- В VI табы и переводы строк встречаются редко
- Удобно работать в командной строке (cut, awk, sed, sort,...)

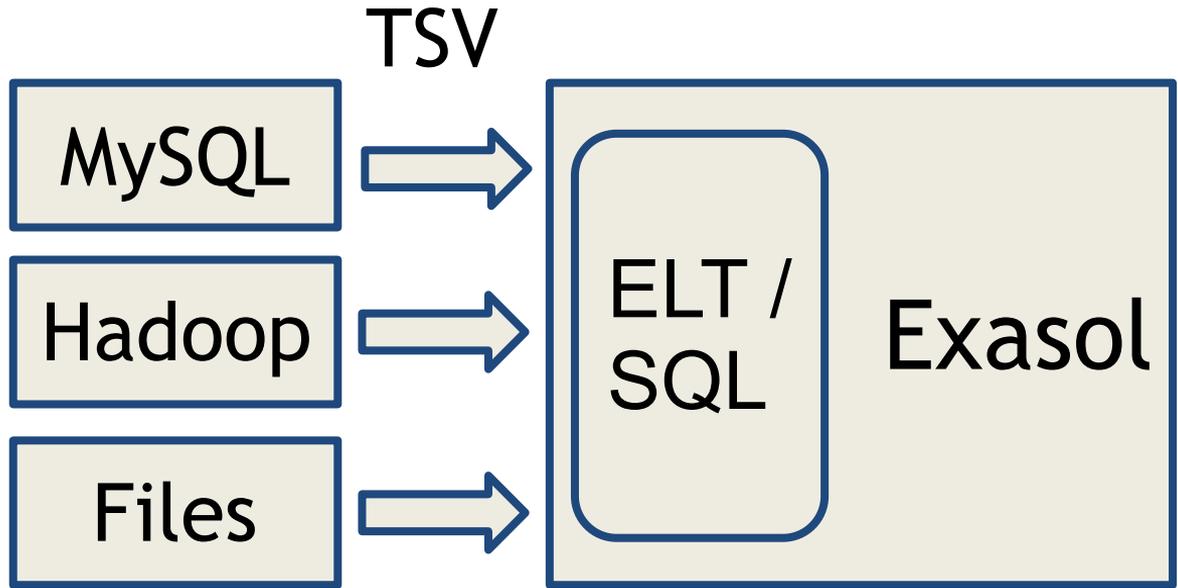
# Формат TSV

- Почти как CSV (comma-separated), только tab-separated
- Нет проблем с экранированием запятых и кавычек
- В VI табы и переводы строк встречаются редко
- Удобно работать в командной строке (cut, awk, sed, sort,...)
- Поддерживается везде (CSV с набором опций)

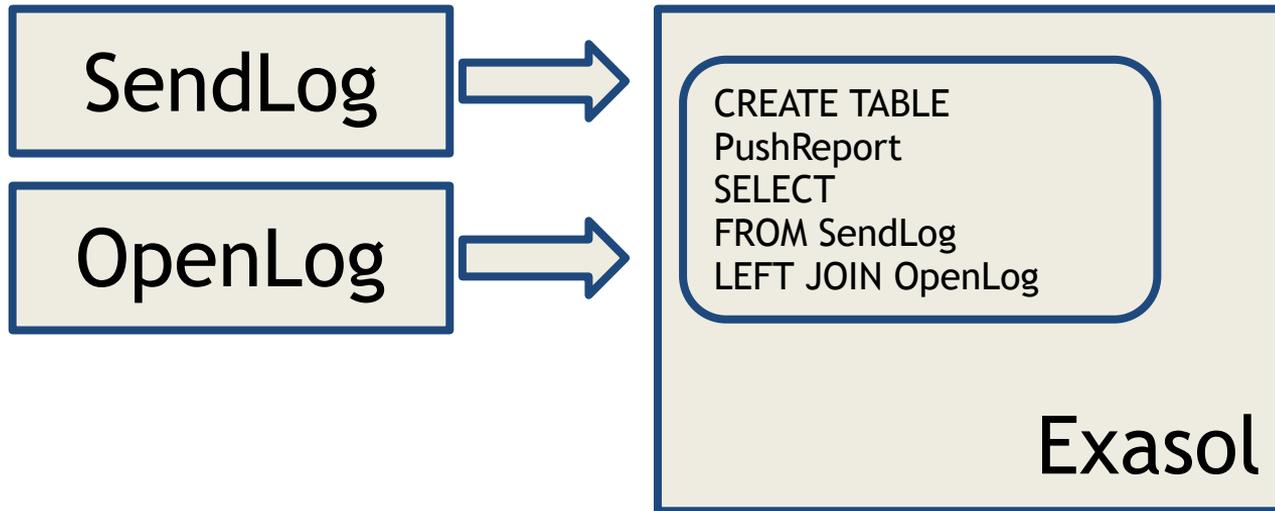
# Формат TSV

- Почти как CSV (comma-separated), только tab-separated
- Нет проблем с экранированием запятых и кавычек
- В VI табы и переводы строк встречаются редко
- Удобно работать в командной строке (cut, awk, sed, sort,...)
- Поддерживается везде (CSV с набором опций)
- Удобен в реализации

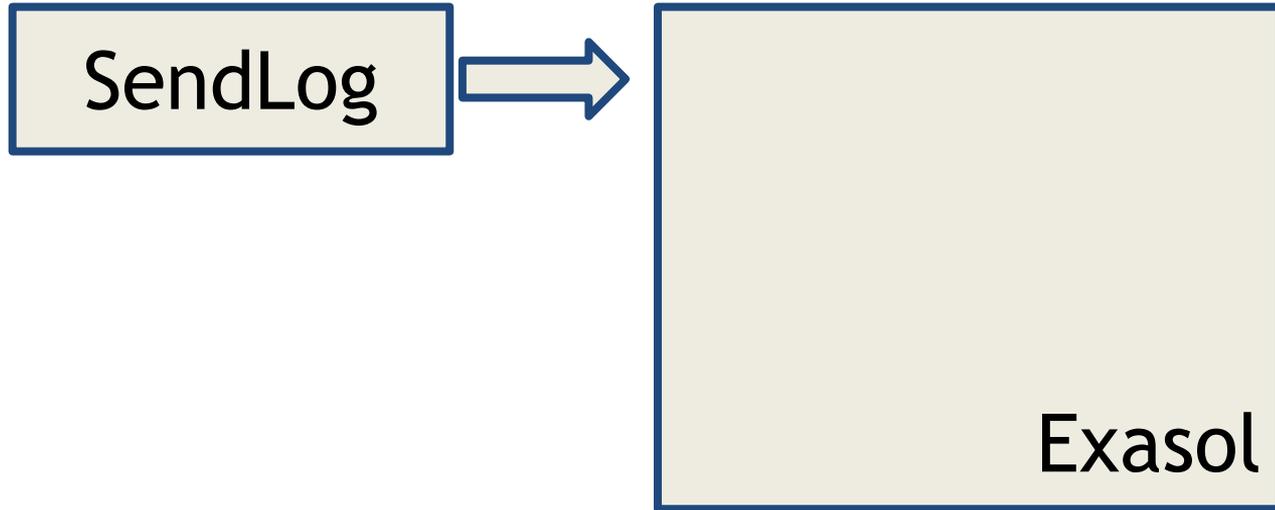
# TSV



# Пример: Push уведомления



# Пример: Push уведомления



# Передача MySQL -> Exasol

- Через временный файл

```
mysql -nsq -e
```

```
'SELECT * FROM SendLog' > /tmp/
```

```
file
```

30 минут, 100Gb, 500М строк

```
mysql -nsq -e
```

```
'SELECT * FROM SendLog' > /tmp/
```

```
file
```

```
exajload -sql
```

```
"IMPORT INTO staging 20 минут
```

```
FROM LOCAL CSV FILE
```

```
'/tmp/file'"
```



50 минут

# Передача MySQL -> Exasol

- Через временный файл
- Через pipe

```
mysql -nsq -e
```

```
'SELECT * FROM SendLog'
```

```
mysql -nsq -e  
    'SELECT * FROM SendLog' |  
exajload -sql  
    "IMPORT INTO staging  
    FROM LOCAL CSV FILE  
    '/dev/stdin'"
```

```
mysql -nsq -e  
    'SELECT * FROM SendLog' |  
exajload -sql  
    "IMPORT INTO staging  
    FROM LOCAL CSV FILE  
    '/dev/stdin'"
```

`set -o pipefail;` ← Не забыть!!!

`mysql -nsq -e`

`'SELECT * FROM SendLog' |`

`exajload -sql`

`"IMPORT INTO staging`

`FROM LOCAL CSV FILE`

`'/dev/stdin'"`



30 минут

# Передача MySQL -> Exasol

- Данные с одной машины
- А что, если шардинг?

```
(  
  mysql -nsq -h host1 'SELECT ...' &&  
  mysql -nsq -h host2 'SELECT ...' &&  
  mysql -nsq -h host3 'SELECT ...'  
) | exajload -sql "IMPORT ... '/dev/  
stdin"
```

```
(  
mysql -nsq -h host1 'SELECT ...' &&  
mysql -nsq -h host2 'SELECT ...' &&  
mysql -nsq -h host3 'SELECT ...'  
) | exajload -sql "IMPORT ... '/dev/  
stdin"
```

Последовательно 8(

# MySQL => Exasol : multi pipe

fdlinecombine <https://github.com/vi/fdlinecombine>

Multiplex multiple input streams into stdout using \n as separators.

Does One Thing, But Does It Well.

# fdlinecombine

```
< (mysql -nsq -h host1 'SELECT ...')
```

```
< (mysql -nsq -h host2 'SELECT ...')
```

```
< (mysql -nsq -h host3 'SELECT ...')
```

```
| exajload -sql "IMPORT .. '/dev/
```

```
stdin"
```

fdlinecombine

```
< (mysql -ns st1 'SELECT ...')
```

```
< (mysql -ns st2 'SELECT ...')
```

```
< (mysql -ns st3 'SELECT ...')
```

```
| exajload -sq PORT ... '/dev/
```

```
stdin'''
```

[Bash Pitfalls](#)



# MySQL => Exasol : multi pipe

Сделай сам!

PHP: `proc_open()`

Python: `subprocess.Popen()`



# MySQL => Exasol : multi pipe

Сделай сам!

Универсальные альтернативы:

`/dev/fd/%N`

`mkfifo` - создать named pipe

`/dev/stdin, /dev/stdout`



А почему бы не использовать GNU parallel?

“GNU parallel makes sure output from the commands is the **same output as you would get** had you **run the commands sequentially**. This makes it possible to use output from GNU parallel as input for other programs.”

# GNU parallel

- Может мержить потоки (опция `--line-buffer`)

# GNU parallel

- Может мержить потоки (опция `--line-buffer`)
- При этом жрёт много ресурсов

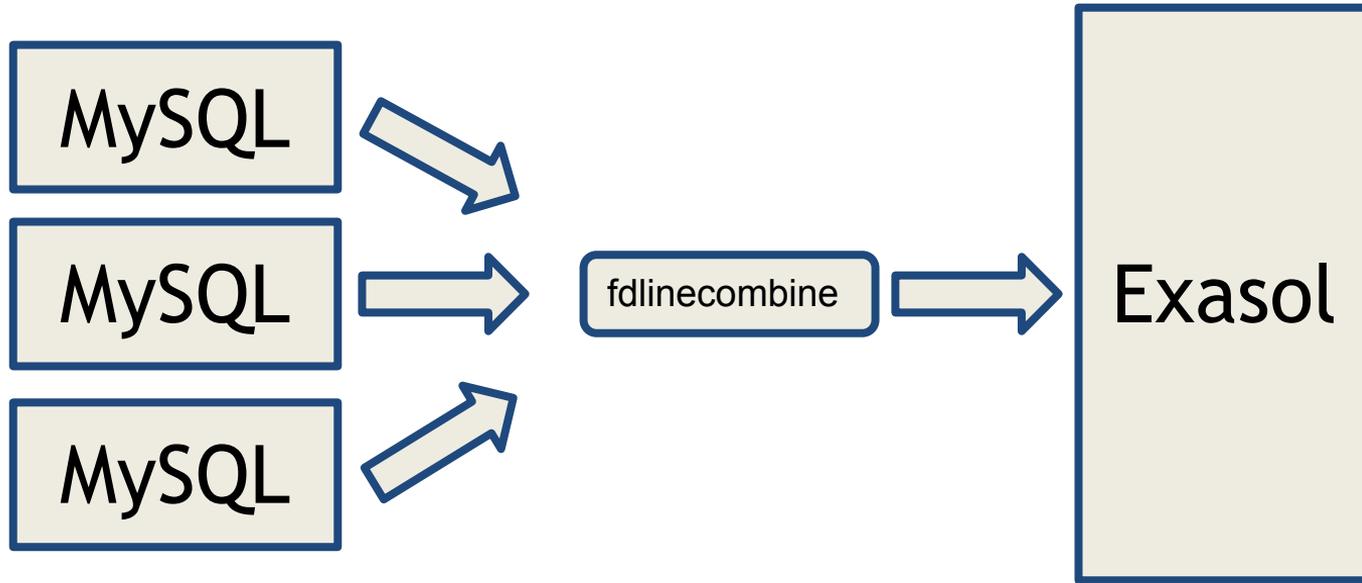
# GNU parallel

- Может мержить потоки (опция `--line-buffer`)
- При этом жрёт много ресурсов
- Сложен в отладке

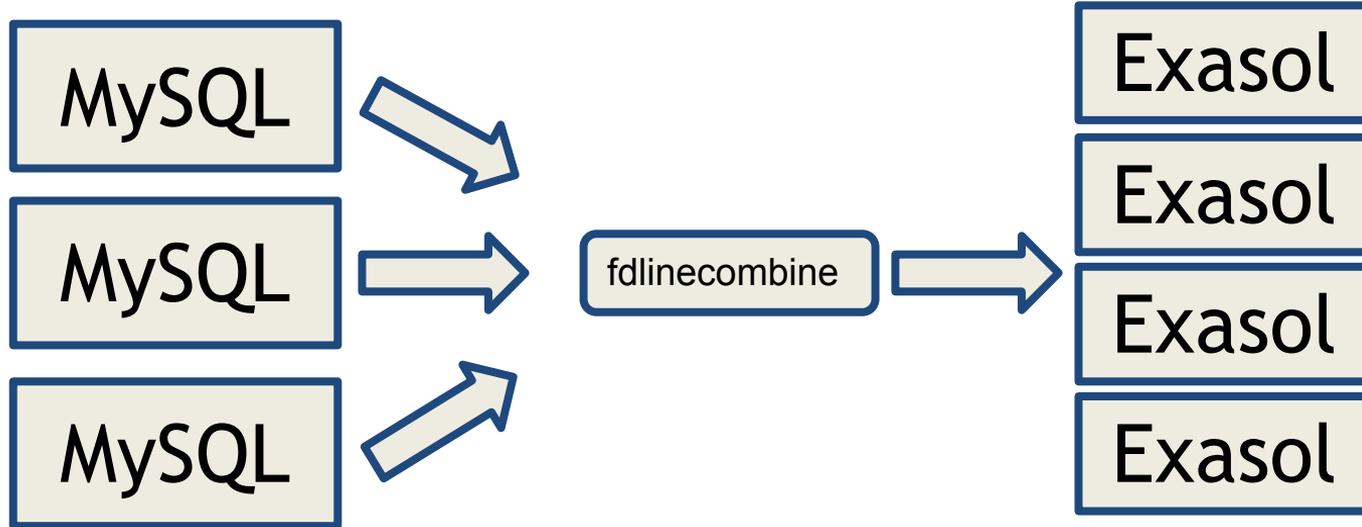
# GNU parallel

- Может мержить потоки (опция `--line-buffer`)
- При этом жрёт много ресурсов
- Сложен в отладке
- Мы находили баги (теряли данные)

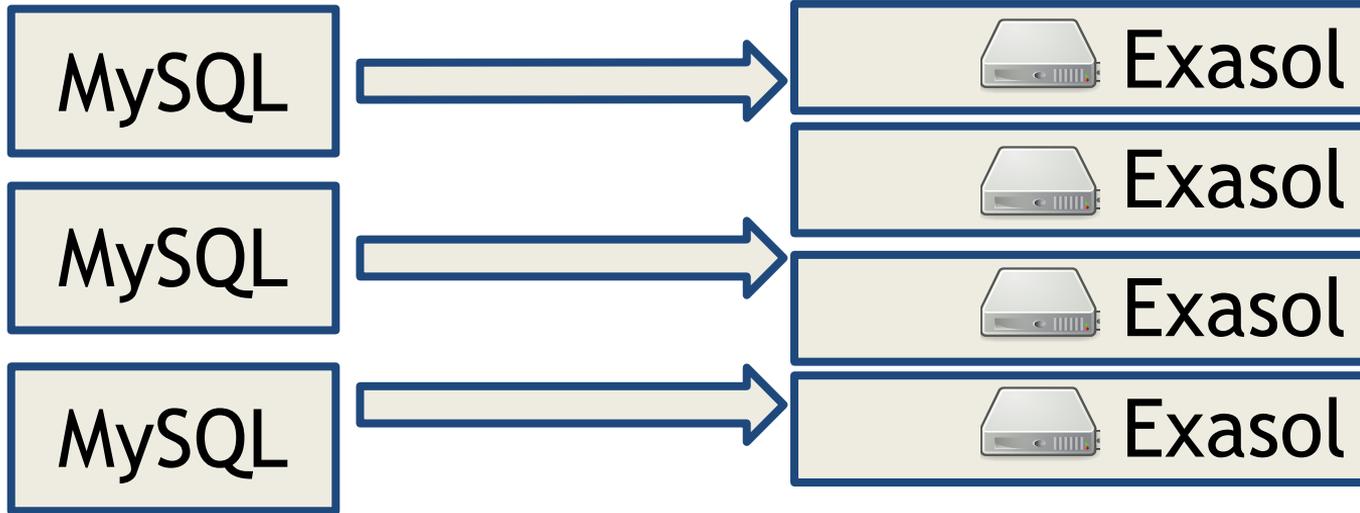
# MySQL => Exasol



# MySQL => Exasol

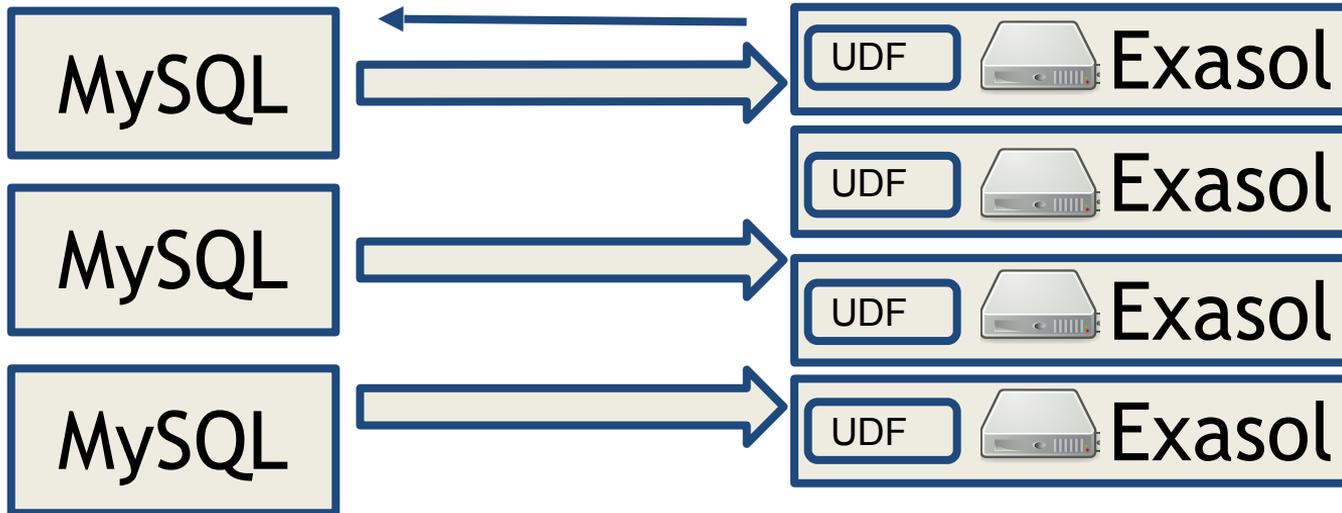


# MySQL => Exasol



# MySQL => Exasol

SELECT \* FROM T1



В 5 раз быстрее

# ETL граф

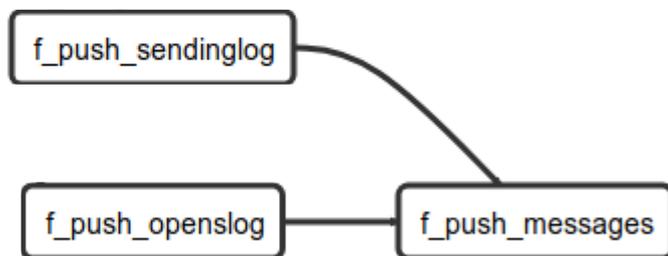
f\_push\_sendinglog

# ETL γραφ

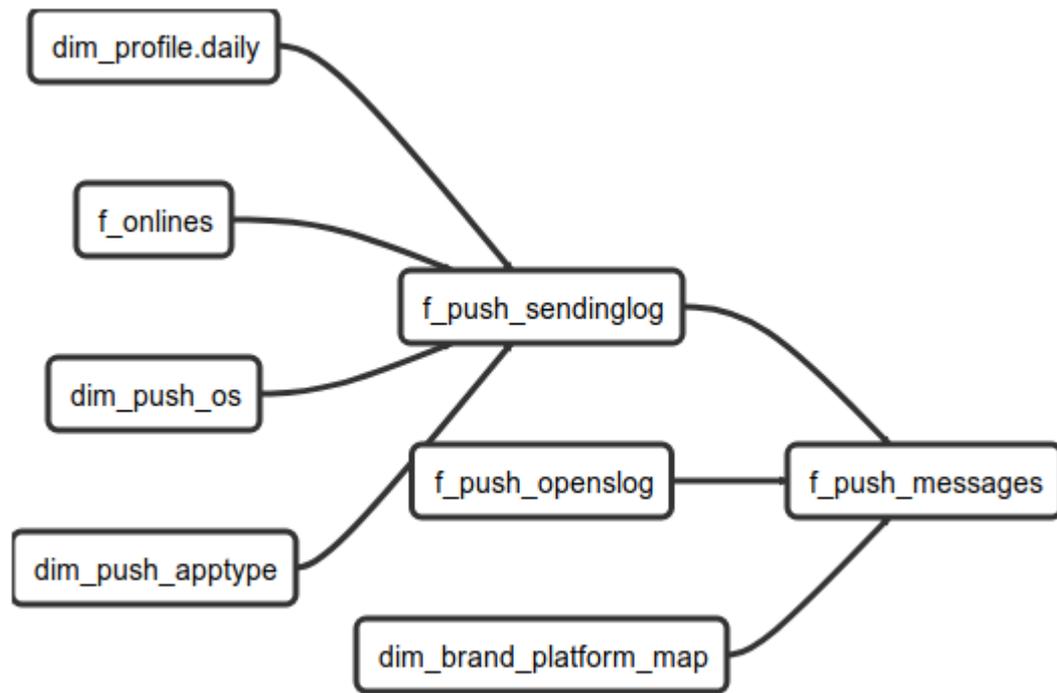
f\_push\_sendinglog

f\_push\_openslog

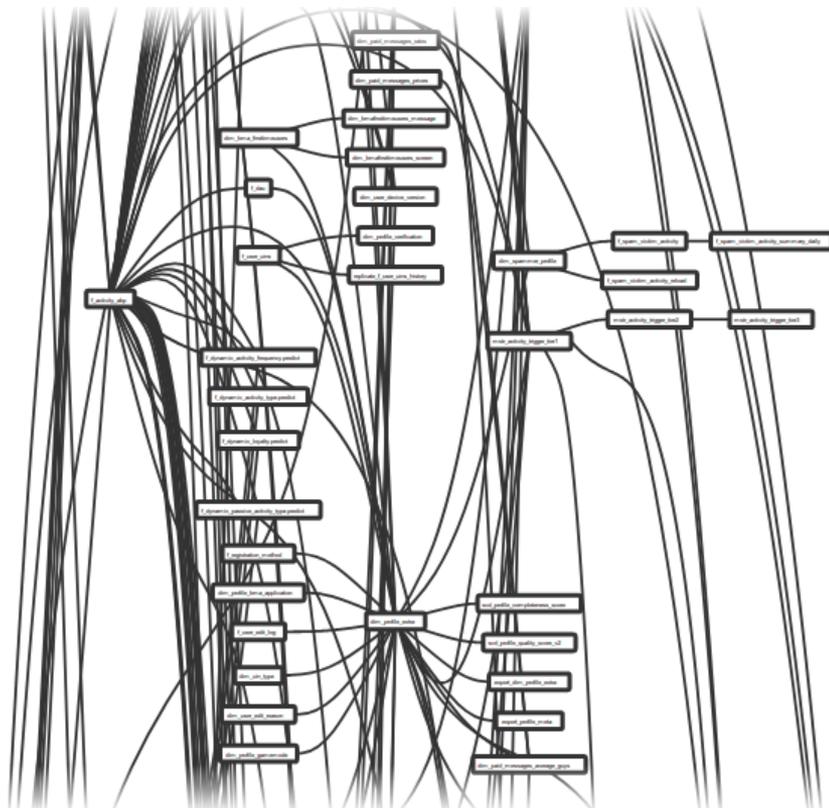
# ETL γραφ



# ETL γραφ



# ETL большого проекта





# Обработка ПОТОКА СОБЫТИЙ

# Продуктовая разработка

- Вопросы про данные

# Продуктовая разработка

- Вопросы про данные
  - Собираем больше информации

# Продуктовая разработка

- Вопросы про данные
  - Собираем больше информации
- Эксперименты и новые метрики

# Продуктовая разработка

- Вопросы про данные
  - Собираем больше информации
- Эксперименты и новые метрики
  - Настраиваем ETL
  - ALTER TABLE ....
  - Генерируем отчёты



Доколе!?

# Автоматизируй это!

- Формальное, machine-readable описание данных
- Автоматизация доставки в хранилища
- Автоматизация репортинга

# Формальное описание событий

- Единый формат для всех платформ
- Строгая типизация атрибутов
- Понятно человеку и машине

# Событие «Авторизация»

# SignIn (21)

Categories: **Account**

Properties:

[Scroll to bottom](#) ↓

1. **method**( [SocialMedia](#) ) \* 

Sign in method user used to sign in.

2. **is\_registration**(*bool*) \* 

Is this sign-in a new registration?

# Событие «Авторизация»

# SignIn (21)

Categories: **Account**

Properties:

Scroll to bottom ↓

1. **method**( *SocialMedia* ) \* X

Sign in method user used to sign in.

2. **is\_registration**(*bool*) \* X :

Is this sign-in a new registration?

# ENUM

## «Способы авторизации»

# SocialMedia

Values

Scroll to bottom ↓

1. **SOCIAL\_MEDIA\_EMAIL**

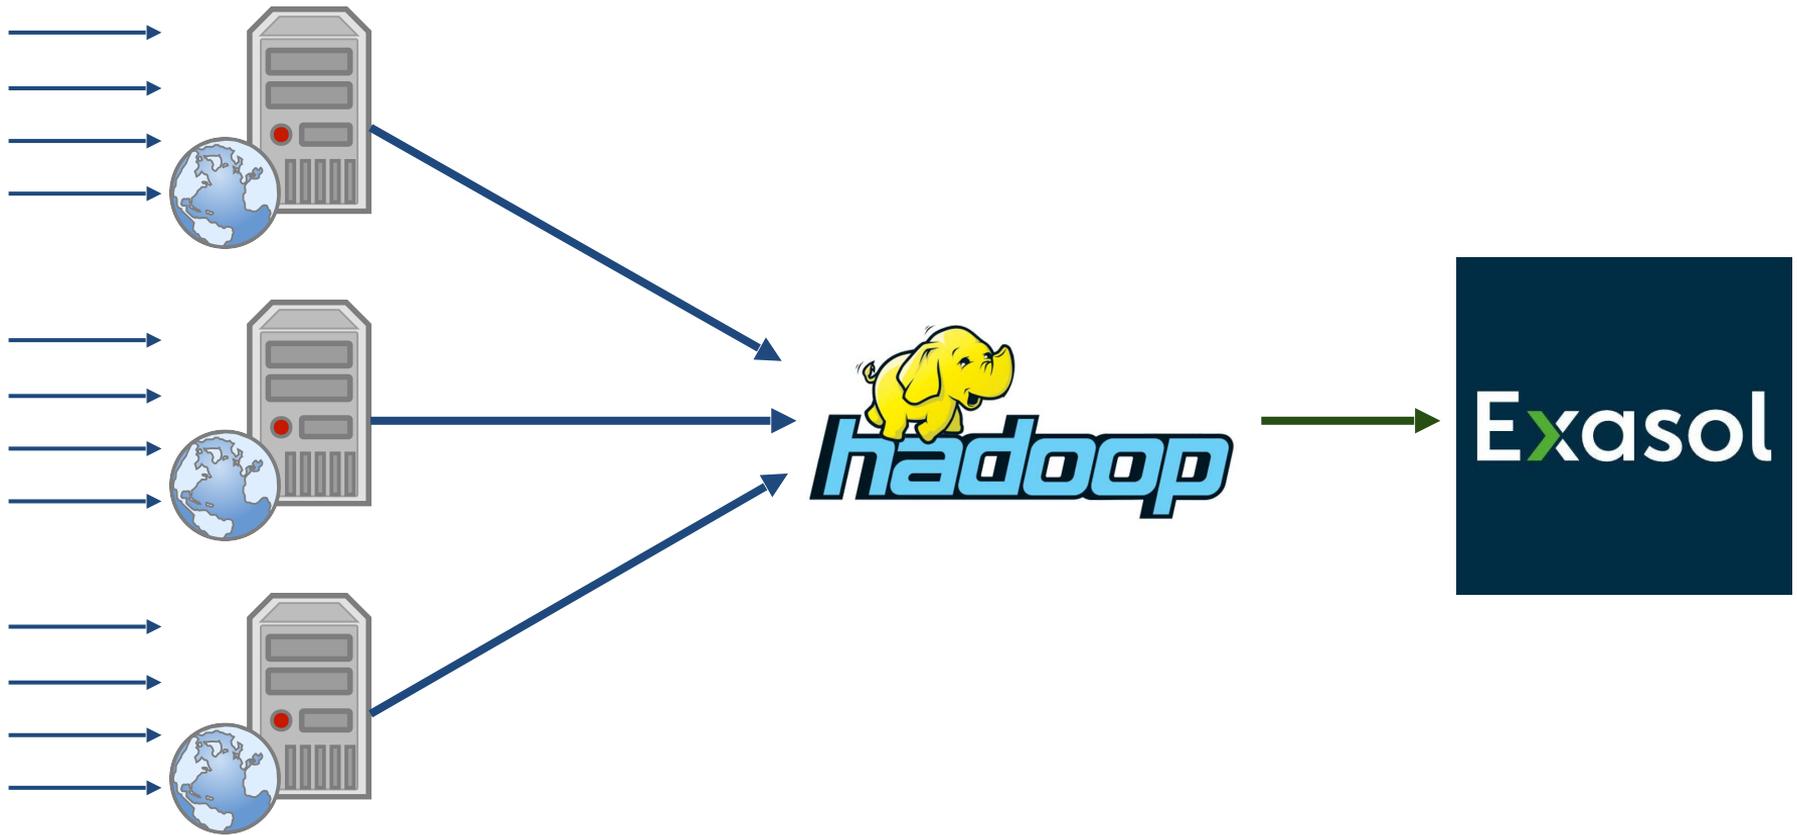
Email

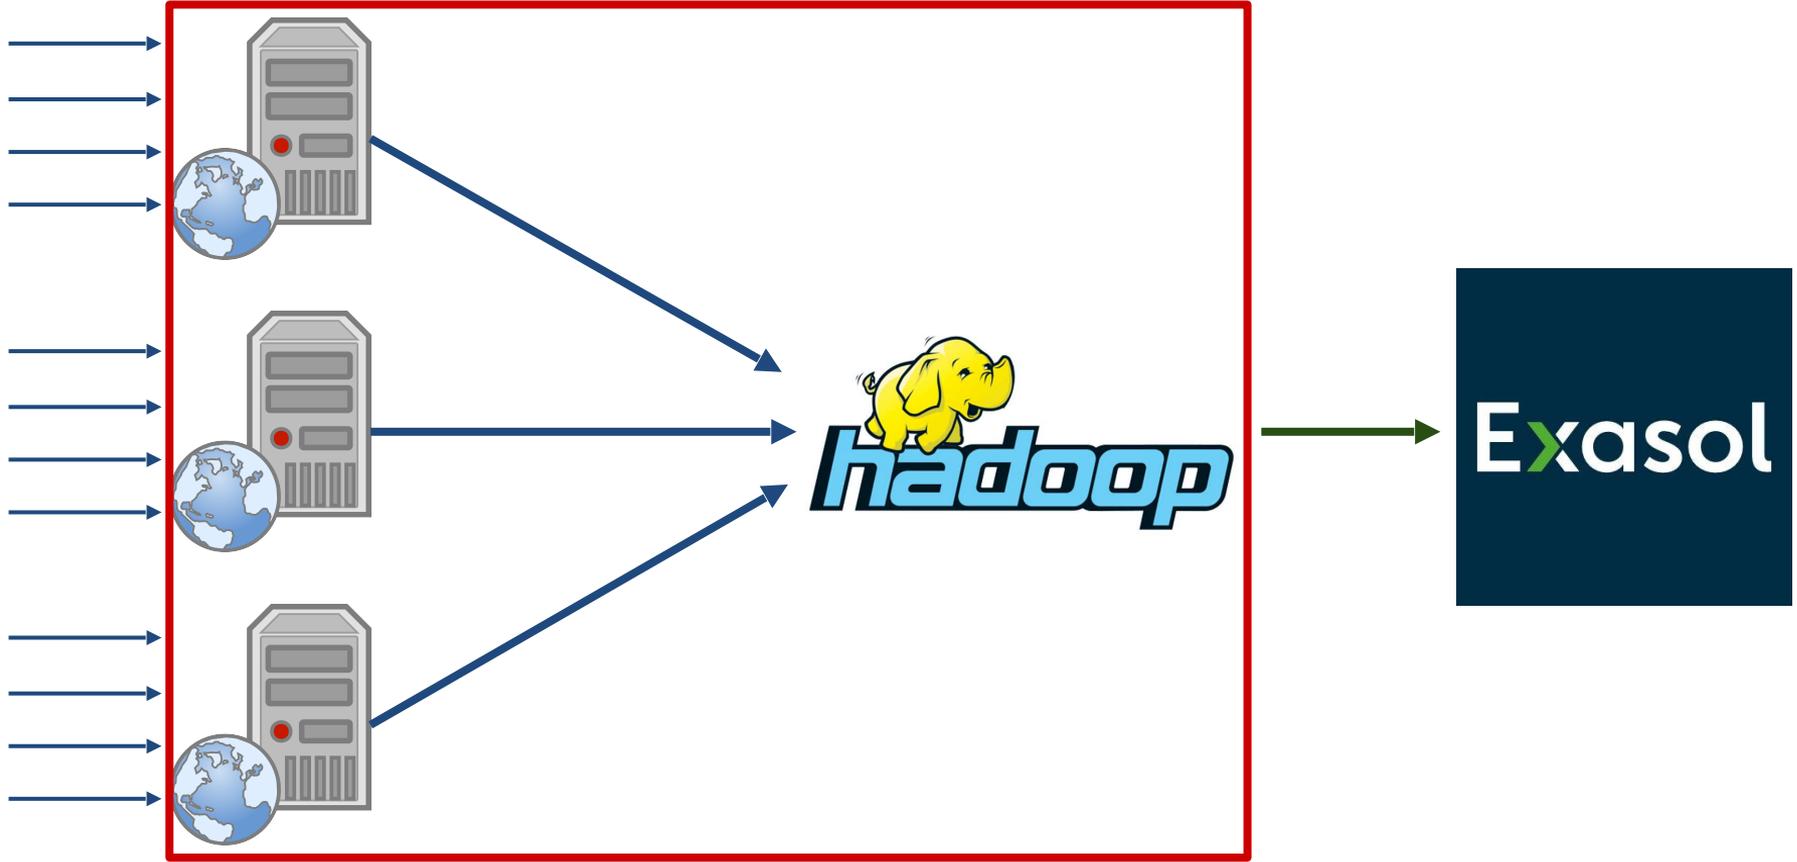
2. **SOCIAL\_MEDIA\_FACEBOOK**

Facebook

# Доставка в хранилища

- Сгенерировать события на backend
- Преобразовать
- Загрузить в хранилище





# Схема в Hadoop (Hive)

- Единая таблица для хранения всех событий
- Хранение атрибутов в `map<string, string>`

# Схема в Hadoop (Hive)

- Единая таблица для хранения всех событий
- Хранение атрибутов в `map<string, string>`
- Модный формат хранения ORC



# Схема в Hive: преимущества

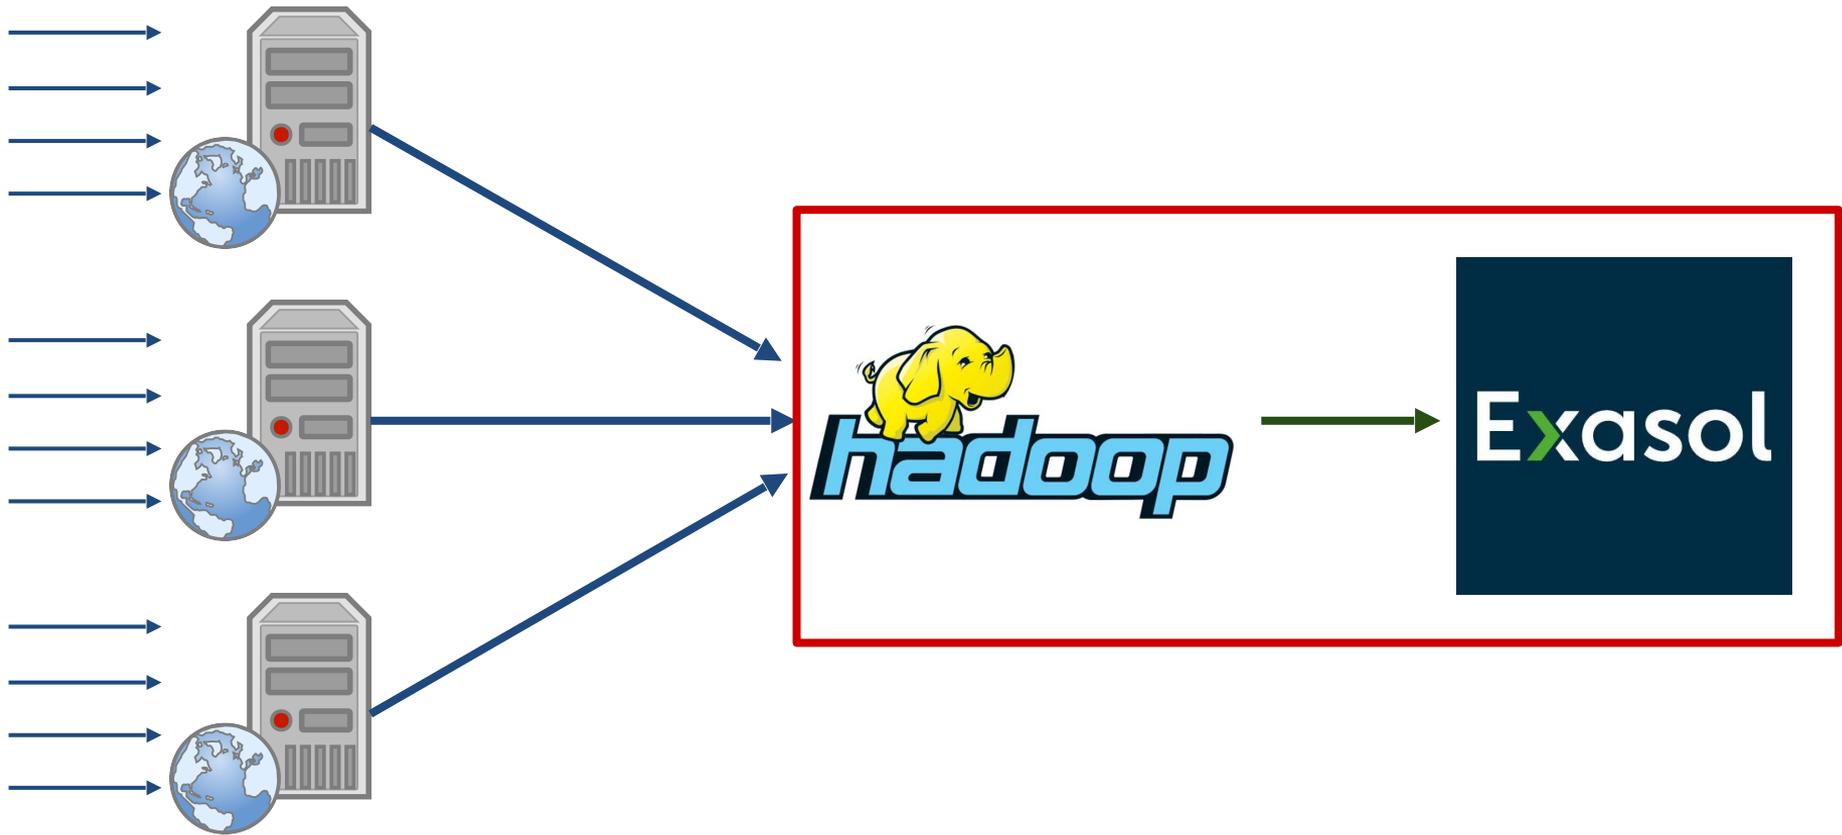
- Поддержка любых атрибутов событий
- Top-level reporting по всему объему данных
- Оперативное обновление

# Схема в Hive: недостатки

- Большое количество партиций
- Overhead на хранение атрибутов в строках

# Доставка в Hive

- Накопить данные в HDFS
- Сделать временную таблицу (JSON)
- `INSERT OVERWRITE TABLE table_name  
SELECT ... FROM table_temporary`



# Схема хранения в Exasol

- Таблица на каждый тип события
- Каждому атрибуту - отдельная колонка
- Общая информация  
о событиях в отдельной таблице

# Header

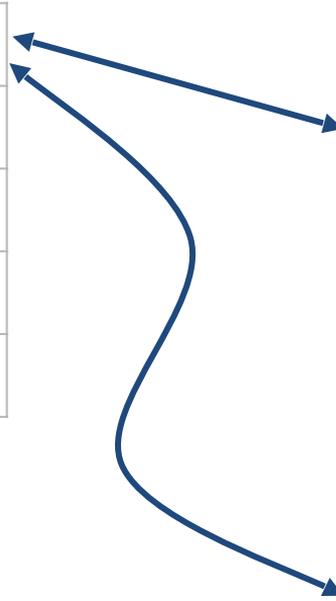
head_id	12345678901234
user_id	100500
gender	Male
country	Russia
platform	Android

# Событие SignIn

head_id	method	job_id
12345678901234	Email	job_one
98765432109876	Facebook	job_two

# Событие ViewProfile

head_id	profile_id	job_id
12345678901234	1567854	job_one
98765432109876	4589783	job_one



# Схема в Exasol: преимущества

- Оптимизация хранилища под типы данных
- Быстрый репортинг по отдельным событиям

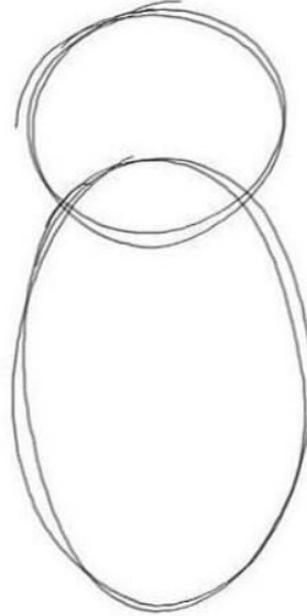
# Схема в Exasol: недостатки

- Надо поддерживать согласованность конфига событий и схемы таблиц
- Нет сквозного репортинга по всем данным

# Доставка в Exasol

- Взять данные из Hadoop
- Сформировать открыть транзакцию в Exasol
- Вставить данные
- COMMIT в Exasol

# Baykuş nasıl çizilir



1. ADIM  
ÖNCE İKİ DAİRE ÇIZIYORUZ...



2. ADIM  
SONRA KALAN DETAYLARI ÇIZIYORUZ.

# Hadoop -> Exasol

- Объём исходных данных - до 150 Gb
- У каждого события - своя схема

The logo for Apache Spark, featuring the word "Spark" in a dark, hand-drawn, cursive font. A bright yellow, hand-drawn star is positioned above the letter "k".

Spark

# Схема pipeline

- Выбрать данные из Hive в Spark
- Для каждого события получаем колонки из Exasol
- Формируем TSV-файлы в HDFS
- Импортируем в Exasol

```
IMPORT INTO data.click_event
```

```
FROM CSV AT
```

```
'http://hadoop:50070/etl_xxxx/signin/'
```

```
FILE '1.csv.gz',
```

Hadoop WebHDFS

```
...
```

```
FILE 'XXX.csv.gz';
```

```
IMPORT INTO data.click_event
```

```
FROM CSV AT
```

```
'http://hadoop:50070/etl_xxxx/signin/'
```

```
FILE '1.csv.gz',
```

```
...
```

```
FILE 'XXX.csv.gz';
```

Параллельная обработка  
событий одного типа

# Преимущества

- Распределение дисковой нагрузки
  - HDFS
  - Spark Workers
- Node-to-node взаимодействие при IMPORT
- Идемпотентность - перезаливка части событий из job\_id



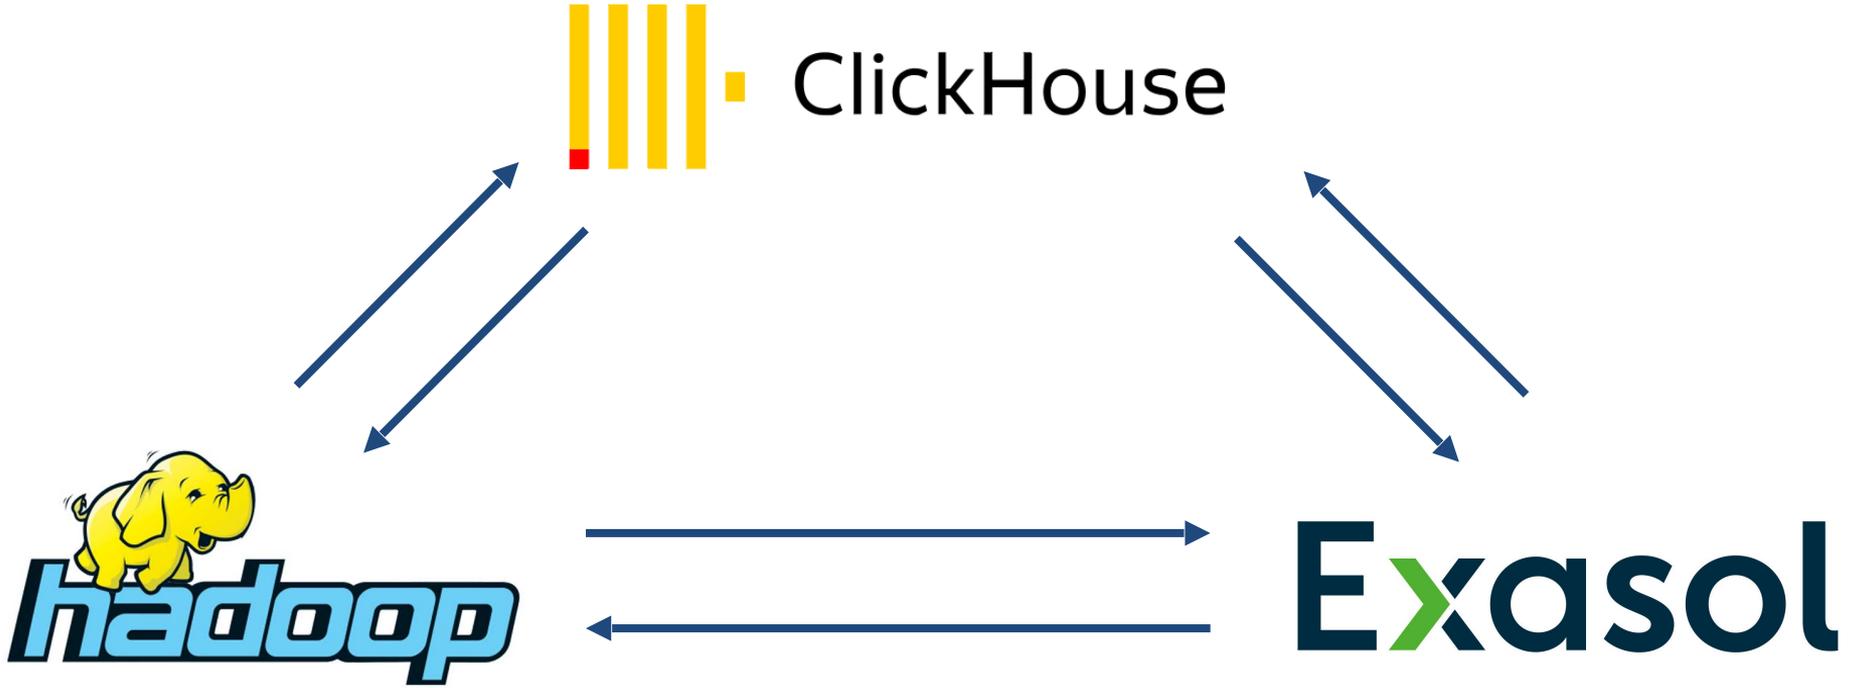
# Cross-database bridges

# Зачем строить мосты?

- Каждая база хороша по-своему
- Не все задачи можно выполнить внутри одного хранилища

# Зачем строить мосты?

- Каждая база хороша по-своему
- Не все задачи можно выполнить внутри одного хранилища
- Требуется обмен данными между большими системами





## ClickHouse

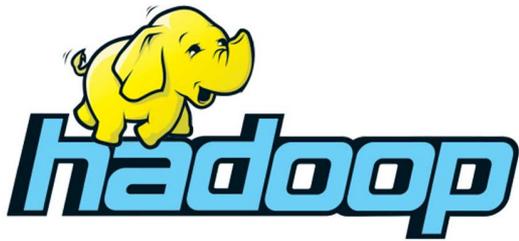
- Сверхбыстрая выборка в пределах таблицы
- Real-time вставка данных
- Можно делать мелкие вставки



# ClickHouse

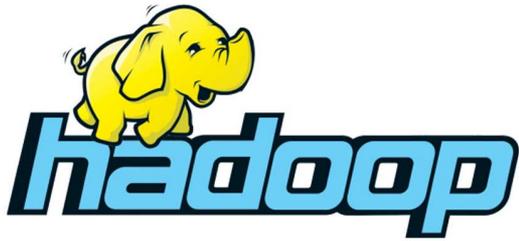
- Слабый JOIN
  - не все аналитические задачи решаются
- Важно думать о data locality
  - иначе не сделать JOIN больших таблиц





- Принимает данные в любых форматах
- Лёгкое масштабирование
- Удобное управление репликацией и retention
- Можно делать любые JOIN  
– хоть и не всегда быстро





- Надо думать о партицировании данных
- Плохо работает с маленькими вставками
- Высокое значение latency



# Exasol

- Высокая скорость сканирования
- Любые аналитические операции
- Всё быстро



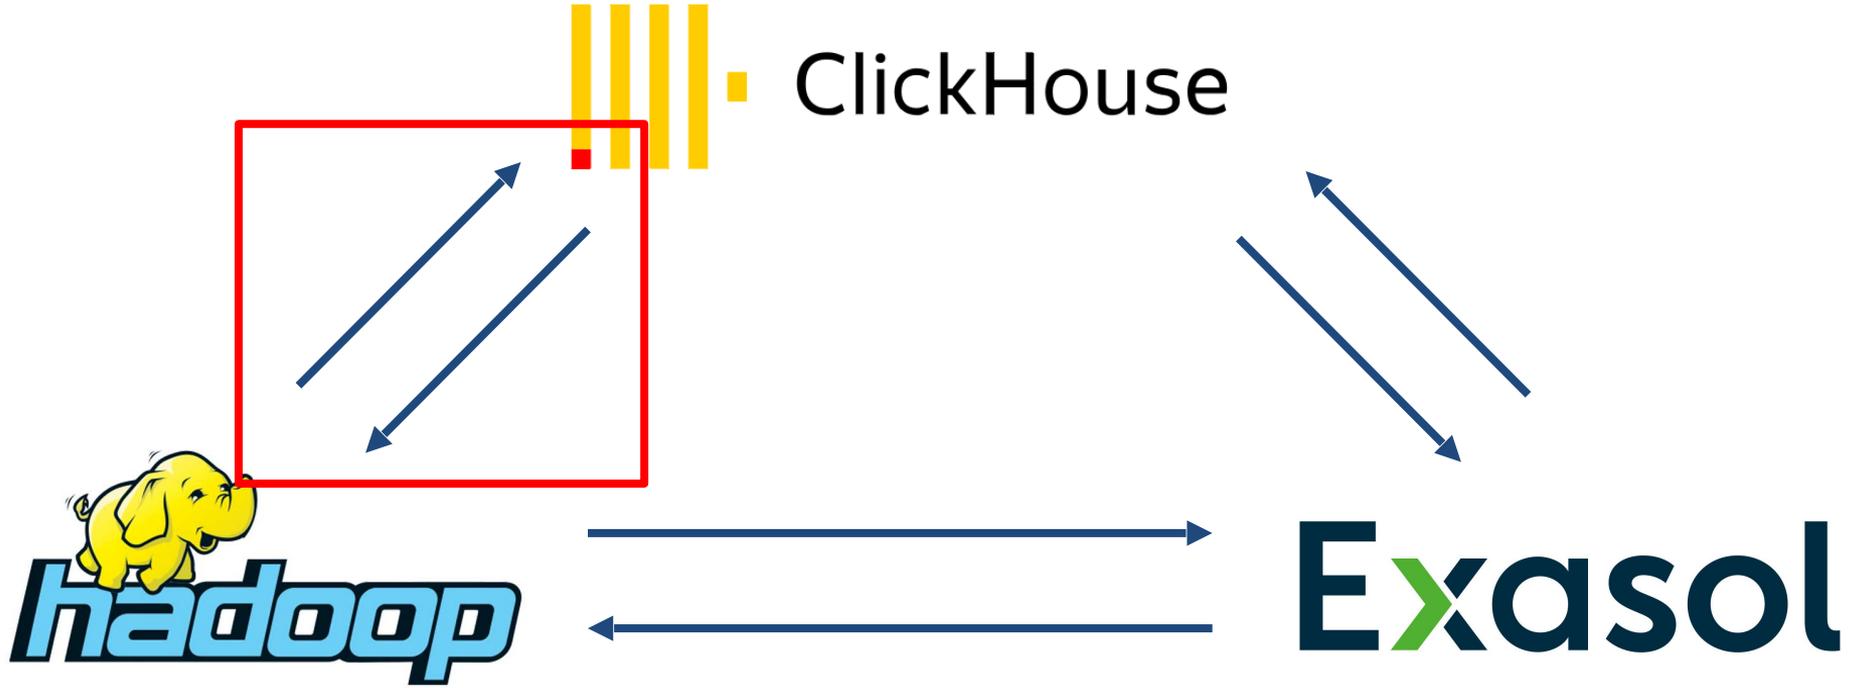
# Exasol

- Дорого хранить исторические данные
- Вставка большими порциями и редко



# Всё круто, и всё же - мосты?

- Ни одно хранилище не обладает 100% информации
- Будем брать лучшее, и доставлять недостающее



# Hadoop to ClickHouse

- Запрос в ClickHouse на импорт данных
- Используя Spark

```
SELECT * FROM
```

```
hdfs(
```

```
  'hdfs://hdfs1:9000/file',
```

```
  TSV,
```

```
  'id UInt64, number Float64'
```

```
)
```

```
SELECT * FROM
```

```
hdfs(
```

```
'hdfs://hdfs1:9000/file', --- URL файла
```

```
TSV, --- формат данных
```

```
'id UInt64, number Float64'--- схема данных
```

```
)
```

# Hadoop to ClickHouse via SQL

- Нативно, внутри ClickHouse
- Поддержка лишь одного файла за раз
  - в разработке поддержка globbing
- Требуется согласованность форматов данных
- Всё прокачивается через  
1 машину ClickHouse

# Hadoop to ClickHouse via Spark

- Читаем данные в Spark
- Преобразуем
- Каждую партицию данных пишем через JDBC-коннектор + нестандартный метод [sendRowBinaryStream](#)

# Hadoop to ClickHouse via Spark

- Не только SQL для преобразований
- Параллелизм обработки
- Пишем в любые ноды ClickHouse

# Hadoop to ClickHouse via Spark

- Не только SQL для преобразований
- Параллелизм обработки
- Пишем в любые ноды ClickHouse
- **Надо программировать**
- **Ограничено Spark + Java/Scala**
- **Накладные расходы от Spark**

# ClickHouse to Hadoop

- Запрос в ClickHouse на экспорт данных
- Через Spark

```
CREATE TABLE hdfs_table
```

```
(id Int32)
```

```
ENGINE = HDFS('hdfs://hdfs1:9000/file', 'TSV');
```

```
INSERT INTO hdfs_table
```

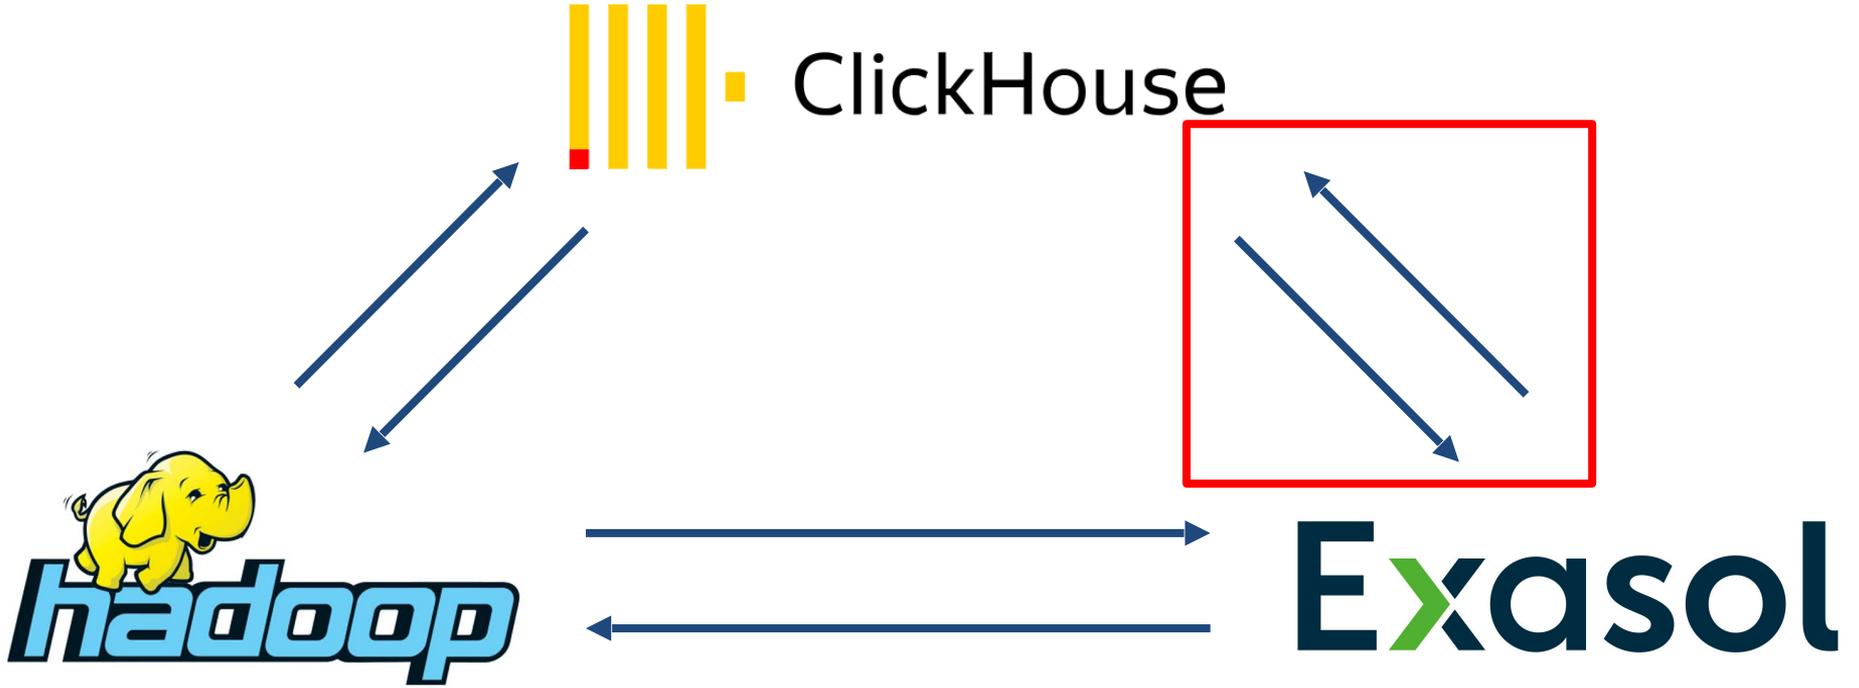
```
SELECT * FROM another_table;
```

# ClickHouse to Hadoop via SQL

- Запись только в один файл
- Обработывается через 1 машину  
ClickHouse

# ClickHouse to Hadoop via Spark

- JDBC + нестандартный метод [executeQueryClickHouseRowBinaryStream](#)
- Программное управление топологией данных



# ClickHouse to Exasol и обратно

- Через `IMPORT/EXPORT` команды Exasol

```
IMPORT INTO exasol_table  
FROM CSV AT  
'http://clickhouse1:8123/'  
FILE '?query=SELECT * FROM clickhouse_table'
```

**EXPORT** exasol\_table

**INTO CSV AT**

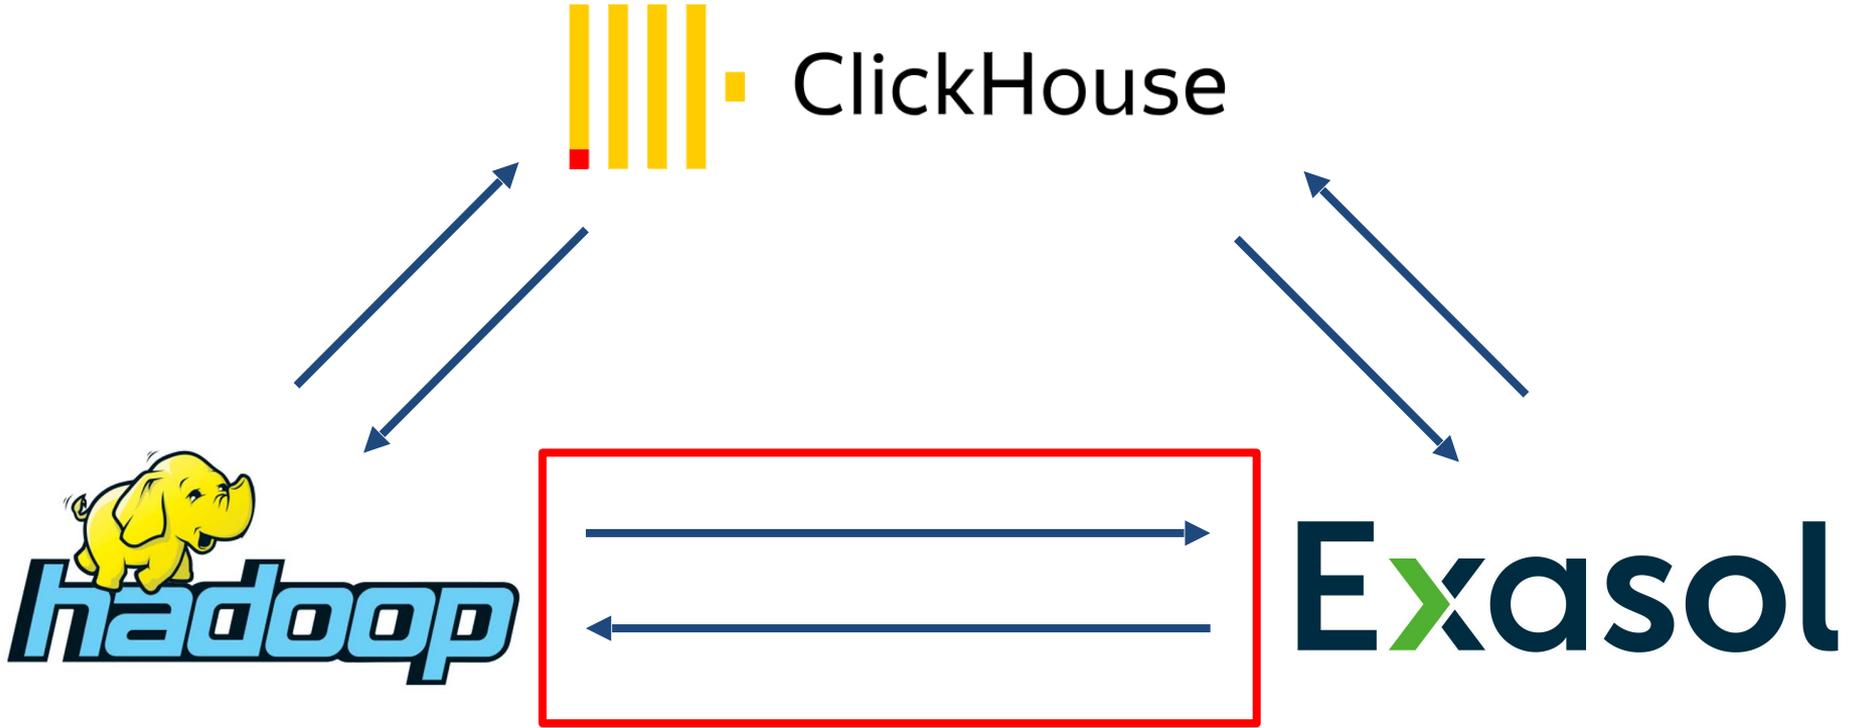
'http://clickhouse1:8123/'

**FILE**

'?query=INSERT INTO clickhouse\_table FORMAT CSV'

# ClickHouse to Exasol и обратно

- Дёшево и просто
- Ограничено взаимодействием двух машин
  - исправить: через Spark
  - в связке с Exasol [sub-connections](#)



# Hadoop to Exasol

- WebHDFS + TSV + Exasol IMPORT query
- Через Spark + Exasol [sub-connections](#)

# Exasol to Hadoop

- Exasol EXPORT query
  - более одного файла
  - только CSV
- Exasol UDF
  - высокая производительность
  - любые форматы
  - требует программирования

# Выводы

- ВІ - это круто :)
- Подбираем хранилище данных под задачу
- Берём лучшее от разных систем
- В экспериментах рождается прогресс

# СПАСИБО!

[krash@corp.badoo.com](mailto:krash@corp.badoo.com)  
[a.eremihin@corp.badoo.com](mailto:a.eremihin@corp.badoo.com)

badoo\_tech