Яндекс  ClickHouse

Разбираемся во внутреннем устройстве ClickHouse

Виталий Людвиченко

Знакомство

Виталий Людвиченко

- 2014-2016 

- 2016-… ClickHouse

Задачи, для которых подходит ClickHouse

Есть поток событий

- Действия пользователей на сайте
- Показы рекламы
- Финансовые транзакции
- DNS–запросы
- …

Хотим сохранять эти события и делать из них какие-то выводы

Идеология ClickHouse

- Интерактивные запросы по данным, обновляемым в реальном времени
- Стараемся заранее ничего не агрегировать
- Диалект SQL + расширения
- Нужны очищенные структурированные данные

Типичный запрос в системе веб-аналитики

Считаем для счётчика топ-10 рефереров за неделю

```
SELECT Referer, count(*) AS count

FROM hits

WHERE CounterID = 1234 AND Date >= today() - 7

GROUP BY Referer

ORDER BY count DESC

LIMIT 10
```

Как выполнить запрос быстро?

- Быстро вычисляем
  - Векторная обработка данных целыми блоками
  - Специализация и низкоуровневые оптимизации

Как выполнить запрос быстро?

- Быстро читаем
  - Только нужные столбцы: CounterID, Date, Referer
  - Сжатие
  - Отсекаем (приближенно) ненужные строки по индексу
  - Поддерживаем локальность чтения

Нужен индекс!

- Выбираем так же, как в классических БД
  - Большинство запросов будут содержать условия на CounterID и Date
- (CounterID, Date) подойдёт
  - Проверяем, мысленно упорядочив таблицу по выражению
- Особенности
  - Таблица действительно будет упорядочена по индексу
  - Не обеспечивает уникальности

Как работает индекс

(CounterID, Date)

primary.idx

	…	…
	1234	2017-05-11
N	1234	2017-06-10
N+8192	1234	2017-06-12
N+16384	1234	2017-06-15
	1235	2013-03-12
	…	…

Одна запись на гранулу – index_granularity (=8192) последовательных строк таблицы

WHERE CounterID = 1234 AND Date >= today() - 7

Как работает индекс

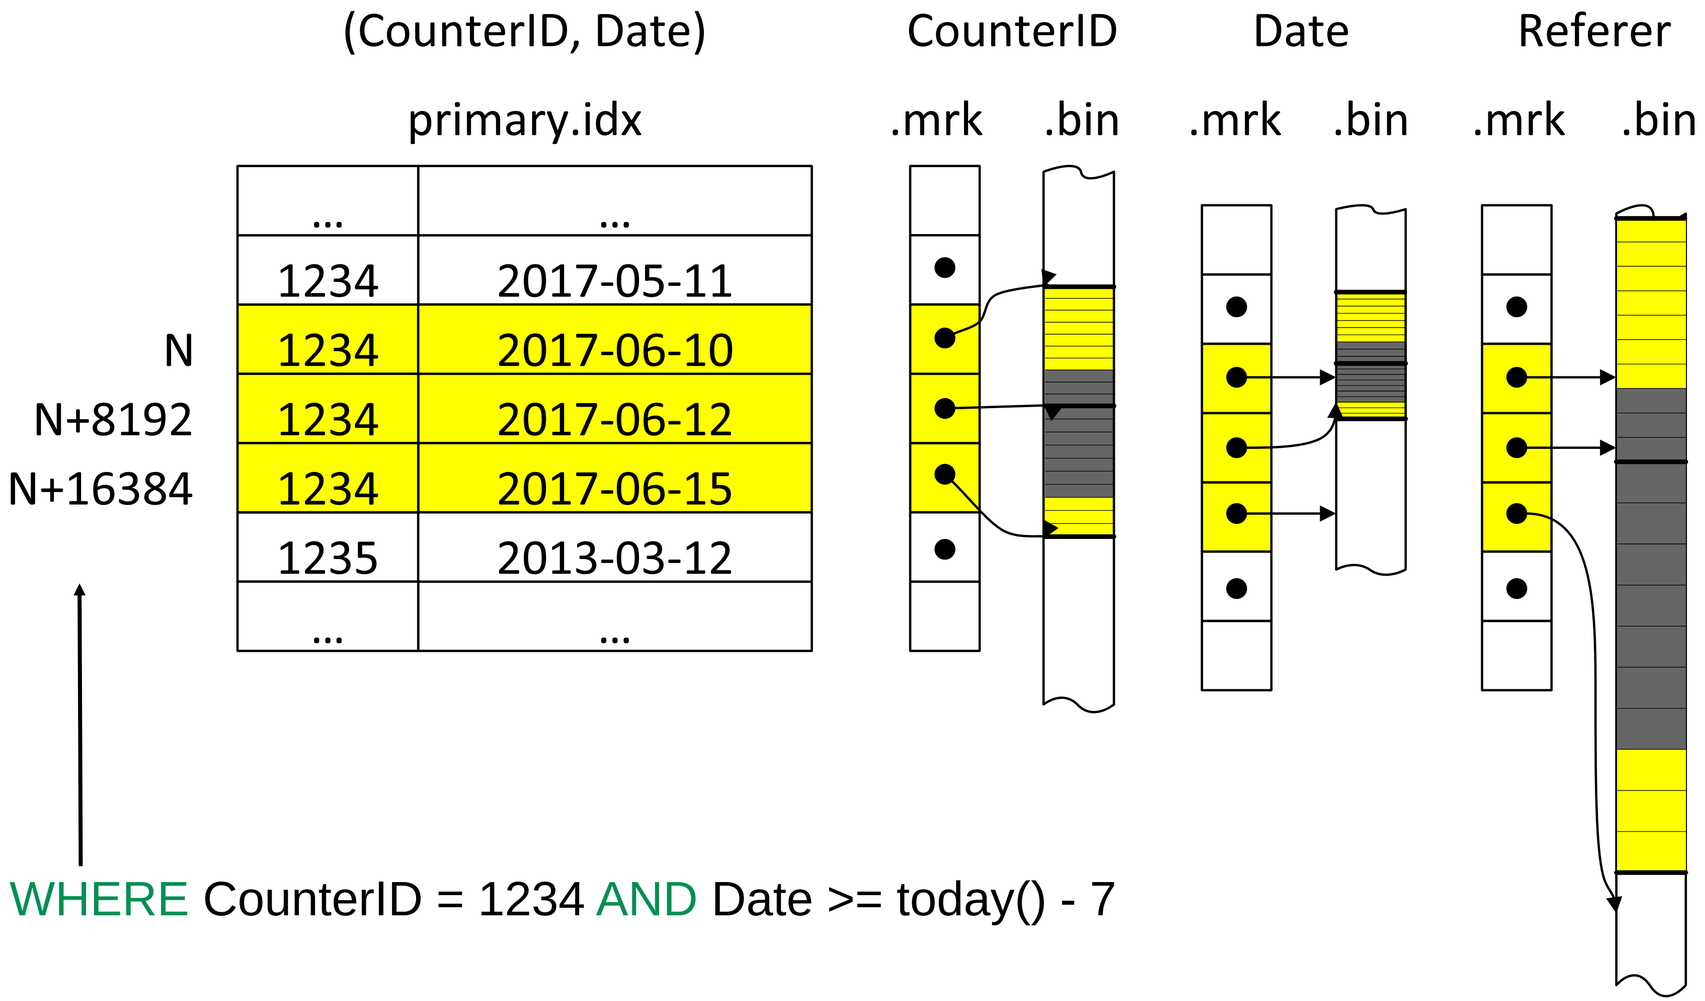

Вставка данных

Как обеспечить упорядоченность?

- События поступают (почти) упорядоченными по времени
  - А нам нужно по первичному ключу!

- MergeTree: поддерживаем небольшое количество упорядоченных кусков
  - Идея та же, что и в LSM-tree

Как обеспечить упорядоченность

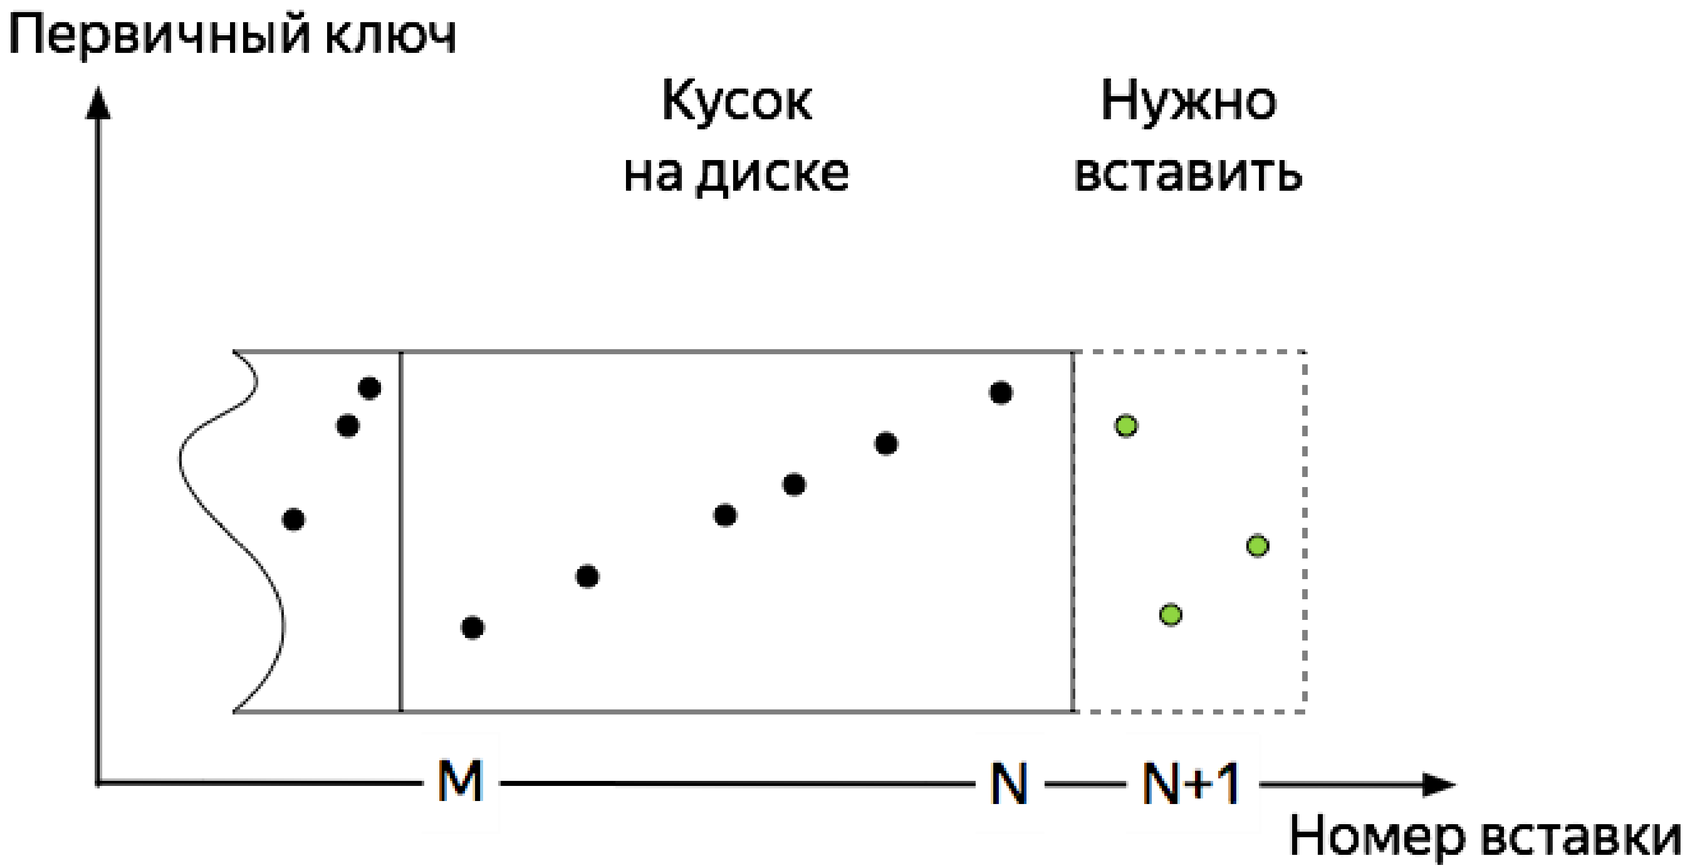

Как обеспечить упорядоченность

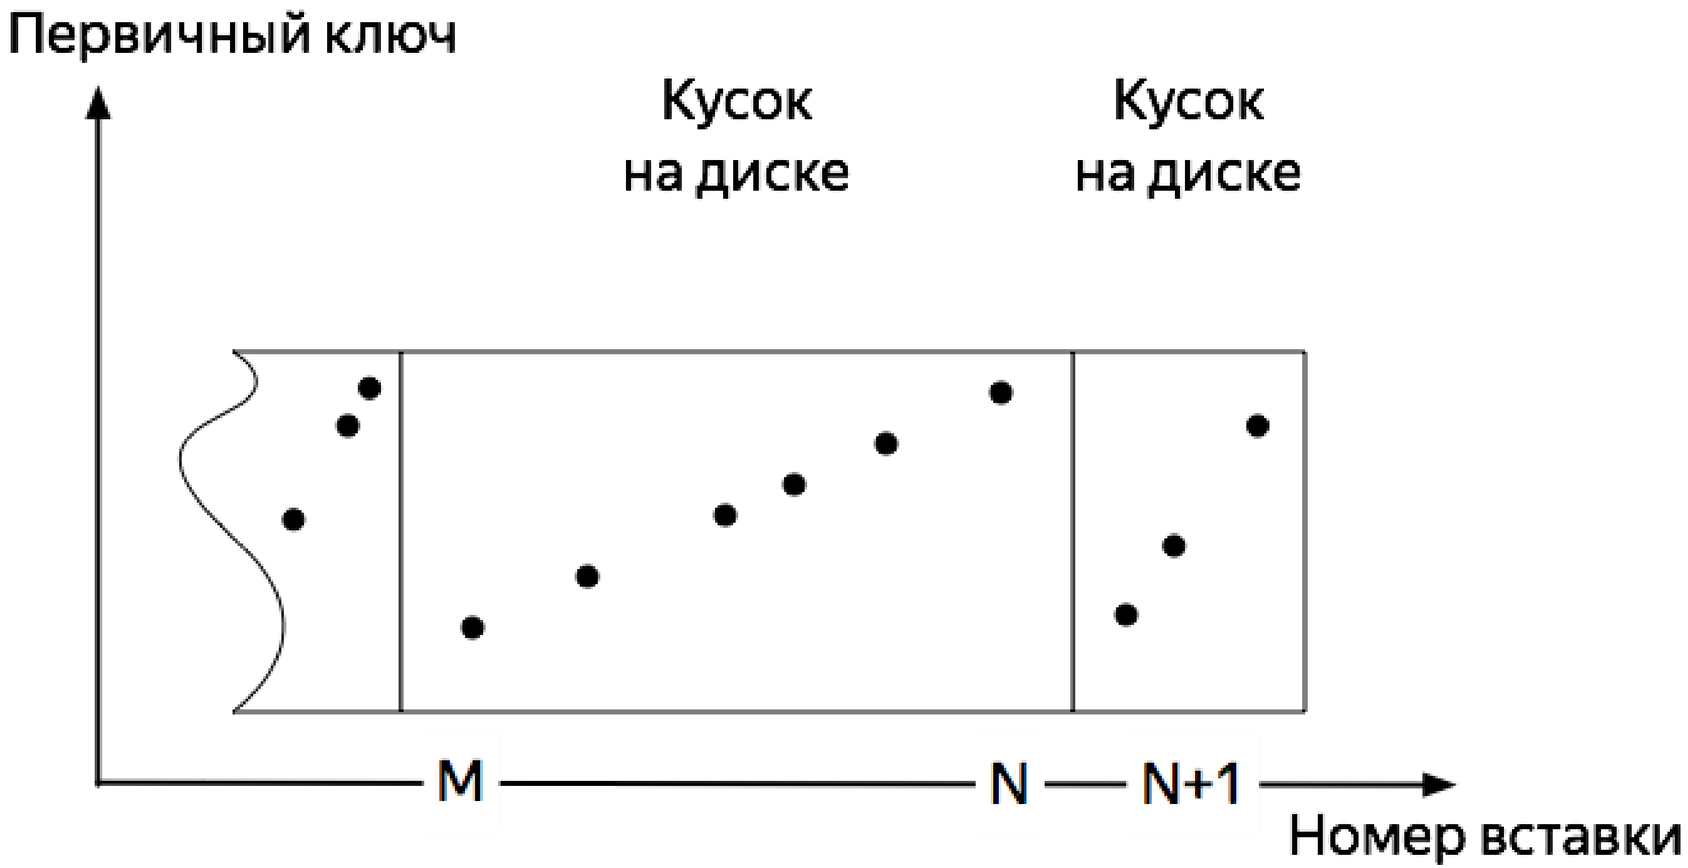

Как обеспечить упорядоченность

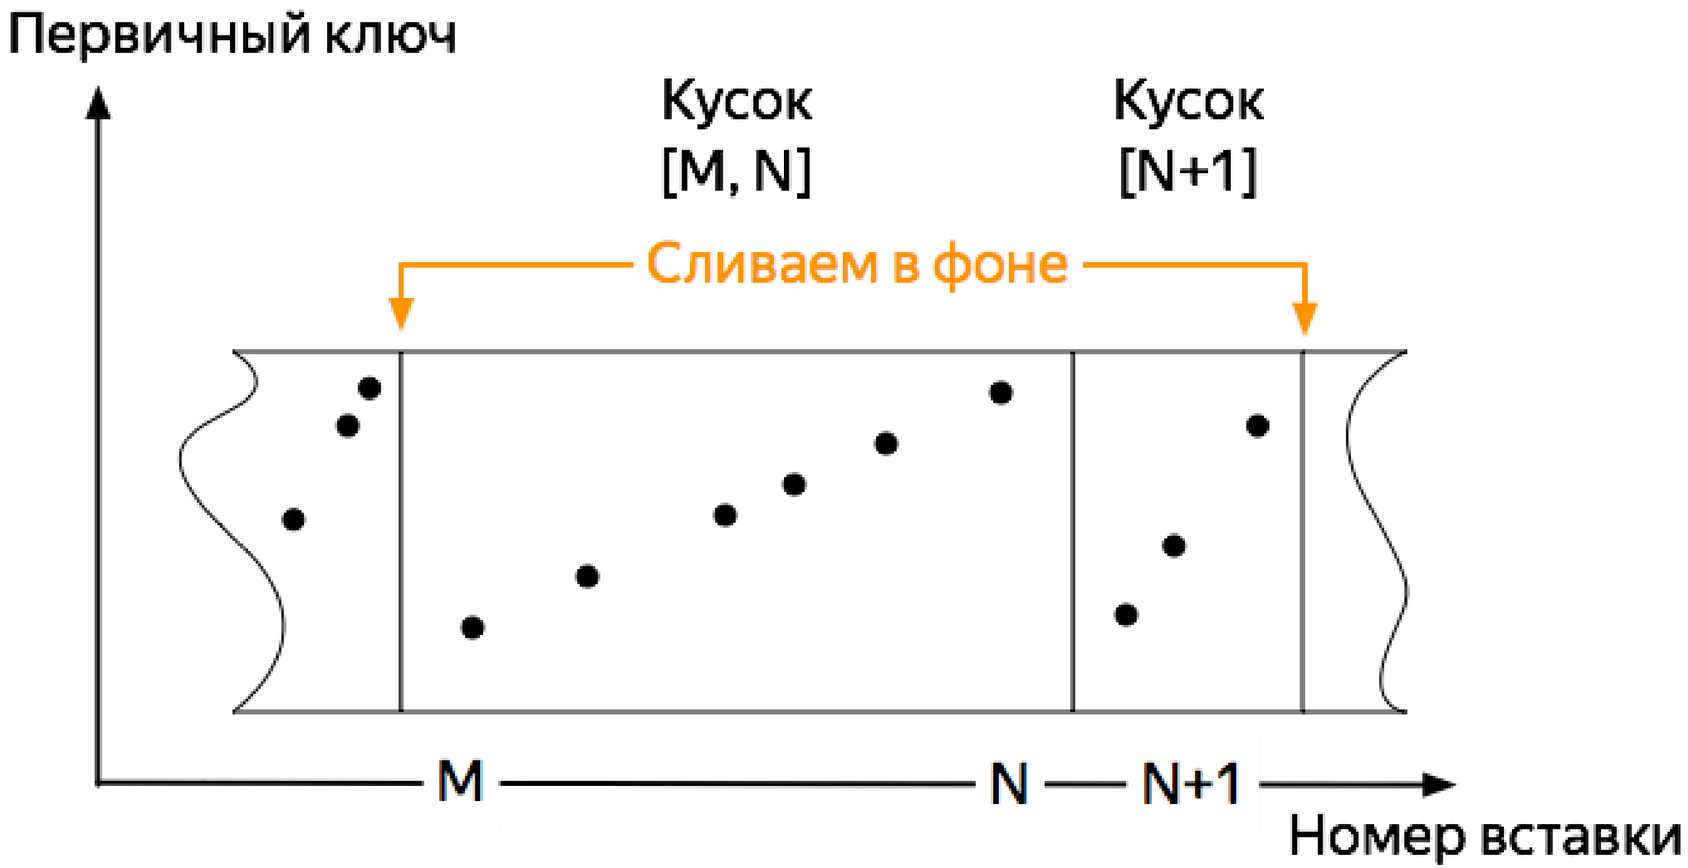

Как обеспечить упорядоченность

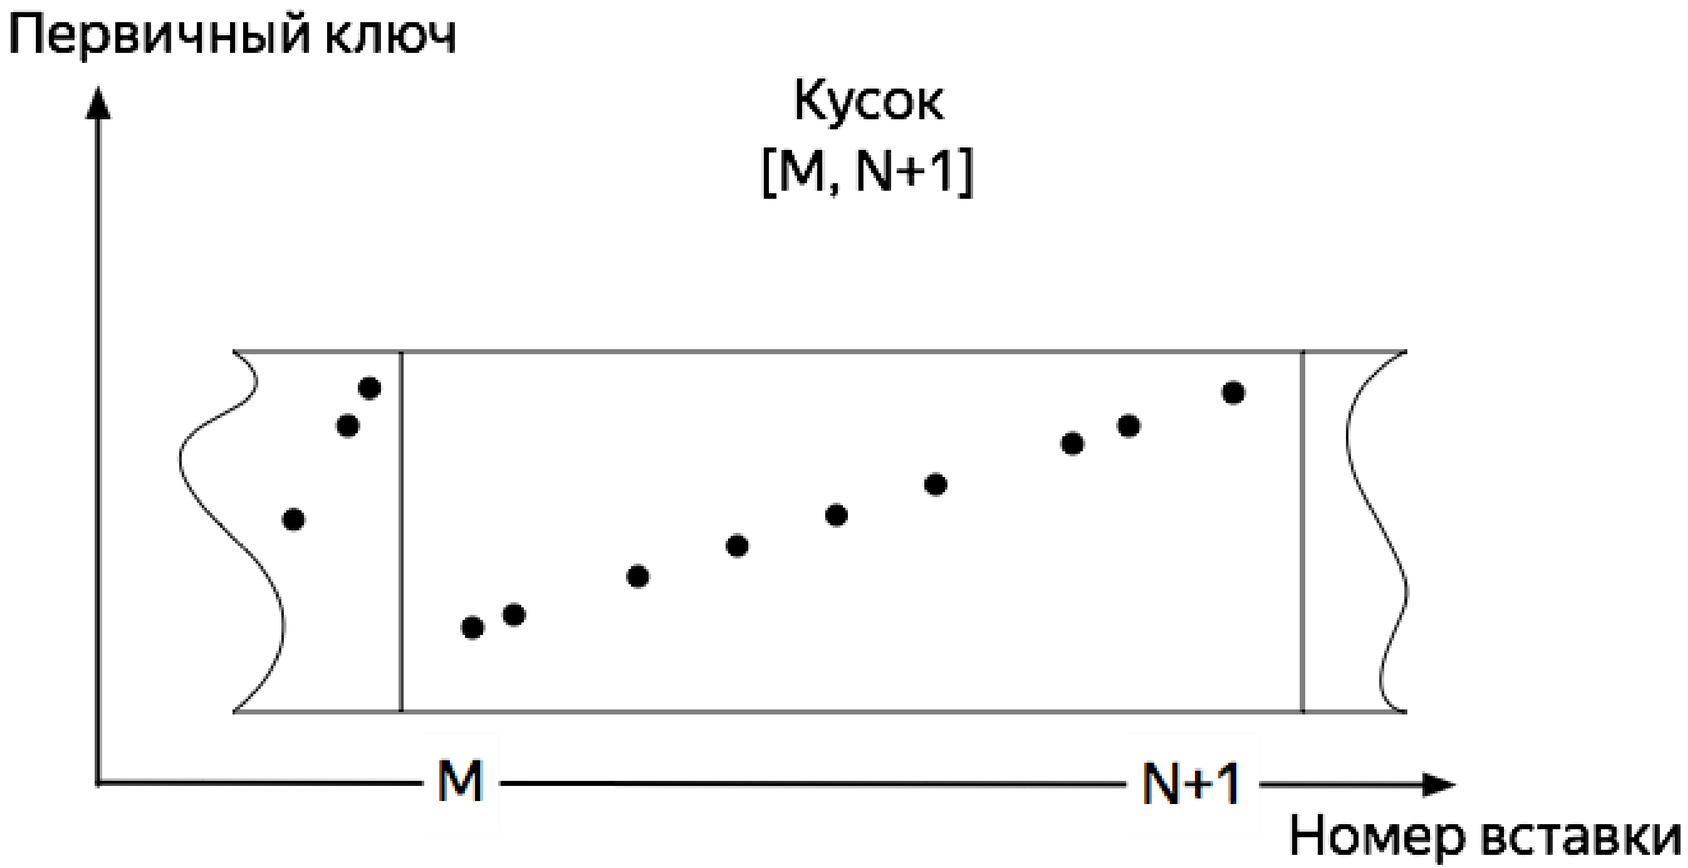

Когда одного сервера не хватает

- Данные перестали помещаться на один сервер…
- Хочется ещё ускориться, добавив железа…
- Несколько одновременных запросов мешают друг другу…

Когда одного сервера не хватает

- Данные перестали помещаться на один сервер…
- Хочется ещё ускориться, добавив железа…
- Несколько одновременных запросов мешают друг другу…

ClickHouse: Шардирование + Distributed таблицы!

Чтение из Distributed таблицы

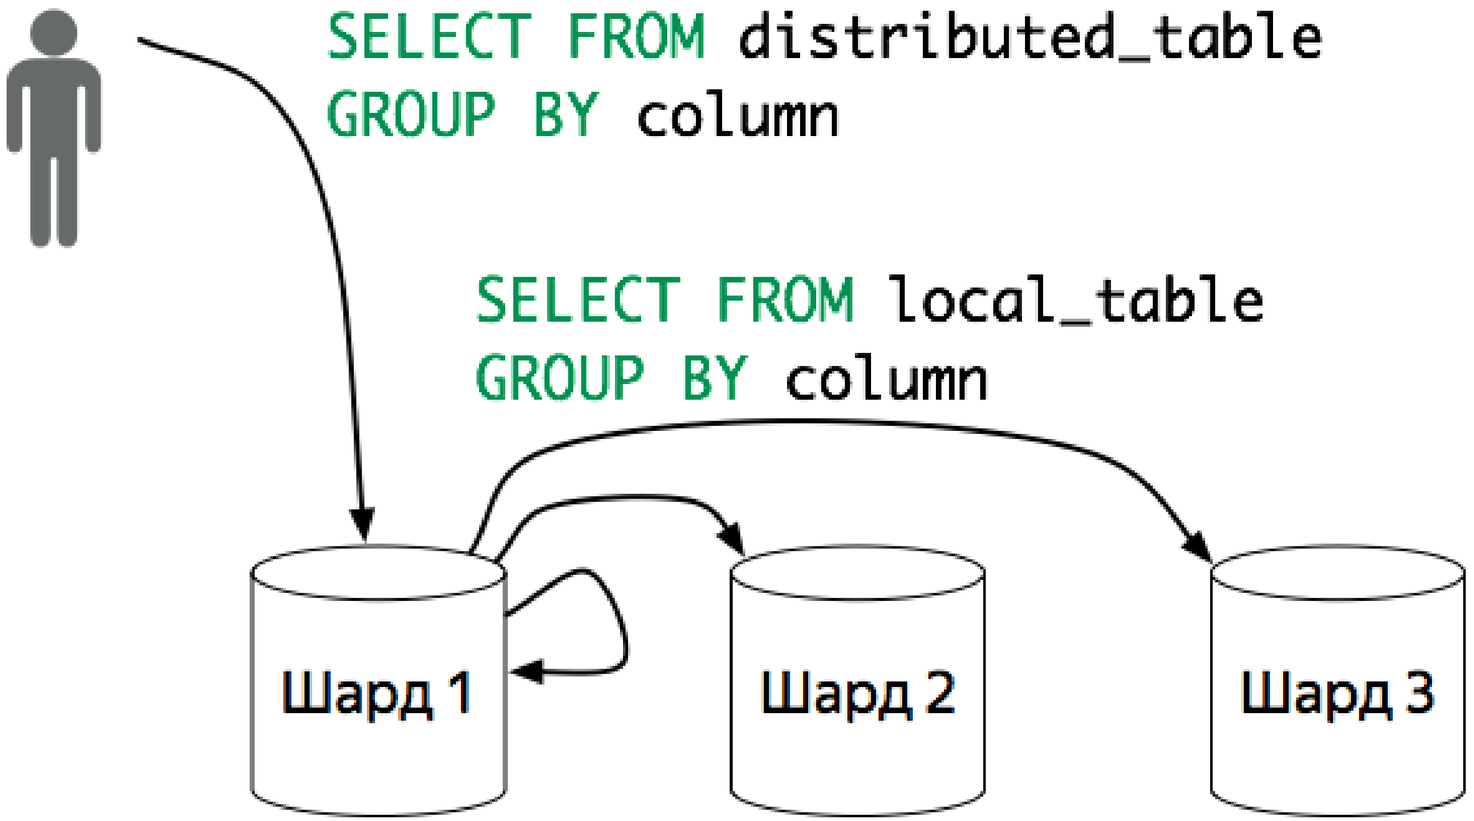

Чтение из Distributed таблицы

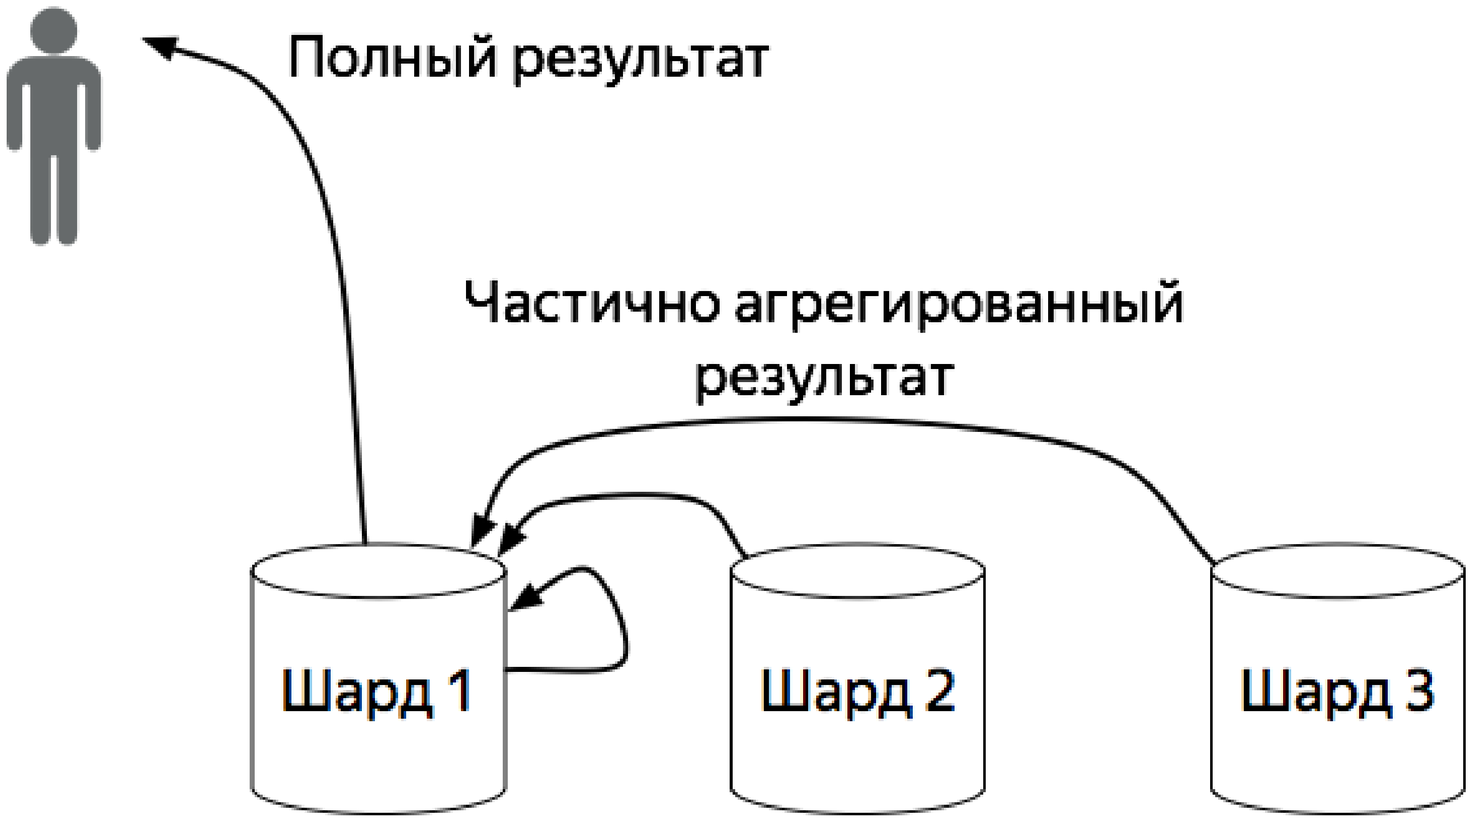

NYC taxi benchmark

CSV 227 Gb, ~1.3 млрд строк

```
SELECT passenger_count, avg(total_amount)
FROM trips GROUP BY passenger_count
```

Шардов	1	3	140
Время, с.	1,224	0,438	0,043
Ускорение		x2.8	x28.5

Запись в Distributed таблицу

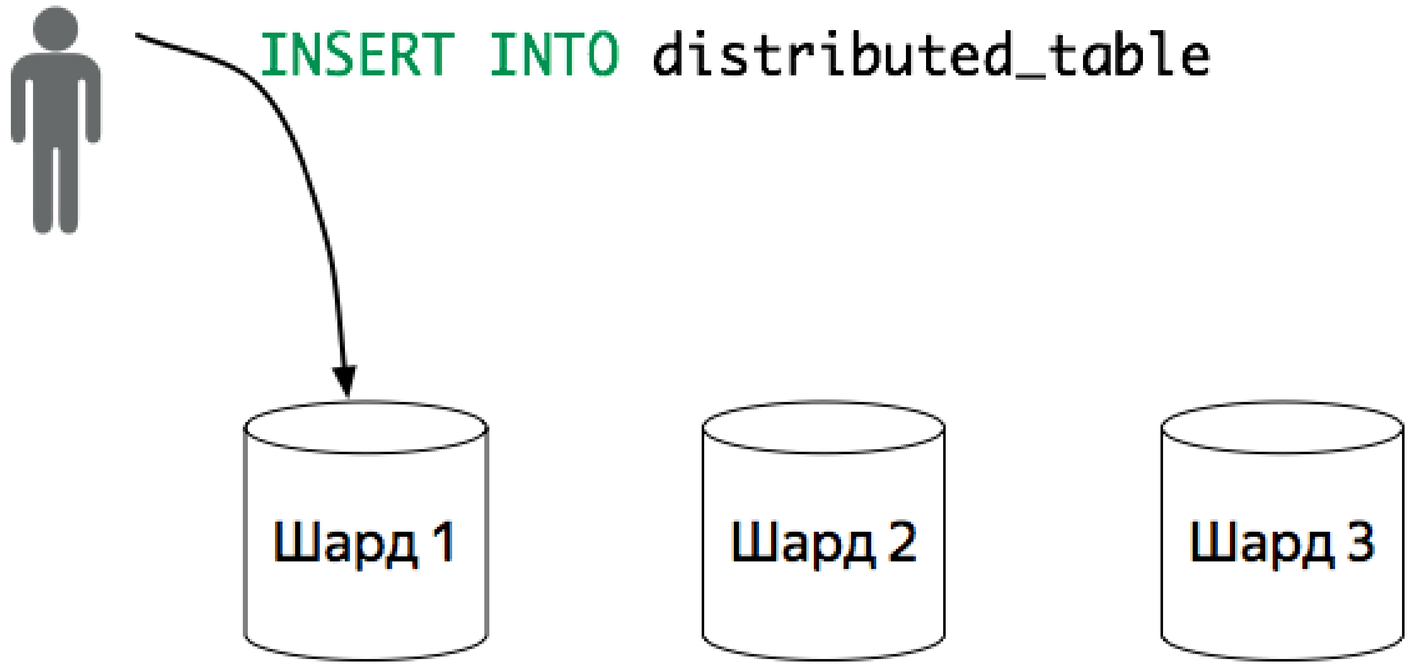

Запись в Distributed таблицу

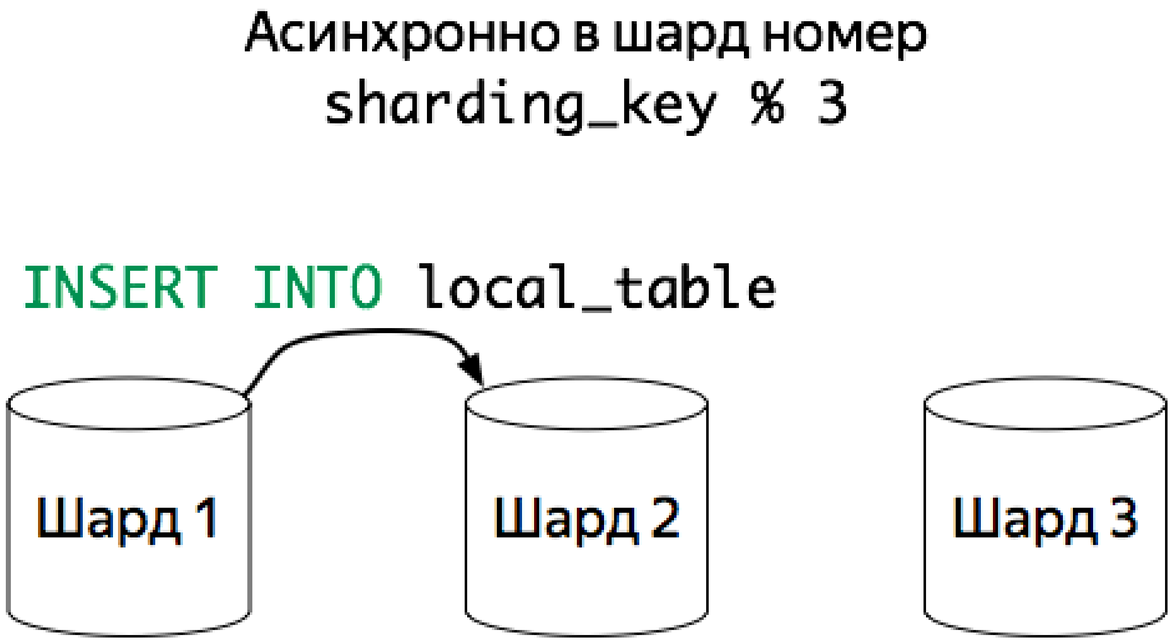

Когда нельзя ломаться

- Хочется защититься от аппаратного сбоя…
- Данные должны быть доступны на чтение и на запись…

Когда нельзя ломаться

- Хочется защититься от аппаратного сбоя…
- Данные должны быть доступны на чтение и на запись…

ClickHouse: движок ReplicatedMergeTree

- асинхронная мастер–мастер репликация
- Работает на уровне таблиц

Как работает репликация

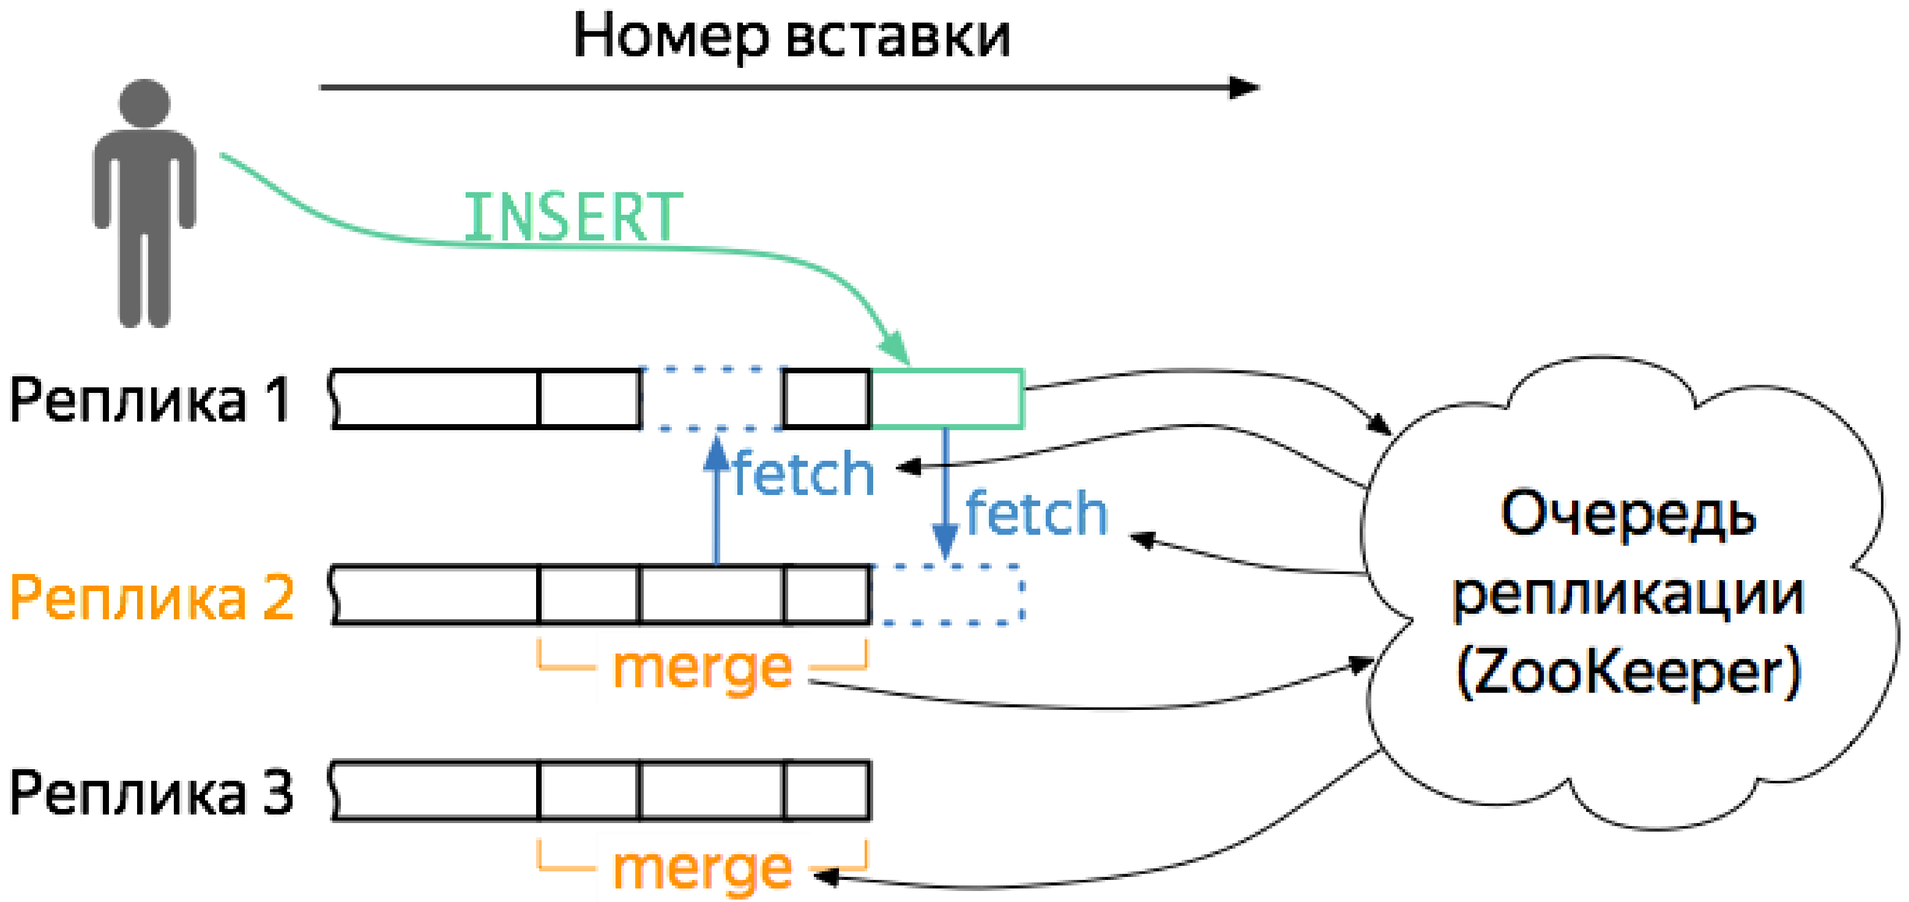

Репликация с точки зрения CAP–теоремы

Что будет в случае сетевого сбоя (partition)?

- Consistency нет!*
  Как и у любой системы с асинхронной репликацией
  * Но можно включить
- Availability (почти) есть!*
  Можно отключать один ДЦ, если
  ZK в 3-х датацентрах, а реплики минимум в 2-х.
  * Нельзя писать в сервер, отрезанный от кворума ZK

Всё вместе

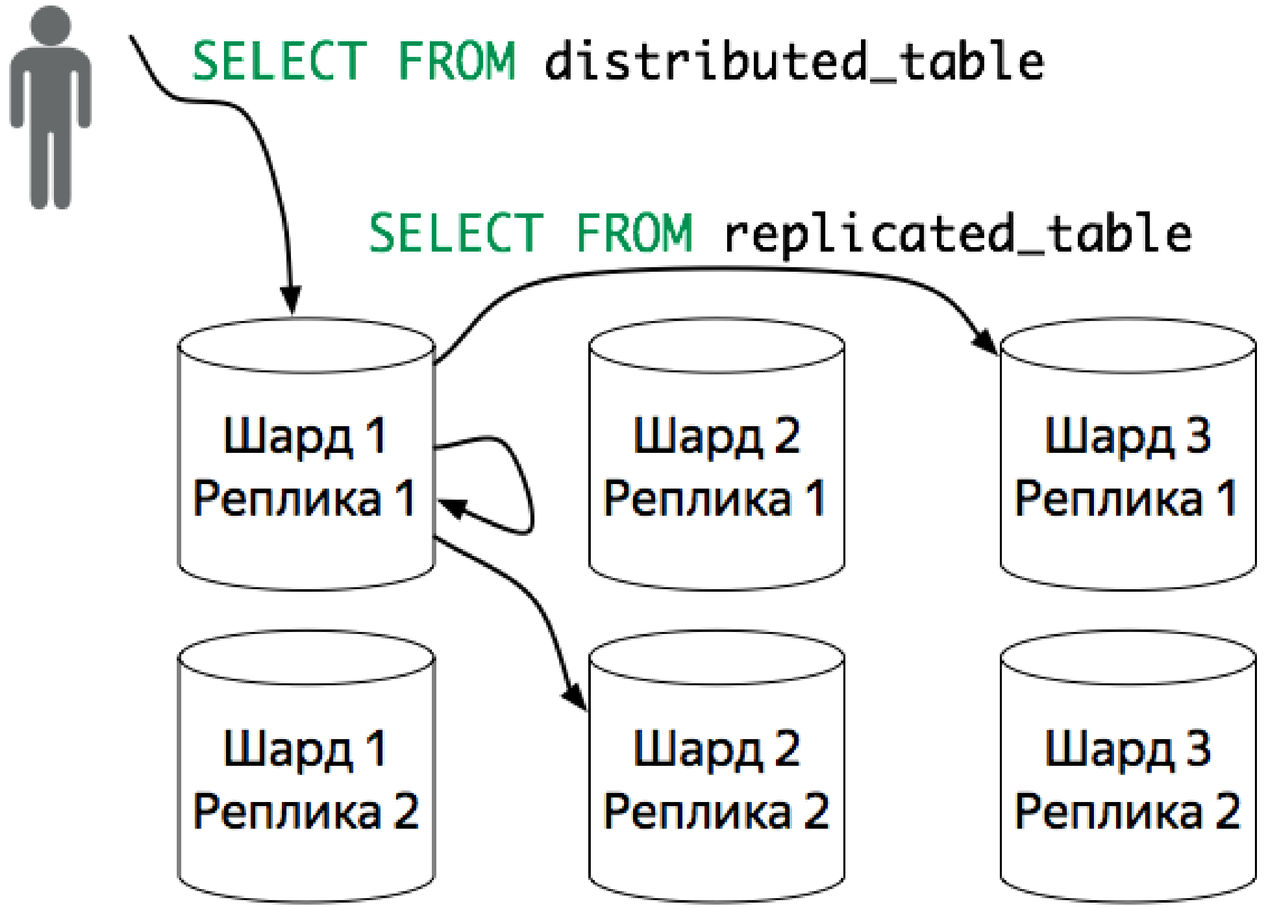
SELECT FROM distributed_table
SELECT FROM replicated_table
Шард 1
Реплика 1
Шард 2
Реплика 1
Шард 3
Реплика 1
Шард 1
Реплика 2
Шард 2
Реплика 2
Шард 3
Реплика 2

Ещё раз, коротко

- Column–oriented
- Сверхбыстрые интерактивные запросы
- Диалект SQL + расширения
- Плохо подходит для OLTP, Key–Value, хранения блобов
- Линейная масштабируемость
- Отказоустойчивость
- Open source!

Спасибо

Начните использовать ClickHouse сегодня!

Вопросы? Можно сюда:

- clickhouse-feedback@yandex-team.ru
- Telegram: https://t.me/clickhouse_ru
- GitHub: https://github.com/yandex/ClickHouse/
- Google group: https://groups.google.com/group/clickhouse