# MySQL от домашней странички до Facebook

Владимир Федорков

Владивосток 2015

лекторий Луч-5

# Правила поведения

- Скучать, сидя в аудитории из вежливости
- Мешать другим
- Пить чай и кофе
- Снисходительно посматривать на докладчика
- Заходить, выходить
- Задавать вопросы в любое время

# О докладчике

- Занимаюсь вытягиванием проектов из сложных жизненных ситуаций
- Специализируюсь на MySQL
  - И полнотекстовом поиске
- Работаю с разными клиентами по всему миру
- Все имена вымышлены, все совпадения случайны

# Три стадии развития цивилизации

- Что?
- Как?
- Где?

# Пережить первую стадию

- Придумать и сделать что-то абсолютно новое
- Сделать что говорит дядя
- Грамотно адаптировать зарубежный сервис
- Запустить в интернет уже работающий offline бизнес

# Вторая стадия: Как?

- На каком языке писать?
- Какую платформу / фреймворк использовать?
- Где хранить данные?

# Да вот так!

- Берем самую крутую платформу на сегодня
- Самый модный фреймворк
- Самое быстрое хранилище данных

# Нет, не так!

- Берем самую крутую платформу на сегодня
- Самый модный фреймворк
- Самое быстрое хранилище данных

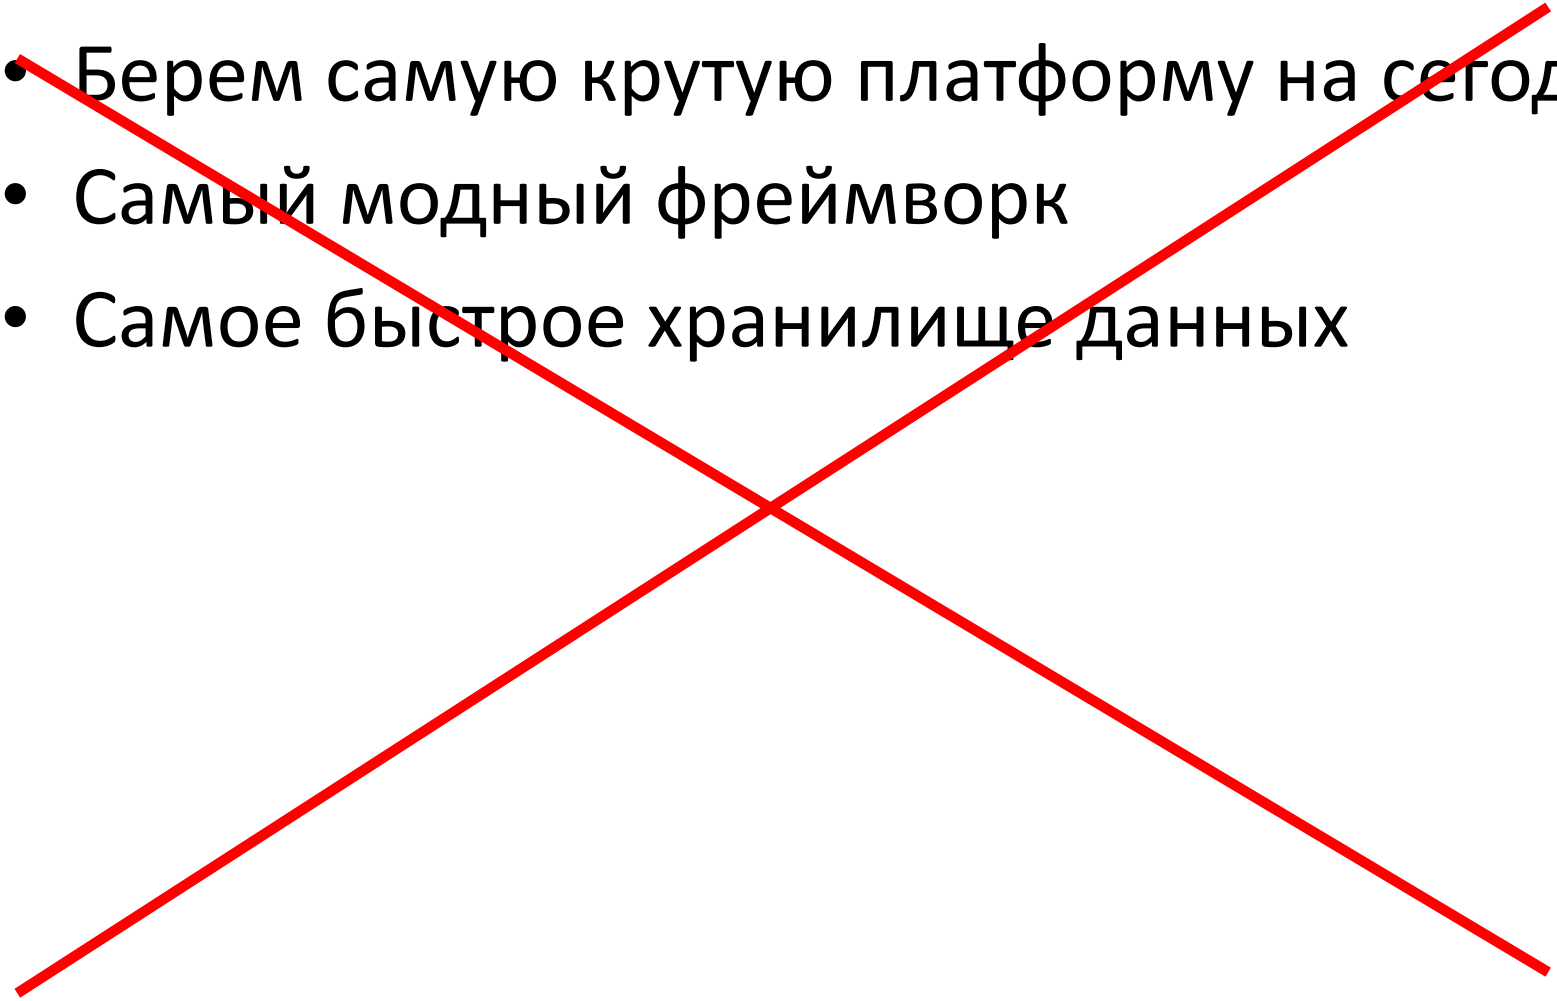

# Определяем цели

- Научиться использовать крутую технологию?
- Или сделать что-то максимально быстро?

# Смотрим вперед, ставим задачи

- Делаем первый релиз максимально быстро
  - можно из глины и соломы
- На известных, хорошо документированных технологиях
- Думаем о том как будем:
  - монетизировать трафик
  - справляться с ростом нагрузки
  - расширять команду
- ... но не очень активно, потому что может не взлететь.

# Решаем простые вопросы.

- Фокусируемся на самом больном.
- Как выбрать технологию хранения данных?
- Где хостить проект?
- Облачные вычисления или ржавые железки?

# Где хранить данные?

- Зависит от того:
  - Как данные читаются
  - Как данные записываются
  - Какие выборки используются
  - Как данные масштабируются
  - Насколько данные ценны
  - Какая нужна скорость доступа
  - Насколько важна отказоустойчивость
  - Насколько значима безопасность
  - Есть ли географическая распределенность

# Где хранить данные?

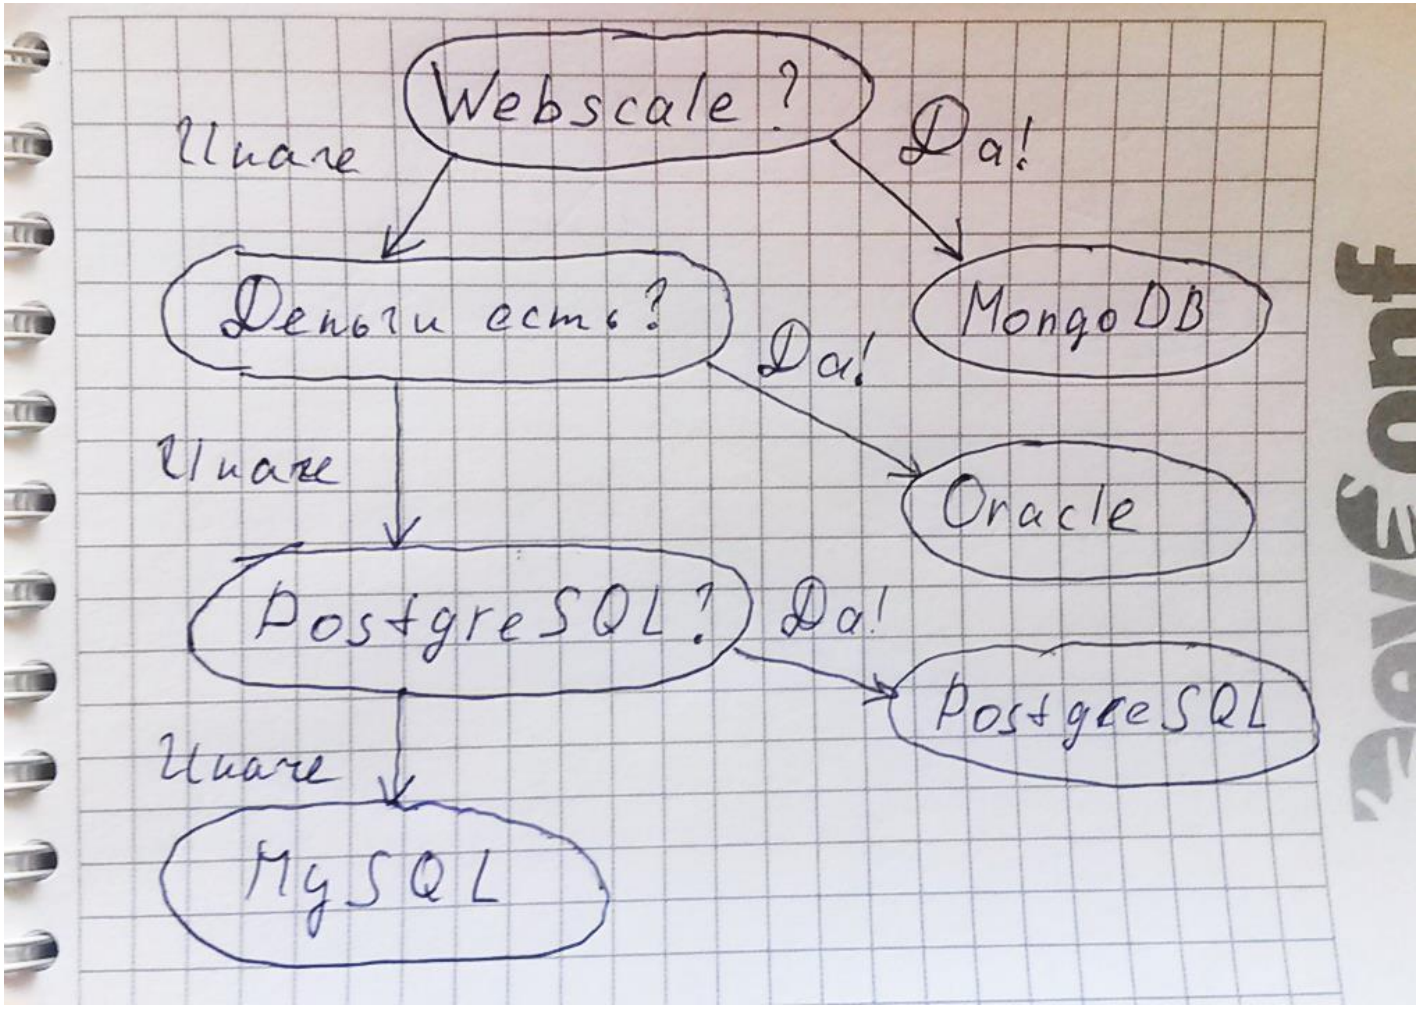

# Что такое MySQL?

- Задуман и сделан как реляционная БД
- Придуман давно
- Умеет ACID

# ACID как это есть

- A – Atomicity
- C – Consistency
- I – Isolation
- D – Durability

# ACID как мы это понимаем

- A – Все или ничего. Даже если отключат свет.
- C – Данные логически непротиворечивы. Всегда.
- I – Изменения не видны пока не закончены.
- D – Записанное можно гарантированно прочитать.

# Когда ACID может быть плохим?

# Дополнительные затраты

- Сохранение корректного состояния в любой момент времени.
  - Блокировки
  - Мультиверсионность
- Восстановление состояния после отказов.
  - Сети
  - Дисков
  - Питания

# Зачем нужен такой тюнинг?

# Там, где данные критичны

- Финансовые приложения
- Торговля (магазины и склады)
- Учебные заведения
- Хранилища документов
- … назовите сами

# Где не надо?

# Web 2.0. Весь.

- Никому не интересны посты Васи Пупкина
  - Кроме самого Васи Пупкина
    - В 95% случаях
- Дешевле вернуть ошибку
  - Вася Пупкин запостит 8915-го котика заново
- В крайнем случае восстановим из бекапа
  - Если он вдруг есть
- Или переключим чтение на другой датацентр
  - Если вы фейсбук

# Почему же все-таки СУБД?

- MySQL одна из хорошо знакомых технологий
  - Условно бесплатна
  - Стабильна
  - Хорошо документирована
  - Есть у кого узнать как правильно
  - Есть у кого купить поддержку
  - Это относится и к выбору платформы

# Как с этим жить?

- Конфигурировать
- Настраивать окружение
- Запускать и тюнить запросы
- Масштабироваться
- Использовать облако
  - или не использовать

# Конфигурация, шаг первый

- Конфигурация MySQL
  - 5% настроек обеспечивают 95% производительности
  - InnoDB наше все, MyISAM уже не наше!
- Что тюнить сразу
  - innodb_buffer_pool_size
  - innodb_file_per_table
  - key_buffer
  - server-id

# Конфигурация, шаг второй

- Сеть
  - skip_name_resolv
  - max_connect_errors
    - FLUSH HOSTS
  - max_allowed_packet
- IO
  - innodb_flush_log_at_trx_commit
  - innodb_log_file_size

# Тест «насколько админу скучно»

- max_join_size – два балла
- sort_buffer_size – пять баллов
- tx_isolation – десять баллов
- Правило 5/95 работает безукоризнено

# Путь самурайской базы

- Готовим MySQL к смерти
  - log_bin
    - Для point-in-time recovery
    - Желательно на другой диск
  - expire_logs_days
  - max_binlog_size
  - sync_binlog
    - Если некуда девать производительность B/B
    - Или если данные очень нужны

# Ура, сконфигурили!

- Правильные настройки
  - не мешают работе MySQL
  - обеспечивают отказоустойчивость
    - только на уровне операционной системы!
  - не обеспечивают его производительности
- Допустим все работает

# Запросы

- Обеспечивают 99,99% тормозов
  - И головную боль админов
- Лучший MySQL запрос тот который до MySQL не дошел.
  - MySQL не сможет выполнить некоторые запросы быстро
  - Просто потому что так спроектирован

# А что с ним не так, турецкий?

- Ограничение дизайна MySQL
  - ACID медленный!
  - B-Tree работает только для спец. случаев
  - Запрос обрабатывается одним ядром
  - Есть Full-text индексы, но они медленные
  - Про репликацию можно говорить часами
    - Что и делаем на собеседованиях
  - Если вышеперечисленное для вас большая проблема – вы используете неправильный инструмент. Вам нужен не MySQL.
    - Если вы не FaceBook.

# Как написать тормозной запрос?

SELECT * FROM table …

- WHERE DAY(FROM_UNIXTIME(`ts`)) = 205
- WHERE deleted != 1
- WHERE id NOT IN (1,2,3,…,10)
- WHERE url LIKE ‘%чтототам%’
  - Не путать с LIKE ‘чтототам%’ !
- ORDER BY RAND()

# Чем плох full table scan?

- Индексы не помогают!
  - Значение функции считается для всех строк
  - B-Tree не эффективен
- Читать всю таблицу долго
- Пока читаем, вымываем память базы ненужными данными
- Как бороться?
  - Пересматривать логику запросов
  - Использовать предварительно аггрегированные данные вместо расчета функций «на лету»
  - Использовать deleted = 0 вместо deleted != 1

# Высокоселективные запросы

- SELECT * / COUNT(*)
  FROM users WHERE sex='female'
  - Здравствуй, половина таблицы
- Как бороться?
  - Читаем только то, что показываем
    - Используем LIMIT
  - Делаем агрегацию для счетчиков
  - Кешируем все, что можем
    - Не в MySQL query cache!
  - Используем внешние инструменты (Mongo, Sphinx, etc)

# Временные таблицы

- Плохо
  - Если попадает на диск – очень плохо!
    - Если есть поля TEXT или BLOB, на диск таблица попадет
- Когда создаются
  - GROUP BY
  - Подзапросы
  - DISTINCT + ORDER BY

# Что делать?

- Тюнить буфферы временных таблиц
  - tmp_table_size
  - max_heap_table_size
- Запускать «тяжелые» запросы на отдельной реплике
  - Например, для генерации отчетов

# Если нагрузка большая

- Query cache
- Thread cache
- Table cache
- Slow query log
- wait_timeout
- connection pooling
- Репликация и шардинг

# КАК ПЕРЕЖИТЬ АПОКАЛИПСИС?

Владивосток 2015

ASTELLAR.COM

# От сервера кластеру

- Один сервер мало, два – плохо.
  - Репликация медленная
    - Работает в один поток (исправили в 5.6)
  - Репликация хрупкая (не исправили в 5.6)
  - Доверия репликации нет
    - Консистентность данных требует проверок
      - Даже если видимых сбоев не было
      - pt-table-checksum + pt-table-sync
- Есть варианты
  - Tungsten и Galera

# Прелести кластера

- Если у тебя упал единственный сервер, это трагедия
  - А если один из десяти?
- Можно использовать реплики для бекапа
- Можно балансировать нагрузку
  - Можно (нужно) сделать реплику для генерации «тяжелых» отчетов

# Что еще умеет кластер

- Встать колом весь от вовремя запущенного ALTER TABLE
- Эффектно среплицировать команду DROP DATABASE
- С разной скоростью выполнять одинаковые запросы на разных нодах

# Ежедневная рутина

- Отказы железа
- Баги софта
- Надежные бекапы и восстановление
- Мониторинг
- Апгреды и настройка репликации
- Настройка сети и безопасности

- Можно ли это все автоматизировать?

# БЕЛЫЕ ОБЛАКА ПРОТИВ РЖАВОГО ЖЕЛЕЗА

# От кластера к облаку

- На примере Amazon RDS
  - Relational database service
- MySQL, Oracle & MSSQL
  - Был MySQL 5.5 и есть 5.6
- Что позволяет?
  - Создавать/удалять ноды и реплики
  - Выделять реплики из кластера
  - Автоматизировать развертывание БД и фронтов
    - Вплодь до полного скриптования

# Что это значит для нас?

- Полностью автоматизированное развертывание приложение с использованием RDS и EC2
- Гибкий контроль производительности и стоимости с помощью добавления и удаления машин
  - В зависимости от времени дня
  - В зависимости от текущей нагрузки
- Изменение параметров кластера на лету

# Что сделать не получиться?

- Зайти на RDS инстанс по SSH
- Починить репликацию
- Сделать бекап с помощью xtrabackup
  - Только mysqldump, только хардкор

# Что мы можем контролировать?

- Выбирать регион для инстанса
- Конфигурировать MySQL
- Выбирать тип инстанса
- Открывать/закрывать доступ по сети
- Выбирать параметры дисковой подсистемы

# Регионы и availability zones

- US
  - East 1 (Northern Virginia)
  - West 1 (Northern California)
  - West 2 (Oregon)
- EU: Ireland, Frankfurt
- China: Beijing
- Asia Pacific: Singapore, Tokyo, Sydney
- South America: São Paulo

# Availability zone

- В каждом регионе нескольк AZ
- Можно сделать AZ мастер
  - Поможет в случае креша основного мастера
    - Репликация может быть сломана

# Storage

- SSD & Magnetic диски
  - Полностью разные архитектурно и физически
- Вы в облаке

# RDS Sizes

| Instance Type | vCPU | Memory (GiB) | PIOPS-Optimized | Network Performance |
|---|---|---|---|---|
| **Standard - current generation** | | | | |
| db.m3.medium | 1 | 3.75 | - | Moderate |
| db.m3.large | 2 | 7.5 | - | Moderate |
| db.m3.xlarge | 4 | 15 | Yes | Moderate |
| db.m3.2xlarge | 8 | 30 | Yes | High |
| **Memory optimized - current generation** | | | | |
| db.r3.large | 2 | 15 | - | Moderate |
| db.r3.xlarge | 4 | 30.5 | Yes | Moderate |
| db.r3.2xlarge | 8 | 61 | Yes | High |
| db.r3.4xlarge | 16 | 122 | Yes | High |
| db.r3.8xlarge | 32 | 244 | - | 10 Gigabit |
| **Burstable performance instances** | | | | |
| db.t2.micro | 1 | 1 | - | Low to Moderate |
| db.t2.small | 1 | 2 | - | Low to Moderate |
| db.t2.medium | 2 | 4 | - | Low to Moderate |

# Настройка MySQL: Parameter groups

- Содержит все возможные настройки MySQL
- Дефолтные настройки не оптимальны
  - Нужно создать свою группу и поменять как надо
  - Число PG не бесконечно
- Некоторые настройки поменять нельзя
- Статические и динамические настройки почти как в «родном» MySQL

# Добро пожаловать в облако!

- Железо можеть быть разное
  - Даже на каждом запуске бенчмарков
- IO зависит от сети
- Стоят ограничители CPU & IO
- Ты не знаешь своих соседей

# Как жить?

- Всегда ориентируемся на худший случай
- Максимально уменьшить нагрузку на IO
  - Перейти на PIOPS (SSD) где возможно
- Агрессивный шардинг наш друг и верный друг и товарищ
- Внимательно следить за
  - нагрузкой на CPU/IO
  - Использованием памяти
  - Вовремя обнаруживать битые реплики

# Что есть хорошего?

- Можно смотреть логи
- Точность в логах запросов до микросекунд
- Есть MySQL 5.6
- Есть зачаточный мониторинг
- Есть попытки автоматического восстановления репликации

# Когда использовать облако?

- Когда не очень много данных
  - Или когда вы можете их зашардить
- Когда сложно предугадывать нагрузку
- Когда быстро нужно много ресурсов
  - Или когда ресурсы нужны ненадолго
- Когда не хватает рук для администрирования

# Как с этим всем живут гиганты?

- Строят свои датацентры и каналы
- Содержат команды инженеров и программистов
- Переделывают MySQL под свои нужды
- Меняются патчами и публикуют их
  - Можно их найти и использовать
- Но если Вы не Твиттер, не Фейсбук и не Google, переживать Вам пока рано!

# Что дальше?

- Twitter @vfedorkov, vk.com/vftimes
- Посмотреть другие доклады на astellar.com
- Прочитать книги
  - “High Performance MySQL”
  - “MySQL Troubleshooting”

# ВОПРОСЫ!

# СПАСИБО!