

# Avito.ru

## Объявления и Postgres

[mtyurin@avito.ru](mailto:mtyurin@avito.ru) // we are hiring

Тюрин Михаил  
главный системный архитектор



<http://www.devconf.ru>



Сайт бесплатных объявлений №1 в России\*

Авто, недвижимость, работа, услуги, техника, одежда и многое другое. На сайте **31 641 046 объявлений**.

Личный кабинет ▾  
Вход и регистрация

[Подать объявление](#)

Найдите объявление в своем городе

Свяжитесь с владельцем объявления

Совершите сделку!



АВТО



НЕДВИЖИМОСТЬ



РАБОТА



УСЛУГИ

[Все категории](#)


## Москва

Санкт-Петербург  
Волгоград  
Екатеринбург  
Казань  
Краснодар  
Нижегород

Пермь  
Ростов-на-Дону  
Самара  
Уфа  
Челябинск

Адыгея  
Архангельская обл.  
Астраханская обл.  
Башкортостан  
Белгородская обл.  
Брянская обл.  
Владимирская обл.

Мордовия  
Московская обл.  
Мурманская обл.  
Ненецкий АО  
Нижегородская обл.  
Новгородская обл.  
Оренбургская обл.



Любая категория  Поиск по объявлениям Москва  Станция метро  Найти

искать только в названиях  только с фото

Все объявления в Москве 6 274 998

Личные вещи 1 864 423    Для дома и дачи 674 297    Для бизнеса 171 149    Животные 81 308  
Транспорт 1 763 094    Бытовая электроника 484 616    Услуги 150 209 **NEW**  
Хобби и отдых 687 178    Недвижимость 297 934    Работа 100 790

**НОВЫЕ ОБЪЕМЫ!**

5 мин. до м. Раменки  
Квартиры бизнес-класса  
Выдача ключей

Посмотреть  
цены

ООО «НДВ Москва».  
Проектная  
декларация  
на сайте  
[www.ndv.ru](http://www.ndv.ru)

Все Частные Компании



По дате



★ **Xeon Quad X5550 LGA 1366 3.06GHz Turbo 6.4GT/s**

2 000 руб.

Товары для компьютера  
м. Калужская  
Сегодня 00:53



★ **Продавец цветов, выездная торговля**

30 000 руб.


Вакансии  
ООО "Дорога цветов"  
Сегодня 00:53



★ **Weltmeister stella 3/4**

9 500 руб. 

Музыкальные инструменты  
м. Тушинская  
Сегодня 00:53



★ **Картина 40x40 см. Холст, масло**

## VIP-объявления



**Монтаж и реконструкцию  
кровли**

350 руб.

Частное лицо



hi!

[avito.ru](http://avito.ru) — «большой» мобайл и веб

- разработка с 2007-ого, активная фаза с 2010-го
- я, Михаил Тюрин, в компании с 2009-го (6 лет — похлопаем!)
- сейчас — я главный системный архитектор
- вырос из команды четырех первых третьих программистов
- сейчас большой департамент (на целый этаж)
- работаю с:
  - директором по разработке, девопс директором, dwh
  - тимлидами и ведущими разработчиками
  - командой баз данных (**Postgres**)

## я в проекте **практически** с самого начала

- первая группа: php + свой\_фреймворк + mysql
  - доисторические времена
- вторая группа: php + (postgres + **tsearch2**)
  - прототип почти был готов
- **третья группа:**
  - php + postgres
  - + Sphinx
  - и первый теле-трафик. теле. трафик!

## я много всего знаю про то, как устроен Avito

- при чем тут postgres? – а с него всё началось!
  - первое, во что уперлись
  - но был опыт:
    - pg 7.4 – 8.2, **pg\_upgrade** (formerly called pg\_migrator)
    - sql/**plpgsql**
    - **hstore**
    - skytools: londiste (**pgq**), **plproxy** и **walmgr**,
    - php и memcached
    - **pgbouncer**
    - немного тюнить могли
    - знал по переписке Олега Бартунова

## задавайте мне потом вопросы

- далее:
  - Sphinx
  - ну и как всё это индексировать?!
  - база начала расти
  - первая логическая репликация
    - skytools londiste
    - materialized view и deferred triggers
    - hstore
  - лучше научились тюнить
    - work\_mem
    - «хинты» планеру
    - shared\_buffers

## МНОГО ВОПРОСОВ

- далее:
  - pgbouncer
  - начали писать свой класс db на php
  - первая очередь для писем
  - первый демон на php (skytools)
  - много кода на plpgsql

## про связь postgres со всеми частями системы

- далее:
  - база растет
  - не успеваем индексировать
  - придумали параллельную индексацию
  - и материализованный снимок (repeatable read)
- и тут еще и очередь модерации

## СВЯЗЬ С ПОИСКОМ И ВЕБОМ

- далее:
  - база растёт
  - на логическую реплику переносим выдачу
  - появилось первое нормальное железо
    - psi raid bbu cache
    - raid10 15K hdd

## про тюнинг всего и вся

- далее:
  - база растёт
  - вводим ещё один мастер – вертикальный шардинг
  - часть отчетов начинаем переносить на стендбай
  
- индекс бек-офиса – **ВСЕ** объявления на Sphinx

## про надежность и архив и восстановление

- далее:
  - база растет
  - появляется **ХОТ** стендбай
  - часть выдачи переносим на хот стендбай
  - собственный архив (PITR)
  - отчеты считаем на отдельной машине из восстановленного бекапа
- тюним дальше shared\_buffers и checkpoint
- начали тюнить linux

## про fsync и tmpfs

- далее:
  - база растёт
  - личный кабинет в tmpfs
  - в tmpfs
  - async commit
  - raid cache — write 146%

## а какой у вас планировщик io и fs, почему?

- далее:
  - база растёт
  - авито начал много зарабатывать
  - организуется dwh система (vertica \$\$\$)
  - планируем варианты интеграции
    - отгрузка по времени
    - материализованные дельты
      - внутри мастера
      - и на логической реплики

## а какие очереди и почему pgq?

- далее:
  - база растёт
  - нужно развивать асинхронные механизмы работы с данными
  - асинхронные
  - pgq
  - хгрс
  - хгрсd — базы вызывают друг друга и php

## какие размеры и нагрузки и чем мониторите?

- далее:
  - база растёт
  - новое железо и \$\$D
  - ssd — хороши
    - быстрые ооочень
    - очень!
    - много iops
    - много место в мало юнитах
    - ещё больше bbu cache — 2GB

## какие сервера и сколько? а под базы?

- далее:
  - база растет и трафик всё это время тоже рос
  - и кол-во фич росло
  - ! но активная часть итемов не зависит от времени
- геокодинг ходит асинхронно в Яндекс
- не успеваем индексировать — отказываемся от снепшота, ставим репликацию на паузу перед индексацией, после возобновляем

## как и где храните картинки, на дисках?

- далее:
  - база растет
  - xdb: 16 нод кластер rproху (16 баз, 8 физ машин)
  - + опять пригодился rgbouncer как роутер

## как часто всё падает, где и почему?

- далее:
  - база и кол-во проектов растет
  - еще раз вертикально шардим второй мастер
    - кончилось место
    - через стендбаи
  - проект «хвоста»: продуктово ограничили ЖЦ объявления по времени

## а как вы выкатываете код хранимоек?

- далее:
  - база растет всегда — это с начала и очень на долго поражает
  - но потом привыкаешь и к этому
  - тюним вакуум и **bgwriter**
  - **реиндекс (concurrently)**

# я опоздал, а почему не mysql?

- так где же всё таки лежат объявления (и деньги)
  - **postgres**
    - мастер базы
      - и личный кабинет в tmpfs
    - хот-стендбаи (и архив)
    - реплика сайта и реплика индексеера
    - dwh лог (etl очередь)
    - xdb кластер
  - **sphinx**
    - индекс сайта
    - индекс бекофиса
- redis, memcached
- rabbitmq
- tarantool
- fluentd, mongodb
- vertica
- aaaaaaaaaaaaaaaaaaaaaa

## ВЫ ТАК МНОГО ВСЕГО СДЕЛАЛИ, НО ВСЁ РАВНО ТЕРЯЕТЕ ТРАНЗАКЦИИ?!

- да!
- МЫ ТЕРЯЕМ НЕСКОЛЬКО ТРАНЗАКЦИЙ ДВА РАЗ В ГОД В СЛУЧАЕ АВАРИЙ
- потому что мы пока так решили для себя cap теорему
- в случае аварии переключаемся на резерв и
- !!! делаем процедуры восстановления
  - обобщенный UNDO лог в londiste
  - специфические процедуры для других связанных узлов

## спасибо! вопросы!

- теперь можно пролистать всё быстро заново и задавать вопросы
- делиться впечатлениями
- наверняка я про самое интересное и не упомянул

<http://www.slideshare.net/ssuserdc9298/pgconf-2015-avito-postgresql>

<http://www.slideshare.net/ssuserdc9298/pgconf-2015-avito-recovery2>

Миша

[mtyurin@avito.ru](mailto:mtyurin@avito.ru)

we are hiring

я часов до 5-ти тут  
могу говорить много часов  
следите за анонсами митапов в Авито