

# **BIG DATA В МЕДИА: ИНФРАСТРУКТУРА АНАЛИТИКИ НА OPEN SOURCE РЕШЕНИЯХ**

Владислав Денисов



# SPORTS.RU

Спортс – digital-издательство для неравнодушных к спорту

MAU

**20 млн**

уникальных пользователей

DAU

**1,5 млн**

уникальных пользователей

SOCIAL MEDIA

**8 млн**

уникальных пользователей

У нас огромное число UGC-контента, мы снимаем фильмы, создаем игры и много чего еще



здесь подробнее про нас

# ДАННЫЕ В SPORTS.RU

Ключевые для бизнес-логики

Спортивная статистика  
(~ 3k событий на матч)

Новости и материалы (~ 3k в месяц)

Активность пользователей:  
комментарии (до 80k в сутки),  
рейтингование (до 250k в сутки)  
и подписки

Картинки  
и другие медиа-файлы

# ДАННЫЕ В SPORTS.RU

Аналитические

Кликстрим: ежедневно +50 ГБ  
сжатых данных о взаимодействии  
пользователей с сайтами,  
приложениями и другими сервисами

Экспорты из разных платформ  
(реклама, CRM, технический  
мониторинг и т.д.) для обогащения  
отчетов

# КОМАНДА

- 4 «data fullstack» человека
- Нет разделения по ролям (веб / мобайл / продукт / маркетинг / бизнес / еще что-то)
- Есть условное разделение по зонам ответственности (описание, инжиниринг, nlp, исследования, спорт)
- Нанимали людей даже без знания SQL, главное – математика
- Аналитик – не калькулятор и не мастер по презентациям: все отчеты автоматизированы

# АНАЛИТИКА

Базы данных



# АНАЛИТИКА

ClickHouse

- Колоночная СУБД, изначально разработанная Яндексом (сейчас отдельная компания), хранилище для нашего кликстрима и других сервисов, где важны не единичные строки, а агрегаты.
- Используем с 2016-го года, тогда – удачная находка (скорость работы позволяла закрыть глаза на некоторые баги и непривычный синтаксис и бросать все силы на переезд с Redshift), сейчас – один из лидеров в области.
- Благодаря шардированию (параллельное вычисление и хранение данных) и репликации (дублирование данных между серверами для отказоустойчивости) можно не терять в скорости с увеличением объемов, данных, в отличие от классических версий MySQL / PostgreSQL.

# АНАЛИТИКА

Инструменты



kubernetes

FastAPI  




Apache  
Airflow



re dash



Streamlit

# АНАЛИТИКА

## Инструменты

- Airflow – основной инструмент для создания пайплайнов по обработке данных. Благодаря этому сервису управлять всеми операциями стало проще – помогают встроенный алертинг и удобный интерфейс.
- FastAPI – основной инструмент для написания бекенд-сервисов в аналитике. Низкий порог входа позволяет создать эффективно работающую логику даже джунам с парой месяцев опыта.
- Kubernetes – система управления кластерами контейнеризированных приложений и сервисов. Де-факто стандарт в веб-разработке, который сильно упрощает развертывание и поддержку приложений.


# АНАЛИТИКА

Свой счётчик. Зачем, когда есть GA/ЯМ?

- Возможность построения кастомных метрик и отчетов
- Мощная детализация (фильтры по конкретному пользователю или последовательности событий)
- Единая структура для веба и приложений
- Обходим адблок – видим больше пользователей (+15% юзеров)
- Соединение с метаданными для красивых дашбордов
- Открыт в open-source, готовы консультировать по внедрению / использованию

# АНАЛИТИКА

## Визуализация



- Минусы своего счетчика – на выходе просто таблица в БД, все представления данных нужно собирать с нуля
- BI – Redash (даже контрибьютим в развитие) – огромный набор визуализаций и возможность собирать дашборды на Python
- Если нужна интерактивность – пишем приложение на Streamlit (Python)





main

oracle

sync

режим выгрузки

product

adblock

robot

sports

All

All

исключить просмотры маркетинга

platform

mobile web

geo

Мск и МО

## Прогноз

Чем больше период, тем точнее прогноз.

existing start

existing end

2021-07-25

2021-08-01

Advanced

Построить

## Динамика

Выгрузить в Google Sheets


1w

1m

6m

1y

all



## Аномалии

Данные с сервиса <https://docs.google.com/spreadsheets/d/1t>

# АНАЛИТИКА

Конкретнее про бигдату и детализацию

- Суммарно около 1000 строк в таблице с описанием событий
- Отслеживаем просмотр страницы и явные и неявные действия пользователей на них, каждое действие – 1 строка в базе, а 1 просмотр страницы генерирует около 100 событий
- Примеры вопросов, на которые умеем отвечать: какая дочитываемость у контента? а только у тех, кто заходит 5 дней подряд и чаще всего читает про Спартак? сколько денег нам приносит пользователь из ВК? какое пересечение у пользователей между вебom и приложениями? что мешает пользователям в процессе регистрации?

# АНАЛИТИКА

## Data Discovery

- Знания по структуре БД и событий не должны лежать в людях – выносим в общедоступные ресурсы и стараемся поддерживать актуальность
- Документация ивентов – в Google Sheets
- Документация БД – в DataHub



Google  
Sheets



DataHub



# СЕРВИСЫ НА ОСНОВЕ ДАННЫХ

- Аналитики в Sports.ru почти не занимаются ресерчем в ML: часто используем лучшие практики в уже готовых библиотеках
- Команда аналитики сама пишет backend для таких сервисов
- Нейросети – не панацея, если классические алгоритмы справляются не хуже, чаще «классика» работает значительно быстрее, что важно для продакшна
- Есть задачи, которые приходят от бизнеса, но значимая доля сервисов рождается из желания попробовать новый инструмент

# СЕРВИСЫ НА ОСНОВЕ ДАННЫХ

Прогноз трафика


- У нас рекламная модель бизнеса – выручка коррелирует с просмотрами страниц
- Делаем краткосрочный (месяц) и долгосрочный (год) прогнозы
- Сервис прогноза – инструмент для отдела продаж – делаем так, чтобы рекламы было ровно столько, сколько инвентаря доступно



# СЕРВИСЫ НА ОСНОВЕ ДАННЫХ

Expected goals в футболе

- xG – показатель расширенной футбольной статистики, который показывает остроту моментов
- Обучили модель классификации на основе бустинга, которая предсказывает вероятность гола по 100+ параметрам
- Топ-5 лиги + РПЛ имеют данный показатель, который обновляется прямо во время матча



The screenshot shows a mobile application interface for football. At the top, there is a navigation bar with a back arrow, a 'Футбол' (Football) dropdown menu, a 'LIVE' indicator, and a menu icon. Below this is a calendar view with days 2 (Чт), 3 (Пт), 4 (Сб), 5 (Вс), 6 (Пн), 7 (Вт), and 8 (Ср). The date '4 Сб' is highlighted with a green box. The main content area displays the 'Германия. Бундеслига' (Germany. Bundesliga) league. Three matches are listed, each with the status 'Завершен' (Completed), the score, and the xG values for both teams. A white cube is positioned in the bottom left corner of the screenshot.

Match	Score	Team 1 xG	Team 2 xG
Боруссия Д vs Фрайбург	5 - 1	2.66	0.43
Унион Берлин vs Майнц	2 - 1	0.91	1.25
Кельн vs РБ Лейпциг	0 - 0	0.48	0.55

# СЕРВИСЫ НА ОСНОВЕ ДАННЫХ

## Кросспроектные рекомендации

- Делаем свою систему рекомендаций с 2017-го года, сейчас подключаем сторонние ресурсы (пока бесплатный SaaS)
- Работаем качественнее «обменок» (CTR + глубина), но без кликбейта
- Множество алгоритмов: многорукие бандиты, «классика», item2item, next-item – подстраиваемся под конкретную задачу

### Рекомендуем

Энцо в «Челси» за 121 млн, Забитцер и Кейлор теперь в АПЛ. Европа...

+109 🔥 70

«Челси» утащил Энцо Фернандеса! Главное о невероятной зимней закупке

+67 🔥 131

«Лю... не т... бы»: пиц...

# ВСЕ!

Остались вопросы? Хотите потестировать  
рекомендалку или счетчик аналитики? Пишите!

**TELEGRAM: @VLADENISOV**

**MAIL: DENISOV@SPORTS.RU**

