

Яндекс

Твиттер в поиске Яндекса

Иван Комаров

разработчик

я.Субботник в Екатеринбурге, 6 июля 2013

Мотивирующий пример

26 октября 2012 года пользователям Рунета стал доступен сайт zapret-info.gov.ru. Мы хотим его как можно быстрее начать показывать по запросу [реестр запрещённых сайтов].

Какие данные мы можем для этого использовать?

Ссылки на страницу

- Страница не очень быстро обрастает ссылками.
- Тексты ссылок малоинформативны.

Роскомнадзор напоминает о вступлении в силу с 01 ноября 2012 года изменений в Федеральный закон 149-ФЗ "Об информации, информационных технологиях и защите информации", сообщается на сайте "Единого Реестра доменных имен, указателей страниц сайтов в сети "Интернет" и сетевых адресов, позволяющих идентифицировать сайты в сети "Интернет", содержащие информацию, распространение которой в Российской Федерации запрещено" [Zapret-info.gov.ru.](http://zapret-info.gov.ru/)

"Единый реестр доменных имен, указателей страниц сайтов в сети "Интернет" и сетевых адресов, позволяющих идентифицировать сайты в сети "Интернет", содержащие информацию, распространение которой в Российской Федерации запрещено", расположен на сайте <http://zapret-info.gov.ru/>.

Накануне ведомство запустило портал, на котором пользователи смогут жаловаться на интернет-ресурсы. Кроме того, был опубликован порядок ведения реестра сайтов с

будет проверить через специальный ресурс, открытый Роскомнадзором. Но сделать выгрузку всего реестра вправе



Текст и URL страницы

- Мало текста, слова запроса разбросаны по странице.

ЕДИНЫЙ РЕЕСТР

доменных имен, указателей страниц сайтов в сети «Интернет»
и сетевых адресов, позволяющих идентифицировать сайты в сети «Интернет»,
содержащие информацию, распространение которой
в Российской Федерации запрещено

- Мы практически ничего не знаем про URL и домен.




Твиттер

- Ссылки на интересные страницы появляются быстро.
- Каждая ссылка снабжена компактным описанием.



Yakimets Roma
@yakimetsr

Реестр запрещенных сайтов: zapret-info.gov.ru Тут можно узнать запрещен тот или иной сайт в Инете. Ну и настучать на сайты можно тоже там.



Evgeny Vilkov
@EvgenyVilkov

реестр запрещенных сайтов будет размещен по адресу zapret-info.gov.ru. Хорошее дело в домене gov не разместиши!



Pavel Plotnikov
@PavelPV

Реестр запрещенных сайтов в Российской Федерации (открыт частично) zapret-info.gov.ru



RussianNewslne
@RussianNewslne

Реестр запрещенных сайтов обзавелся адресом: На сайте zapret-info.gov.ru можно будет узнать, какие веб-страницы... bit.ly/XrqxoF



Что дальше?

- Я расскажу про **5** задач, которые нам пришлось решать.
- Попробую обойтись без закапывания в технические детали.
- Эти задачи — только верхушка айсберга.

I. Распознавание языков

Twitter Firehose

- Шланг со всеми твитами в мире.
- Типичные объёмы за день:
 - **500 млн** записей в JSON-формате (включая служебные).
 - **1,3 ТБ** в несжатом виде, **200 ГБ** в сжатом.

Как оставить только нужные твиты?

Машинно-обученные классификаторы!

Яндекс

twitter

Обучающая выборка

Запросы пользователей

Твиты

Охват языков

Малая часть

Все возможные


Дата появления

Начало времён

Февраль 2013 года

Твитов со ссылками в день – около 45 млн.

Нас интересуют только **русские и турецкие** твиты (в сумме около 4 млн).



Неоднозначность

На каком языке написан этот твит?



Фрося
@fr0syfr0

Ура новенькие котяты!!

new.livestream.com/FosterKittenCa... born
May 8th

Mama is Kari. The boys are Grant, Adam,
and Tory. The girl is Jamie



Все врут: **twitter**



Caylie

@fopehybopuj

Почему многие геи против однополых браков? dlvr.it/3VnXZh



Я

Человек

uk

ru

ru



Anna Zeiman

@AnnaZeiman

OneTwoTrip и Anywayanyday: история конфликта siliconrus.com/2013/06/onetwo

bg

ru

ru



QAZETA.COM

@Vuqar2011

Bu gün TQDK buraxılış imtahanları keçirəcək wp.me/p2lgIU-3JJ

tr

az

az

Все врут: Яндекс



Nikolay Kolev

@mazalo

Едно изключение от поп-фолк клишетата
fb.me/2uWPYdosn



Я

Человек

bg

ru

bg



Mustafa Selcuk

@mustafaselcuk

Twitter'daki 17 yalan haber
ensonhaber.com/twitterdaki-ge...

tr

en

tr



Azgii

@aza9098

Ё.Отгонбаярын багын найз А.Чинбат хэргээ хүлээжээ medee.mn/main.php?eid=3...

ru

ru

mn

Все врут: методы борьбы

- Переобучать классификатор (дорого!).
- Агрегировать твиты по пользователям.
- Фильтровать по алфавиту.
 - Украинский: і, ї
 - Сербский/македонский: њ
 - Азербайджанский: ә
- Болгарский победить сложнее всего (ъ?).

III. Короткие ссылки

- Значительная часть ссылок в Твиттере испорчена укорачивателями.
- Нельзя просто так взять и понять, что скрывается за ссылкой.



[Сергей Рябов](#)

@ryabov_s

Вот и реестр запрещенных сайтов
заработал. vk.cc/11opP8

Эта ссылка ведёт на всё тот же <http://zapret-info.gov.ru>.

Популярные укорачиватели



<http://t.co/M0PYXN59>

*

<http://bit.ly/ZsCNpV>



<http://goo.gl/PWy1b>



<http://fb.me/21ILnumuz>




<http://vk.cc/11sQxh>

zapret-info.gov.ru

*добровольно-принудительное укорачивание

Полная картина



Хранение редиректов

- Мы сохраняем весь граф редиректов для каждой ссылки.

Зачем нужен граф?

- Уменьшает число обращений к укорачивателям.
- Единая база редиректов для всего Яндекса.

Некоторые любят подлиннее



[pagan](#)

@torque10

Will Facial-Recognition Software Finally
Reveal Mona Lisa's True Identity? |
[bit.ly/IMPLnu](#) RT [@v_shakthi](#)
[@ashwinsanghi](#) [@AndisKakeli](#)



III. Текстовая релевантность

Релевантен ли твит запросу?

навальный



komagor
@komagor

ДА ИЛИ НЕТ!?

Алексей Навальный о Координационном
Совете - YouTube [youtube.com/watch?
v=ByyWGR...](https://youtube.com/watch?v=ByyWGR...)

Однозначные запросы

джигурда



Vadim Samartsev

@vdmsmrcv

youtube.com/watch?v=mdThpb... Никита
Джигурда избил #православного эксперта
в программе "Прямой эфир".



pussy riot



Tereza

@TerezaNotMother

Музыкальная посылка от Сявы для Pussy Riot. Шик) youtube.com/watch?v=dIQKWc...



Многословные запросы

северное братство хомяков



Русская планета

@rusplt

Лидер сообщества «Северное братство»
признал свою вину в экстремизме:
Ученый Петр Хомяков, являющийся
руководи... bit.ly/PZqkVi



карта россии



Vladimir Kaltyrin

@kaltyrin

Карта пунктов приёма вторсырья |
Гринпис России act.gp/xGXBHV via
@gp_russia



Неправильное выделение объекта

за рулем



[Катёнатор 16+](#)

@noomrem

Соц.кампания, цель которой — обратить внимание водителей на проблему употребления алкоголя за рулем. Они там все упрлс. youtube.com/watch?feature=...



- Скорее всего, имелся в виду журнал «За рулём».
- Важно, в каком контексте используются слова запроса в твите.

Текст «не про то»

народный фронт



Ivan Semyonov

@Sem7ser

"@[interfax_news](#): Пятеро боевиков убиты в Дагестане: bit.ly/18A5DLW #novosti" - Они не хотят вступать в Народный фронт



лужков , матвиенко



Дорогая редакция

@lentaruofficial

Питер интернетизирован на 59%, Мск - на 58% <http://bit.ly/h3kHg7>. При Лужкове такого не было, а при Матвиенко эта сторона наиболее опасна



Граф дружбы

Ориентированный граф (V, E), где:

- V – пользователи.
- E – пары читающих друг друга пользователей.



@navalny

@MedvedevRussia

IV. Социальный граф

ТТХ

- Twitter API для сбора графа.
- Размеры (только русские и турки):
 - $|V| = 21$ млн.
 - $|E| = 1,6$ млрд.
- MESH для обработки (см. доклад Паши Артёмкина).

Применение: авторитетность

- Все пользователи Твиттера равны, но некоторые равнее других.
- Нужно число, оценивающее ценность пользователя.
- Количество читателей – очень плохо.
- Алгоритмы, использующие граф целиком, гораздо лучше. *

* На самом деле нет.

TunkRank

- Итеративный графовый алгоритм.
- Как PageRank, только для Твиттера.
- Грубая и тупая модель, но работает.

$$TunkRank(user) = \sum_{f \in Followers(user)} \frac{1 + RetweetProbability \cdot TunkRank(f)}{|Following(user)|}$$

v. Спам

Чем занимаются спамеры?

- Автоматический фолловинг.
- Покупка и взлом пользователей.
- Воровство контента.
- Создание псевдосообществ.
- Нет предела совершенству!

Как мы с этим боремся?

- [REDACTED] [REDACTED] [REDACTED] [REDACTED].
- [REDACTED] [REDACTED] [REDACTED] [REDACTED] [REDACTED] [REDACTED].
- [REDACTED] [REDACTED] [REDACTED] [REDACTED] [REDACTED].
- [REDACTED]: [REDACTED], [REDACTED] и [REDACTED].
- Нет предела совершенству!

Спасибо за внимание!

#TweetLangChallenge

#yasubbotnik

Это не спам!

Почта: dfyz@yandex-team.ru

Твиттер: @i_komarov

Реальная возможность заработать призы!