


# **СИСТЕМА ЗАЩИТЫ ПОЛЬЗОВАТЕЛЕЙ ОТ НЕЖЕЛАТЕЛЬНОЙ ИНФОРМАЦИИ В СЕТИ ИНТЕРНЕТ**

**с.н.с., к.т.н. Чечулин А.А.**

Лаборатория проблем компьютерной безопасности  
Санкт-Петербургский институт информатики  
и автоматизации РАН (СПИИРАН)  
Санкт-Петербург, Россия

# Немного статистики

- На октябрь 2016 года в Рунете (зона .ru, .рф и .su) зарегистрировано 5 381 819 (ru), 906 303 (рф) и 119 106 (su) доменов (<http://statdom.ru>).
- В то же время по данным Netcraft (<http://news.netcraft.com/>) в октябре 2016 г. в Интернете функционирует 1 429 331 486 сайтов.



# Неприемлемые сайты

**Федеральный закон № 139-ФЗ от 28 июля 2012 года** описывает необходимость блокировать сайты, содержащие:

- материалы с **порнографическими** изображениями несовершеннолетних и (или) объявлений о привлечении несовершеннолетних в качестве исполнителей для участия в зрелищных мероприятиях порнографического характера;
- пропаганду употребления **наркотиков** и **психотропных веществ**, информацию о способах их производства и местах приобретения;
- информацию о способах совершения **самоубийства**, а также призывов к совершению самоубийства;
- **любую иную информацию, запрещённую к распространению в России решениями судов.**



# Неприемлемые сайты для детей

- Некоторые категории веб-сайтов могут негативно повлиять на развитие и психику ребенка, например:
  - содержащие материалы **порнографического и эротического** характера;
  - рекламирующие **алкогольные** напитки;
  - связанные с пропагандой **сектантства**;
  - сайты **знакомств**;
  - посвященные **азартным** играм;
  - призывающие к **расовой, религиозной** и т.п. дискриминации;
  - реклама **табакокурения**;
  - демонстрирующее **кровь и насилие**;
  - связанные с пропагандой **оружия**.



# Целевая аудитория и проблемы

- **Кому это надо?**

- Разработчики в области информационной безопасности
- Частные лица (родители?)
- Организации
- Правительство

- **Проблемы**

- Объем данных
- Скорость обработки
- Сложная структура информации
- Динамическое содержимое
- Разные типы данных
- Разные языки
- ...



# Постановка задачи

- Цель работы:
  - Разработка системы **категоризации веб-сайтов** для блокировки сайтов с неприемлемым содержанием, в т.ч. на иностранных языках
- Задачи:
  - Анализ **способов** определения категории веб-сайтов
  - Определение **исходных данных**
  - Разработка **архитектуры** системы
  - Реализация архитектуры в **программном прототипе**
  - Проведение **экспериментов** для проверки качества работы предложенного подхода
  - Оценка **результатов**



# Способы классификации

- Способы классификации
  - Ручной анализ
  - Анализ списков классифицированных сайтов
  - Интеллектуальный анализ данных (Data Mining)
- Методы Data Mining
  - Decision Trees (DT)
  - K-nearest neighbors (kNN)
  - Naive Bayes (NB)
  - Support Vector Machine (SVM)
  - Нейросети
  - ...




# Методы Data Mining

**Цель** состоит в том, чтобы создать модель, которая предсказывает значение **целевой переменной** на основе **нескольких переменных на входе**.

**Дерево принятия решений** (Decision Tree, дерево классификации или регрессионное деревом)



**Метод k ближайших соседей** (k-nearest neighbors algorithm, k-NN)





# Методы Data Mining

**Цель** состоит в том, чтобы создать модель, которая предсказывает значение **целевой переменной** на основе **нескольких переменных на входе**.

**Метод опорных векторов**  
(SVM, support vector machine)

**Искусственная нейронная сеть**  
(ИНС, Neural Networks)



# Исходные данные

- Источники признаков:

- Текст сайта
- Текст из тегов сайта
- Теги сайта
- Изображения
- URL
- Ссылки между сайтами
- Каталоги сайтов
- Ответы от WhoIS
- История изменения
- Репутация
- Мультимедия
- Скрипты
- ...

- Общие характеристики:

- Количество признаков
- Типы признаков (binomial, integer, float, enumeration, и т.д.)
- Источники признаков (списки сайтов для тренировок и оценки)



# Список сайтов


- Подготовка **обученной модели** производилась на основе выборки состоящей из **40000** сайтов.
- **Тестовая выборка** состояла из **4000** сайтов.
- **Характеристики**
  - 19+1 категорий: Категории: Adult, Alcohol, Banking, Blogs, Cults, Dating, Drugs, Forum, Gambling, Games, Hate, Health, Job\_Search, News, Sport, Tobacco, Travel, Violence, Weapons + Unknown
  - Источники данных:
    - DMOZ (the Open Directory Project, <http://rdf.dmoz.org/rdf/> )
    - URLBlackList (<http://urlblacklist.com/>)
  - Сайты для обучающей выборки **не всегда** имели **высокую степень релевантности** категориям которыми они были обозначены.

# Метрики оценки качества классификации

Относится ли сайт к категории		Эксперт	
		TRUE	FALSE
Классификатор	TRUE	<i>TP (true positive)</i>	<i>FP (false positive)</i>
	FALSE	<i>FN (false negative)</i>	<i>TN (true negative)</i>


- Для каждой категории вычисляется:
  - $a$  (true positive) – количество сайтов **правильно** распознанных как **принадлежащие** категории;
  - $b$  (false positive) – количество сайтов **неправильно** распознанных как **принадлежащие** категории;
  - $c$  (false negative) – количество сайтов **неправильно** распознанных как **не принадлежащие** категории;
  - $d$  (true negative) – количество сайтов **правильно** распознанных как **не принадлежащие** категории;
  - Полнота ( $p$ ) =  $\frac{a}{a+c}$ ; Точность ( $r$ ) =  $\frac{a}{a+b}$ ;
  - $F$ -мера ( $Fmeasure$ ) =  $\frac{2pr}{p+r}$

# Архитектура Извлечение и обработка веб-сайтов



# Архитектура

## Общий подход к классификации




- Три подхода к фильтрации признаков на 3-м уровне
  - **Main Units** – классификатор использует только 2-й уровень
  - **Mixed Units** – классификатор использует и 1-й и 2-й уровни
  - **Mixed Units with extended feature set** – классификатор использует 1-й и 2-й уровни вместе с основными признаками


# Архитектура

## Выбор принципов фильтрации признаков


### Main Units




### Mixed Units



### Сравнение




### Mixed Units with extended feature set




# Реализация Тестовый стенд

<http://www.shallalist.de/Downloads/shallalist.tar.gz>



Распаковка архива



Перевод данных из файловой системы в БД



Этап загрузки \*



Этап извлечения признаков для анализа \*\*



Формирование схемы для ПО RapidMiner



Преобразование данных в формат, воспринимаемый ПО RapidMiner



DAT    AML





Этапы работы в ПО RapidMiner \*\*\*



Генерация отчетов



# Реализация Тестовый стенд



list_of_categories	data_sources
id integer	id integer
category_name()	source_name(150)
	url varchar(300)

list_of_websites
id integer
category_id integer
source_id integer
website_url char(300)

html_data
website_id integer
html_contents text
added_at_datetime timestamp

text_data
website_id integer
text_contents text
lang varchar(50)
text_length integer
isused integer

# Содержимое сайтов

Для экспериментов использовались следующие данные:

- URL web-страницы;
- HTML файл web-страницы;
  - Текст;
  - Текст из 10 наиболее встречаемых тегов (title, p, a, div, meta:content, li, link:title, span, h1, h2);

В перспективе предполагается использовать изображения, находящиеся на веб-странице, для повышения точности классификации.

```
47     </td></tr></table></td>
48     <td width="1" bgcolor="#000000" rowspan="101"></td>
49 </tr>
50 <tr><td height='34' valign='top' background="/img/bottom-header.jpg">
51     being organized by Researchers of Laboratory of Computer Security Problems</h3>
52     <ul>
53     <li>Session on "Advanced research in cyber security" in the International Conference "RusCrypto'2013" (Solnechno
54     <li>21th Euromicro International Conference on Parallel, Distributed and network-based Processing (PDP 2013). Sp
55     </ul>
56
57     <h3>Former Conferences and Workshops
58     organized by Researchers of Computer Security Research Group</h3>
59     <ul>
```

# Подход к классификации текста

- **Словарь**
  - Подход TF/IDF и его модификация
  - Количество текста
- **Обработка текста**
  - Стемминг
  - Токены
  - Гипонимы
  - Гиперонимы
- **Входные данные**
  - Уникальный ID
  - Наличие слова на сайте
  - Категория сайта

Category	Keywords
Adult	porn, sex, pic, xxx, hardcor
Alcohol	wine, tast, wineri, vineyard, beer
Banking	bank, loan, credit, union, financi
Blogs	septemb, juli, novemb, august, wordpress
Cults	church, bibl, christ, god, ministri
Dating	rencontr, singl, est, profil, vou
Drugs	whoi, eng, traffic, verifi, legitim
Forum	gmt, vbulletin, phpbb, guest, moder
Gambling	casino, poker, gambl, bet, bonu
Games	xbox, wii, psp, game, charact
Hate	hate, jew, jewish, truth, god
Health	clinic, treatment, patient, health, therapi
Job_Search	recruit, employ, resum, execut, candid
News	radio, opinion, classifi, newspaper, digit
Sport	leagu, athlet, golf, season, basketbal
Tobacco	tobacco, smoke, cigarett, cigar, smoker
Travel	trip, cruis, charter, island, destin
Violence	violenc, abus, domest, victim, sexual
Weapons	gun, shoot, rifl, firearm, pistol

# Внешние источники и иностранные языки

## ■ Ответы от WhoIs

- Первоначальные результаты показали, что ответы не имеют строгой структуры
- Некоторые элементы ответов от WhoIs могут быть использованы как метаинформация для классификации

```
domain:      SPB.RU
nserver:     ns3-geo.nic.ru.
nserver:     ns4-geo.nic.ru.
nserver:     ns8-geo.nic.ru.
state:       REGISTERED, DELEGATED, VERIFIED
org:         JSC 'RU-CENTER'
registrar:   RU-CENTER-REG-RIPN
admin-contact: https://www.nic.ru/whois
created:     1997.03.11
paid-till:   2015.04.01
free-date:   2015.05.02
source:      TCI
```

Last updated on 2014.07.15 13:56:34 MSK

## ■ Иностранные языки


- Два подхода:
  - Формировать новые признаки
  - Переводить сайт на английский
- Был использован 2-й подход через Yandex переводчик

감사합니다 Natick  
Grazie Danke Ευχαριστίες Dalu  
Thank You Köszönöm  
Спасибо Dank Tack  
谢谢 Merci Seé  
Obrigado ありがとう

# Результаты текстовой классификации

## ■ Результаты экспериментов

- Наличие схожих категорий приводит к понижению качества классификации (например, “Hate” and “Violence”, “Cults” and “Religion”, и т.д.)
- Выбранная архитектура классификаторов позволяет получить хорошие показатели качества
- Выбор деревьев решений в качестве классификаторов привело к превалированию точности над полнотой





# Результаты текстовой классификации

## ■ Дополнительные результаты

- Категория Unknown повышает качество классификации
- Классификация основанная на тексте зависит от количество текста
- Данный классификатор может быть использован в одиночку

## ■ Иностранные языки

- Система автоматического перевода (Yandex-translate)
- Основной язык – английский
- Снижается вариативность языка, что повышает качество классификации



# Классификация по URL

## ■ Словарь (n-граммы)

- (1) Сбор всех адресов веб-страниц (URL) относящихся к одной категории в файл
- (2) формирование токенов на основе специальных символов
- (3) устранение стоп-слов и применение стеммера
- (4) формирование n-грамм

## ■ Словарь

- Подход TF/IDF
- 50 3-грамм для каждой категории

## ■ Входные данные

- Уникальный ID
- Наличие 3-граммы в URL
- Категория сайта

Category	Keywords
Adult	apd, bds, bep, deo, drt, dtu, eos, exv, fap, fuc, ...
Cults	aba, aex, aht, aib, aji, aof, asa, avy, bab, baj, ...
Dating	afu, all, ate, ati, aur, bsi, cli, cup, dat, dda, ...
Drugs	acy, agr, apv, axp, axs, dsf, ecs, gea, grx, hfr, ...



# Структура HTML и ссылки

## ■ Структура HTML

- Эти признаки могут помочь с распознаванием сложных категорий (News, Blogs, Forums, etc)
- Входные данные
  - Уникальный ID
  - Наличие относительное количество тегов
  - Категория сайта

## ■ Ссылки

- Эксперименты требуют больших объемов связанных сайтов
- Результаты показали плохое качество, но причина – качество выборки





# Комбинирование классификаторов

## ■ Результаты экспериментов

### экспериментов

- Предложенный подход может быть использован для построения систем защиты от нежелательной информации
- Комбинирование источников позволяет повысить качество классификации
- Основные источники данных:
  - Общая текстовая информация и текст из тегов
  - URL



# Заключение (1/2)

## Использованное ПО

- Для сбора и первичной обработки данных
  - Jsoup (<http://jsoup.org>);
  - NetBeans IDE (<http://netbeans.org/>);
  - Яндекс.Перевод (<http://translate.yandex.ru/>);
- Для хранения данных
  - PostgreSQL (<http://www.postgresql.org/>);
  - pgAdmin (<http://www.pgadmin.org/>);
- Для проведения экспериментов
  - RapidMiner (<http://rapid-i.com/>).

# Заключение

- Была представлена технология **классификация веб-сайтов** с помощью методов Machine Learning и Data Mining
- Представлены технология и инструменты, позволяющие **автоматизировать** процесс подготовки исходных данных и обученной модели
- Эксперименты показали **высокую точность** категоризации веб-сайтов, что дает возможность **использования** разработанной технологии **в системах блокирования** веб-сайтов с неприемлемым содержанием
- В дальнейшей работе планируется расширить список анализируемых **языков** и перейти от жесткой классификации к мягкой

# Вопросы



Спасибо за внимание  
Вопросы?



Контактная информация:

Чечулин Андрей Алексеевич ([chechulin@comsec.spb.ru](mailto:chechulin@comsec.spb.ru))

<http://comsec.spb.ru/chechulin>

SPIIRAS