

МЕТОДЫ ОБНАРУЖЕНИЯ ПИСЕМ- ТРАНСФОРМЕРОВ

Ермакова Лиана

Понятие спама

- **Спам** - это анонимные незапрошенные массовые рассылки электронной почты (Лаборатория Касперского)
- Но:
 - Спам в социальных сетях
 - Спам в IM

Методы борьбы со спамом

- Black list
- White list
- Grey list
- Анализ заголовков
- Байесовская фильтрация по словам
- Генетические алгоритмы и ручное выставление весов
- Обнаружение повторов и признаков массовости
- Интегрирующие системы

Сигнатурные подходы

- Синтаксические
 - Оперируют цепочками слов
 - «Шинглы»:
 - вычисление контрольных сумм для всех подцепочек текста
 - построение случайной выборки из полученного набора
- Лексические
 - Оперируют словарем
 - Метод опорных векторов

Сообщения-трансформеры

- Сообщения, имеющие сходное содержание, но различные по форме
- Каждое отдельное письмо выглядит как обычный связный текст, и, только имея много копий сообщения, можно установить факт перефразировки

Классификация спама

- По структуре:
 - спам, замаскированный под личную корреспонденцию
 - спам, замаскированный под легальные массовые рассылки
 - рекламный спам
- По тематике:
 - Нигерийские письма
 - Цепочечные письма
 - «страшилки»
 - письма счастья
 - Быстрый заработок
 - Реклама
 - Программное обеспечение
 - Медикаменты
 - Образование
 - Финансы
 - Страхование...

Методы трансформирования сообщения

- Транслитерация
- Намеренные опечатки
- Синонимия
- Замена букв цифрами и наоборот (4-ч, 0-о, 3-з, 1-л)
- Замена кириллических символов схожими символами латиницы (к-к, а-а, Н –Н и т.д.)
- Введение дополнительных символов («Вы хотите вернуть вашего любимого человека навсегда и полностью избавиться от измен?»)»)
- Чередование различных символов (например, в номерах телефонов)
- Варьирование электронного адреса
- Варьирование ссылок...

Алгоритм выявления писем-трансформеров

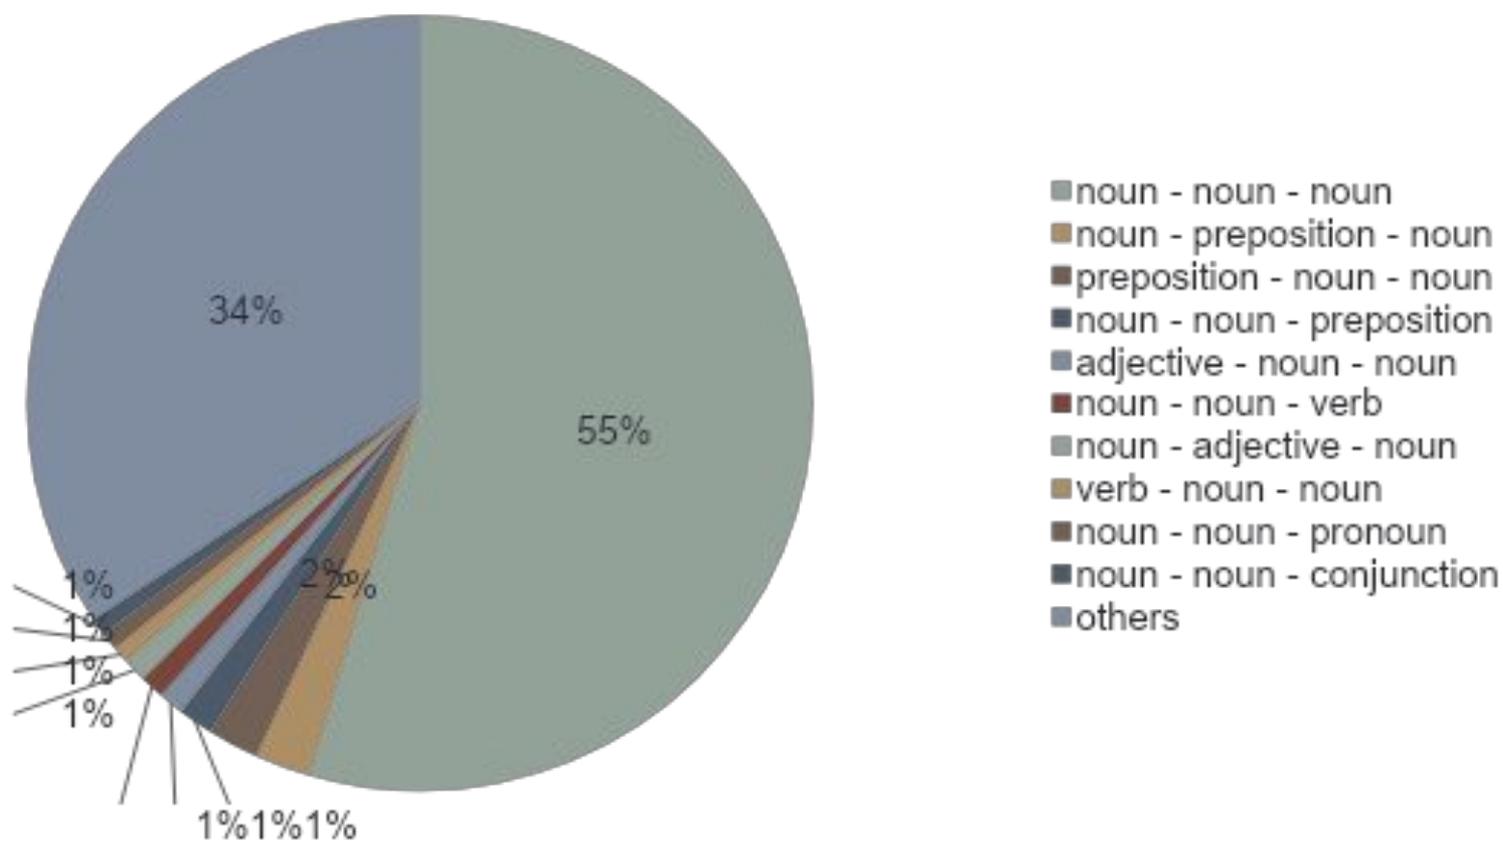
- На основе количественных характеристик с применением машины опорных векторов новое сообщение относится к той или иной категории
- В качестве уточняющего признака используется триграммное сходство с учетом расстояния Дамерау-Левенштейна и выявленных правил замены символов

Квантитативные характеристики

- доля полнозначных и служебных слов
- доля предложений, слов и абзацев определенной длины
- доля вхождения каждой части речи (краткие и полные формы прилагательных и причастий мы считали различными частями речи)
- количество знаков препинания
- встречаемость частей речи
- и т.д.
- **Общее число признаков – 135**

Доли последовательностей частей речи

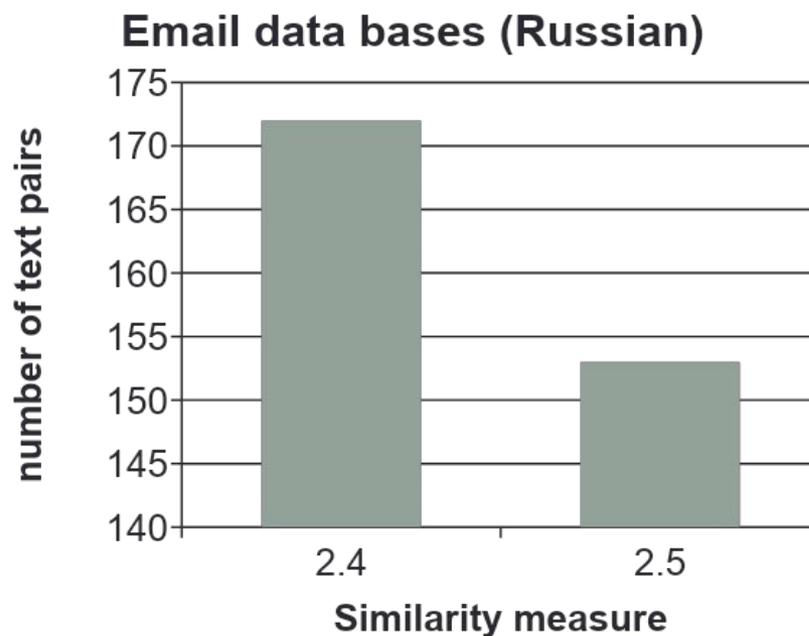
POS trigram share



Email базы

- **sWEVIE email BAZY**
pRODAVA BAZ email
ADRESOW (ADRESA
DLQ email
RASSYLOK) <...>
- **aDRESA DLQ email
RASSYLOK**
pRODAVA BAZ email
ADRESOW (ADRESA
DLQ email
RASSYLOK) <...>

Мера сходства,
вычисленная при помощи
триграмм



ЕГРЮЛ

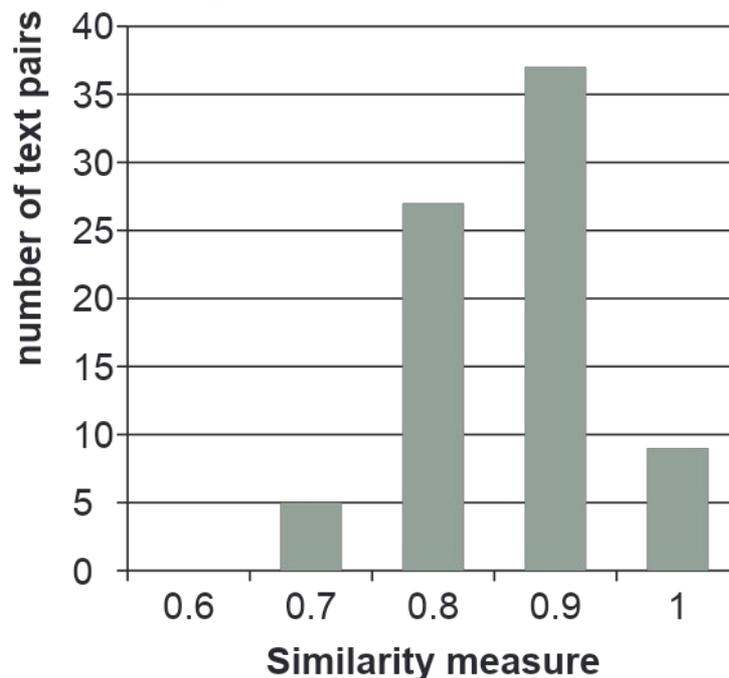
В начале года всегда возникает **потребность** в "свежих" выписках ЕГРЮЛ и справках Госкомстата. Предлагаем Вам: получение выписки ЕГРЮЛ за **1,200 рублей** справки Госкомстата за **1 200 руб.** заказ выписки ЕГРЮЛ + справки Госкомстата составит всего **2.000 рублей** Доставка курьером, оплата по факту. **Контактная информация + 7495 222+07.68**

В начале года всегда возникает **необходимость** в "свежих" выписках ЕГРЮЛ и справках Госкомстата. **Мы** предлагаем Вам: получение выписки ЕГРЮЛ за **1 200 рублей** справки Госкомстата за **1 тыс. 200 р.** заказ выписки ЕГРЮЛ + справки Госкомстата составит всего **2 тыс. 000 руб-й.** Доставка курьером, оплата по факту. **Телефон: + 7495 222_07;68**

В начале года всегда возникает **потребность** в "свежих" выписках ЕГРЮЛ и справках Госкомстата. **Мы** предлагаем Вам: получение выписки ЕГРЮЛ за **1 тыс. 200 руб-й** справки Госкомстата за **1 200 рублей.** заказ выписки ЕГРЮЛ + справки Госкомстата составит всего **2,000 р.** Доставка курьером, оплата по факту. **Контакты + 7(495) 222-07-68**

Мера сходства,
вычисленная при
помощи триграмм

Unified State Register
of Legal Entities (Russian)



Параметры машины опорных векторов для определения писем-трансформеров на русском языке

- Sample size = 707 (Train), 236 (Test), 943 (Overall)
- Support Vector machine results:
- SVM type: Classification type 1 (capacity=10,000)
- Kernel type: Radial Basis Function (gamma=0,007)
- Number of support vectors = 118 (0 bounded)
- Support vectors per class: 94 (0), 16 (1), 8 (2)
- Class. accuracy (%) = 100,000(Train), 100,000(Test), 100,000(Overall)

Знакомства

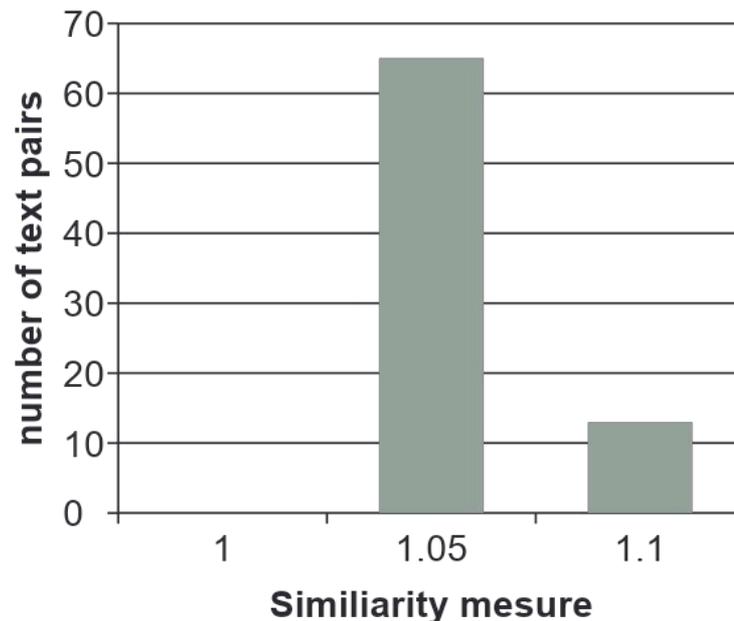
<...> La preghiamo di rispondere solo alla mia personale e-mail: **khhaykanush**@yahoo.com Tua amica Haykanush.

<...>La preghiamo di rispondere solo alla mia personale e-mail: **haykanusharm**@yahoo.com Tua amica Haykanush.

<...>La preghiamo di rispondere solo alla mia personale e-mail: **khaykanush**@yahoo.com Tua amica Haykanush.

Мера сходства, вычисленная при помощи триграмм

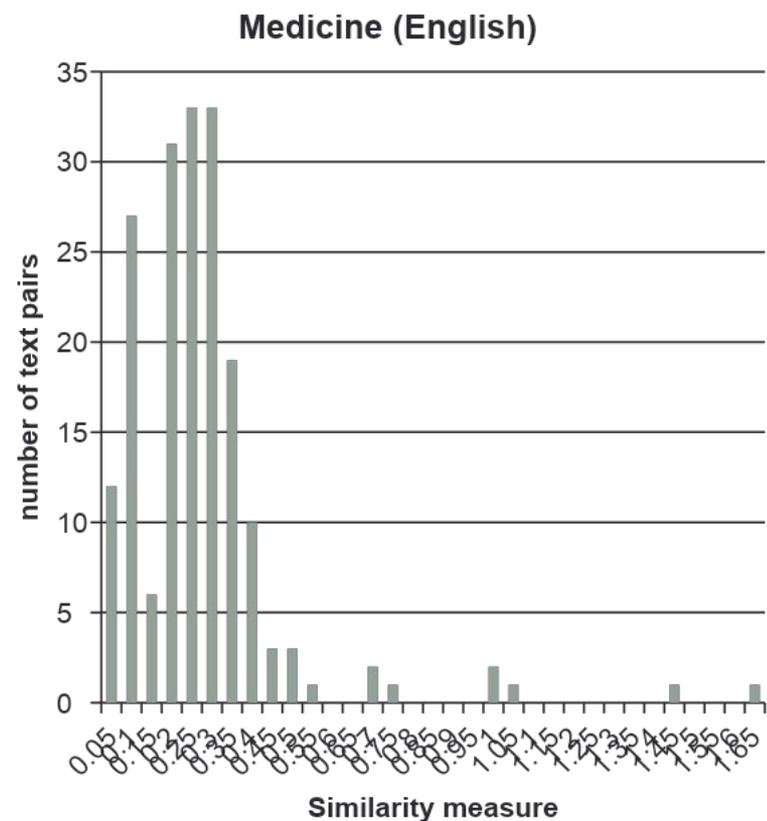
Dating (Italian)



Медикаменты

Тема	Текст
Desire to impress and please your lover tonight	The only bluepill you need to get bigger python. http://wanzulkifli.com/c6ave6lc.html
Gain in size and win your wife's addiction	Desire to act like a pornstar? Bang a magicpilule! http://bpyasociados.com.ar/9vh6w3lf.html
Wish to act like a porn-director Nail a blu colored med!	0% amorous failure risk http://mikloswowmobile.com/uaagzeib.html
Dream to act like a porn-director Bang a blu colored pill!	Long manliness is great http://antalyagunlugu.com/d4zz8qan.html

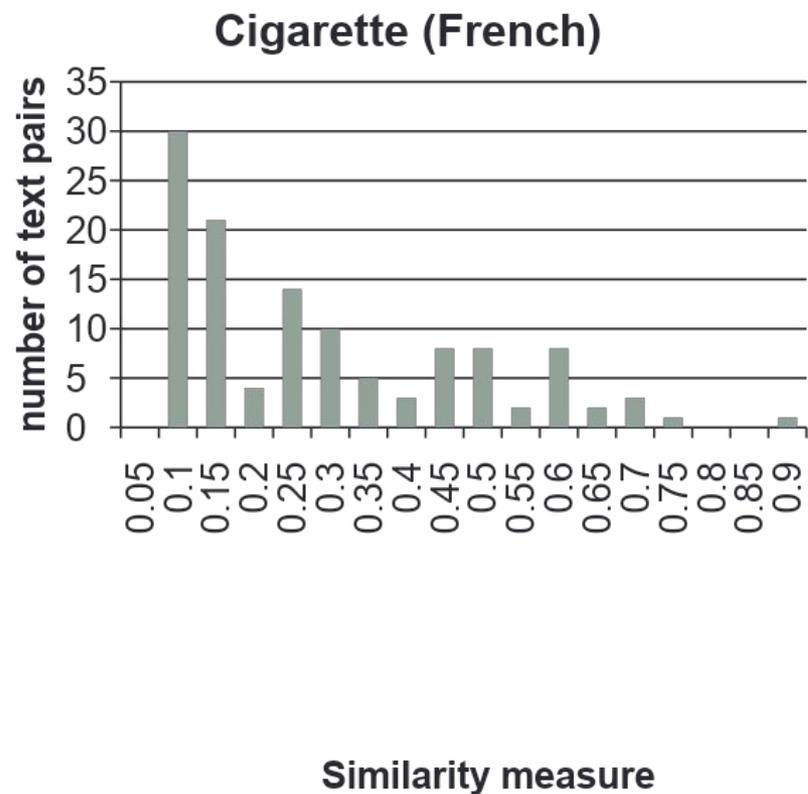
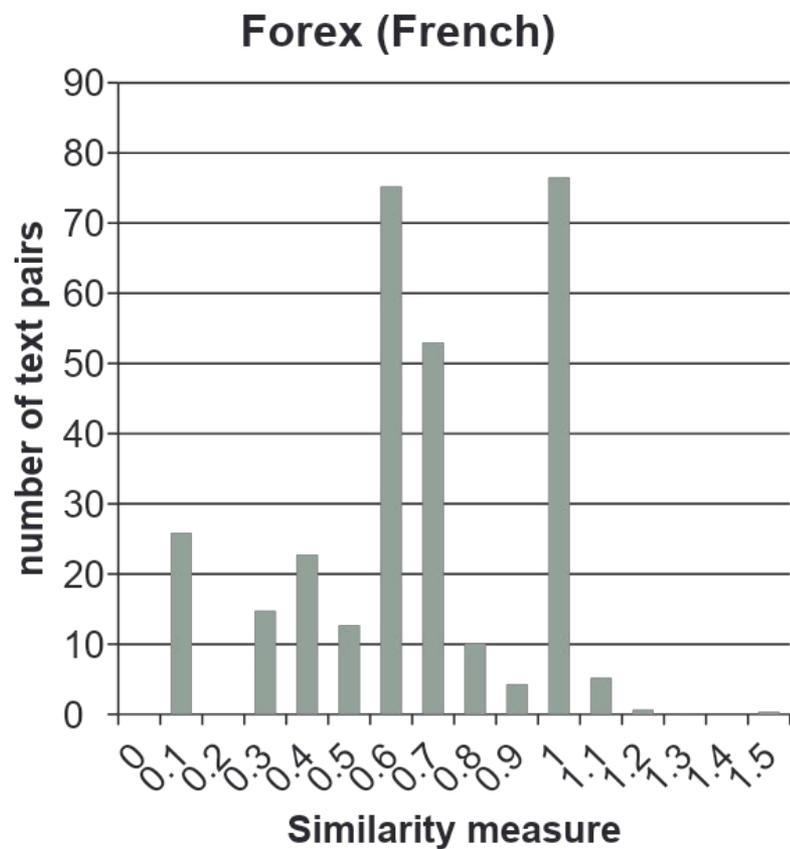
Мера сходства,
вычисленная при помощи
триграмм



Казино

Тема	Текст
Comme Faire _200 de _20 - nous APPRENDRONS	Bonne journee Jessikaparsons, { http://yxaqih983.o-f.com/kerizev.html } Accueillez la fortune dans votre vie avec de grandes opportunit�s de gagner, avec l'assurance que vos informations personnelles sont prot�g�es et vos gains seront pay�s rapidement. Une demi-heure et �200 dans ta poche
Gagner _100 pour une demi-heure c'est r�el	Du jour reussi Shirley_patel, { http://gamingworldshop.ru } Il y a de grandes promotions auxquelles vous pouvez participer et qui vous promettent encore plus de plaisirs et de fa�ons de gagner. Faire �100 pour une demi-heure - Apprendre?
Faire -100 pour une demi-heure - Apprendre	Bonne journee Nvshamshik, { http://beluwulod.maddsites.com/abimogek.html } Il y a de grandes promotions auxquelles vous pouvez participer et qui vous promettent encore plus de plaisirs et de fa�ons de gagner. Gagner -100 pour une demi-heure c'est r�el
Jouer ici, c'est le bonheur ! Telechargez maintenant	{ http://opakypiwel.dreamstation.com/jededila.html } On ne peut pas faire plus simple, il suffit de vous inscrire, de faire un versement et vous recevez un fantastique bonus de bienvenue - alors foncez et gagnez ! La meilleure selection de jeu sur internet ! Jouez ici
Jouez plus, gagnez plus	Salut Shea.swan Des options bancaires s�res qui conviendront a tous sont disponibles. Relaxez-vous et soyez certains que vos informations confidentielles sont s�curis�es et ne seront p� #97;s divulgu�es. { http://durl.me/554k6 } Comment aimeriez-vous commencer au mieux dans le jeu en ligne avec 1,200 Gratuits? Ils sont d�ja a vous, r�clamez-les, jouez et gagnez!

Другие примеры



Выводы

- Контентная фильтрация применима для различных систем обмена сообщениями (электронная почта, IM, социальные сети), т.к. она не опирается на служебную информацию
- Особо рассматривается проблема обнаружения намеренно искаженных фрагментов
- Предлагается метод детектирования массовых сообщений, фильтрация которых затруднительна из-за меняющегося контента. Рассматриваются возможности увеличения производительности за счет использования методов Монте-Карло
- Предложенный двушаговый метод обнаружения писем-трансформеров в почтовом потоке является улучшением сигнатурного метода

Спасибо за внимание!