

# Методы автоматического извлечения оценочной лексики для заданной предметной области

Семинар SIGMOD 2013

*Четвёркин Илья*

*Аспирант ВМК*

*МГУ им. М.В. Ломоносова*

# План презентации

- **Введение**
- Классификация текстов по тональности
  - Подходы к решению
  - Семинар РОМИП
  - Проблемы и преимущества методов. Переносимость
- Постановка задачи извлечения оценочных слов
  - Обзор методов построения словаря
  - Признаки и модель оценочных слов
- Перенос на другие предметные области
  - Система по извлечению оценочных слов *DomEx*
- Обобщенный список оценочных слов
  - Использование словаря в разных задачах
- Вычисление оценок для оценочных слов

# Автоматическая обработка

- Огромное количество субъективных данных
  - Структурированные отзывы и неструктурированные тексты
- Поиск и извлечение полезной информации
  - Для бизнеса: лояльность к продуктам и бренду
  - Для людей: помощь в принятии решений
- **Сложная задача!**
  - Применяется весь спектр методов NLP
  - Большое количество подзадач

# Sentiment analysis

- Основные направления исследований
  - Классификация текста по субъективности \ объективности
  - **Классификация текста по тональности**
  - Классификация по выражаемым эмоциям в тексте
  - Выделение саркастических предложений
  - Аннотирование отзывов
- Разные уровни детализации (фрагмент, предложение, документ)

# План презентации

- Введение
- **Классификация текстов по тональности**
  - Подходы к решению
  - Семинар РОМИП
  - Проблемы и преимущества методов. Переносимость
- Постановка задачи извлечения оценочных слов
  - Обзор методов построения словаря
  - Признаки и модель оценочных слов
- Перенос на другие предметные области
  - Система по извлечению оценочных слов *DomEx*
- Обобщенный список оценочных слов
  - Использование словаря в разных задачах
- Вычисление оценок для оценочных слов






# Основные подходы к решению

- Агрегация оценочных выражений (+правила их комбинирования)
  - Хорошая история и отличное представление!



- Один глобальный классификатор
  - Хорошая история и отличное представление!



---

# Использование глобального классификатора


# Использование глобального классификатора

- Используется документ как целое
- Не требуется выделение оценочных выражений и их тональной ориентации
- Нужны признаки для классификации
- Нужна размеченная коллекция документов

**Pang et al. 2002**

**Whitelaw et al., 2005:**

Add Appraisal Groups Information;  
Attitude & Orientation appraisal features  
+ unigram: 90.2% accuracy



**Pang & Lee 2004:**  
Classification based  
only on the most  
subjective *sentences*.  
86.4% accuracy with  
60% words

**Pang & Lee 2005:**  
Extend to numerical rating.  
First run a standard n-ary  
classifier, then alter the  
outputs to assign similar  
labels to similar reviews (with  
metric labeling)

---

# Классификация мнений на основе оценочных выражений

# Оценочные выражения

- Отдельные слова
  - Прилагательные – много оценочных слов (*пристойный, умильный, мерзопакостный*)
  - Существительные (*нудятина, галиматья, удачность*)
  - Глаголы (*взбесить, восторгать*)
  - Наречия (*выигрышно, метко*)
- Фразы
  - *Обязателен к просмотру*
  - *Лишен достоинств*
  - *Убивать всю интригу*

# Классификация на основе оценочных выражений

- Необходим словарь оценочных слов с тональностями
  - Общий
  - Для конкретной предметной области
- Правила комбинирования оценочных слов
  - Учет отрицаний
  - Учет слов-операторов (усиливающих или меняющих оценку)
  - Учет синтаксической структуры

# План презентации

- Введение
- **Классификация текстов по тональности**
  - Подходы к решению
  - **Семинар РОМИП**
  - Проблемы и преимущества методов. Переносимость
- Постановка задачи извлечения оценочных слов
  - Обзор методов построения словаря
  - Признаки и модель оценочных слов
- Перенос на другие предметные области
  - Система по извлечению оценочных слов *DomEx*
- Обобщенный список оценочных слов
  - Использование словаря в разных задачах
- Вычисление оценок для оценочных слов

# Дорожки РОМИП 2011-2012

- Классификация документа целиком (например отзыва) по общей оценке выраженной автором
  - Классы: Положительный и Отрицательный (возможно Нейтральный)
  - 5 классов, от наиболее положительного до отрицательного
  - Вероятно наиболее широко изучаемая проблема
- Поиск мнений по запросу в коллекции блогов
- Классификация прямой и косвенной речи из **НОВОСТНЫХ ЦИТАТ**

# Некоторые выводы РОМИП

- Наиболее распространенным и эффективным алгоритмом классификации отзывов является **метод опорных векторов**
- Комбинирование SVM с различными лексическими и статистическими характеристиками улучшает результат
- При переносе классификатора на другую предметную область качество существенно падает
  - Инженерный подход работает более устойчиво

# План презентации

- Введение
- **Классификация текстов по тональности**
  - Подходы к решению
  - Семинар РОМИП
  - **Проблемы и преимущества методов. Переносимость**
- Постановка задачи извлечения оценочных слов
  - Обзор методов построения словаря
  - Признаки и модель оценочных слов
- Перенос на другие предметные области
  - Система по извлечению оценочных слов *DomEx*
- Обобщенный список оценочных слов
  - Использование словаря в разных задачах
- Вычисление оценок для оценочных слов

# Проблемы и преимущества методов

- Методы машинного обучения
  - + Высокое качество классификации
  - Необходима размеченная коллекция
  - Плохая переносимость модели
  - Сложно исправлять ошибки (дообучать)
- Методы на основе словарей и правил
  - + Устойчивое качество работы
  - + Легко исправлять ошибки
  - Необходим словарь оценочных слов
  - Низкое качество классификации

# Переносимость классификаторов

- Оценочные слова в области товаров и услуг отличаются от оценочных слов в новостях
  - Слова *зло*, *предательство* не являются оценочными в области товаров и услуг
- Классификатор тональности обученный в одной области работает намного хуже в другой
- **Актуальной** является задача автоматического извлечения оценочных слов для заданной предметной области

# План презентации

- Введение
- Классификация текстов по тональности
  - Подходы к решению
  - Семинар РОМИП
  - Проблемы и преимущества методов. Переносимость
- **Постановка задачи извлечения оценочных слов**
  - Обзор методов построения словаря
  - Признаки и модель оценочных слов
- Перенос на другие предметные области
  - Система по извлечению оценочных слов *DomEx*
- Обобщенный список оценочных слов
  - Использование словаря в разных задачах
- Вычисление оценок для оценочных слов

# Постановка задачи

- Автоматизированное построение словаря оценочных слов для заданной предметной области
  - Выявить специфические черты оценочной лексики
  - Построить модель оценочных слов
- Проверить переносимость модели на различные предметные области
- Извлечь реальные словари оценочных слов
- Показать полезность извлеченных знаний на реальных задачах анализа мнений

# План презентации

- Введение
- Классификация текстов по тональности
  - Подходы к решению
  - Семинар РОМИП
  - Проблемы и преимущества методов. Переносимость
- **Постановка задачи извлечения оценочных слов**
  - **Обзор методов построения словаря**
  - Признаки и модель оценочных слов
- Перенос на другие предметные области
  - Система по извлечению оценочных слов *DomEx*
- Обобщенный список оценочных слов
  - Использование словаря в разных задачах
- Вычисление оценок для оценочных слов

# Обзор методов построения словаря

- Построение словаря экспертами вручную
- Использование различных словарей и онтологических ресурсов
- Использование различных правил и закономерностей в поведении оценочных слов для их извлечения из коллекции текстов
- Комбинация нескольких подходов

# Словарь, созданный вручную

## ■ Эксперты

- Выбирают оценочные слова и выражения
- Проставляют их тональность

## ■ Плюсы

- Перенос человеческого знания
- Относительная надежность

## ■ Минусы

- Зависимость от предметной области
- Эксперты не могут вспомнить все оценочные многословные выражения
- Трудоёмкость

# Подход на основе словарей

- Использование словарей содержащих отношения между словами ( синонимы, антонимы, гипонимы) (Hu & Liu, 2004)
  - Вручную составляется базовое множество слов, затем расширяется с помощью словаря
  - Основной принцип: если слово оценочное, то его синонимы и антонимы будут оценочными
- Использование толковых словарей с описанием сущностей (Esuli & Sebastiani, 2005)
  - Слова имеющие одинаковую ориентацию имеют «похожее» толкование

# Корпусный подход

- Поиск правил и закономерностей употребления оценочных слов в текстах
  - Поиск слов часто встречающихся со словами «хорошо» и «плохо» (Turney, 2002)
  - Использование союзов И, ИЛИ, НО (Hatzivasiloglou, 1997)
  - Поиск близких по контекстам слов (Velikovich et al, 2010)
- Методы машинного обучения для классификации слов (Chetviorkin & Loukachevitch, 2012)
  - Набор признаков качественно описывающий поведение оценочных слов

# План презентации

- Введение
- Классификация текстов по тональности
  - Подходы к решению
  - Семинар РОМИП
  - Проблемы и преимущества методов. Переносимость
- **Постановка задачи извлечения оценочных слов**
  - Обзор методов построения словаря
  - **Признаки и модель оценочных слов**
- Перенос на другие предметные области
  - Система по извлечению оценочных слов *DomEx*
- Обобщенный список оценочных слов
  - Использование словаря в разных задачах
- Вычисление оценок для оценочных слов

# Модель оценочных слов

- На основе четырех текстовых коллекции для каждого слова извлекается набор признаков
- Основные характеристики оценочных слов, учтенные в предлагаемой модели:
  - Оценочные слова чаще встречаются в отзывах, чем в описаниях объектов, либо в новостях
  - Оценочные слова чаще встречаются в отзывах с некоторой тональностью, чем равномерно во всех типах отзывов
  - Оценочные слова чаще являются наречиями или прилагательными
- Применяется комбинация методов машинного обучения для классификации слов

# Текстовые коллекции

- Коллекция отзывов о фильмах
  - 28773 отзыва о фильмах различных жанров, собранные с рекомендательного портала *www.imhonet.ru*
  - Пользовательская оценка для каждого текста (десятибалльная шкала)
- Коллекция описаний фильмов
  - 17680 описаний фильмов
- Новостная коллекция
  - Около двух миллионов новостных документов
- Малый корпус
  - Составлен из частей коллекции отзывов

# Opinion Word Concentration

## Коллекция мнений & Малая коллекция

глава государства в новогоднем поздравлении к украинскому народу, заявляет его пресс-служба в пятницу. По словам Януковича, украинцы, как честные и работающие люди, заслужили **достойную** жизнь, а у детей должно быть **счастливое** детство и **радостное** будущее. Президент также отметил, что старшее поколение, которое создавало независимость страны и создавало ее богатство, также имеет право на то, "чтобы осень и зиму своей жизни провести в атмосфере **тепла**, уважения, **достатка**". Вместе с тем, глава государства призвал к **высокой концентрации оценочных слов!** "Они должны быть направлены на поддержку того, что экономические преобразования " **не** будут проходить быстро и **просто**". "Даже в новогоднюю ночь **не** имею права рассказывать сказку. Скажу, как есть: будет у нас много работы. Но у нас есть и много энергии. У нас много веры в наше государство, у нас много надежд в свои силы и на божью помощь", - подчеркнул В.Янукович. "И с этим мы идем в **Новый год**. И с этим мы вновь победим и будем **счастливы**", - заявил Президент. В своем поздравлении он назвал уходящий 2010 год **непростым**, но **счастливым**. "Нам

## Коллекция новостей & Коллекция описаний

Андрей Коновалов. Он сопровождает министра энергетики Сергея Шматко в поездке по Подмосковным населенным пунктам, отключенным от электроснабжения. По словам Коновалова, последними были запитаны подстанции 35 кВт Андреево (восток Подмосковья) и Импло (Городской станции электроснабжения (от Ю.М. Кольца) в районе совхоза имени Бабушкина). Шматко уточнил, что неподключенными оставались именно эти две подстанции. "Теперь основная проблема лежит в зоне распределительных сетей 6 -10 кВт. Они наиболее **пострадали** от наледи", - сказал Коновалов. В целом, по его словам, восстановление электроснабжения Подмосковья выходит на финишную прямую.

---

# Характеристики оценочных слов для классификации

# Частотные характеристики

- Частотность леммы в коллекции
- Документная частотность
- Частотность слов с большой буквы
- Странность =  $\frac{P_s(w)}{P_g(w)}$
- TFIDF

*Всего 15 характеристик на основе 4х коллекций*

# Примеры отзывов с оценками



[Женя Филимонов](#) 7 августа 2012 #

!!!!!!

★ Оценка: 9



[Sanechka608](#) 6 августа 2012 #

Много слышала положительных отзывов о фильме, но руки все не доходили, но все же я его посмотрела и не пожалела, гениальный фильм, прекрасная игра актеров, фильм до последнего держит в напряжении, ни секунды не поплыла что его посмотрела. Гениальное кино! Всем советую посмотреть!

★ Оценка: 10



[british-idler](#) 6 августа 2012 #

Один из лучших!

★ Оценка: 10



[Obsuzhdate1](#) 4 августа 2012 #

Фильм не может не понравится, любой зритель оценит его по достоинству. Книга тоже супер.  
Читайте больше книг, там все интересней!

★ Оценка: 10

# Характеристике на основе оценок

- Отклонение от средней оценки

$$Dev(w) = |E(c | w) - E(c)|$$

- Дисперсия оценки слова

$$Var(w) = E(c^2 | w) - E(c | w)^2$$

- Вероятность отнесения слова к классу

$$Lhc(w) = \log \frac{P(w | c)}{P(w)}$$

# Морфологические характеристики

- ❑ Часть речи
  - Существительное, Прилагательное, Глагол, Наречие
- ❑ Есть ли у данной леммы морфологическая неоднозначность
  - Встречается ли лемма в разных частях речи в зависимости от контекста
- ❑ Найдено ли слово в морфологическом словаре
- ❑ Начинается ли слово на приставки: БЕЗ, БЕС, МАЛО, МНОГО, НЕ, НИЗКО, ОДНО, ПЕРЕ

---

# Алгоритмы классификации и оценка качества

# Алгоритмы

- Для обучения алгоритмов классификации 18,362 слов *в предметной области о фильмах* были вручную размечены двумя ассессорами
  - 4079 слов были отобраны как оценочные
- Решалась задача классификации слов на два класса: оценочные слова и неоценочные
- Мы использовали следующие алгоритмы: *Logistic Regression, LogitBoost, Random Forest*

# Оценка качества

- Для оценка качества извлеченных списков слов мы использовали метрику *Precision@n*
  - Удобна для оценки качества комбинации списков
  - Может быть использована с различными порогами

<b>Logistic Regression</b>	<b>LogitBoost</b>	<b>Random Forest</b>	<b>Avg</b>
75.7%	75.3%	72.4%	81.5%

Превосходит все характеристики ( $\geq 20\%$ )

# План презентации

- Введение
- Классификация текстов по тональности
  - Подходы к решению
  - Семинар РОМИП
  - Проблемы и преимущества методов. Переносимость
- Постановка задачи извлечения оценочных слов
  - Обзор методов построения словаря
  - Признаки и модель оценочных слов
- **Перенос на другие предметные области**
  - Система по извлечению оценочных слов *DomEx*
- Обобщенный список оценочных слов
  - Использование словаря в разных задачах
- Вычисление оценок для оценочных слов

# Перенос модели


- Четыре новые предметные области:
  - Книги, компьютерные игры, мобильные телефоны и цифровые фотокамеры
  - Структура коллекций в этих областях такая же как и в предметной области о фильмах
- Каждое слово из этих предметных областей преобразуется в вектор характеристик
- Модель, **обученная в предметной области о фильмах**, используется для классификации слов в других областях

# Коллекции

	<b>Коллекция отзывов</b>	<b>Коллекция описаний</b>	<b>Источник</b>
<b>Фильмы</b>	28,773	22,321	Imhonet
<b>Книги</b>	23,883	22,321	Imhonet
<b>Игры</b>	7,928	1,853	Imhonet
<b>Цифровые Фотокамеры</b>	10,208	920	Yandex Market
<b>Мобильные Телефоны</b>	30,620	890	Yandex Market

# Результаты переноса

<b>Предметная область</b>	<b>P@1000</b>
Фильмы	81.5%
Книги	86.0%
Игры	72.2%
Цифровые Фотокамеры	62.0%
Мобильные Телефоны	73.2%



# План презентации

- Введение
- Классификация текстов по тональности
  - Подходы к решению
  - Семинар РОМИП
  - Проблемы и преимущества методов. Переносимость
- Постановка задачи извлечения оценочных слов
  - Обзор методов построения словаря
  - Признаки и модель оценочных слов
- Перенос на другие предметные области
  - Система по извлечению оценочных слов *DomEx*
- **Обобщенный список оценочных слов**
  - Использование словаря в разных задачах
- Вычисление оценок для оценочных слов


# Обобщенные список

- Для создания обобщенного словаря оценочных слов для продуктов и услуг мы скомбинировали списки оценочных слов из *5 предметных областей*
- Мы хотели увеличить вес слов, которые встречаются в большом количестве областей и имеют высокий вес в каждой области

$$R(w) = \max_{d \in D} (prob_d(w)) \cdot \sum_{d \in D} \frac{1}{|D|} \cdot \left( 1 - \frac{pos_d(w)}{|d|} \right)$$

# Обобщенные список

- Оценка качества списка согласно метрике *Precision @1000* равна **91.4%**.
- Этот обобщенный список оценочных слов состоит из слов реально используемых в отзывах пользователей
  - Для создания такого рода списков не требуется никаких словарных ресурсов
  - <http://www.cir.ru/SentiLexicon/ProductSentiRus.txt>
- В качестве baseline был взят комбинированный список *Weirdness*



# Примеры слов из обобщенного списка

- *БЕСПОДОБНЫЙ*
- *НЕВНЯТНЫЙ*
- *ОТЛИЧНЕЙШИЙ*
- *ОБАЛДЕННЫЙ*
- *БЕЗУМНО*
- *НЕПОНЯТНО*
- *НЕПРИЯТНО*
- *ОТВРАТНЫЙ*
- *НЕЖНЫЙ*
- *ПОСРЕДСТВЕННЫЙ*
- *ШИКАРНЫЙ*
- *НЕЛОГИЧНЫЙ*
- *КЛЕВЫЙ*
- *СРЕДНЕНЬКИЙ*
- *НЕПОНЯТНЫЙ*
- *СЛАБЕНЬКИЙ*
- *НЕЕСТЕСТВЕННЫЙ*
- *НЕПЛОХО*
- *СУПЕРСКИЙ*
- *НЕПЛОХОЙ*

# План презентации

- Введение
- Классификация текстов по тональности
  - Подходы к решению
  - Семинар РОМИП
  - Проблемы и преимущества методов. Переносимость
- Постановка задачи извлечения оценочных слов
  - Обзор методов построения словаря
  - Признаки и модель оценочных слов
- Перенос на другие предметные области
  - Система по извлечению оценочных слов *DomEx*
- **Обобщенный список оценочных слов**
  - **Использование словаря в разных задачах**
- Вычисление оценок для оценочных слов

# Задача переноса классификатора

- Для оценки полезности обобщенного списка оценочных слов мы использовали его в задаче переноса на разные области классификатора тональности
  - Области: *Фильмы, Книги, Цифровые камеры, Мобильные телефоны*
- Во всех парах предметных областей извлеченный словарь показывал лучшее качество
- Наилучший результат был получен при переносе классификатора с *Мобильных телефонов* на *Цифровые камеры* **+3.25%**

# Задача извлечения мнений

- Наилучшие результаты в задаче извлечения мнений были получены с использованием обобщенного списка оценочных слов
- Каждый пост получал вес в соответствии:

$$Weight = \alpha \cdot \left( \sum_{w \in q} tfidf_w + \sum_{w \in q} tfidf_w^{header} \right) + (1 - \alpha) \cdot SentiWeight$$

- Оптимальный  $\alpha = 0.6$
- *SentiWeight* вычислялся как доля слов из списка в тексте

	Фильмы	Книги	Камеры
p@1	30.0%	44.0%	49.4%

# План презентации

- Введение
- Классификация текстов по тональности
  - Подходы к решению
  - Семинар РОМИП
  - Проблемы и преимущества методов. Переносимость
- Постановка задачи извлечения оценочных слов
  - Обзор методов построения словаря
  - Признаки и модель оценочных слов
- Перенос на другие предметные области
  - Система по извлечению оценочных слов *DomEx*
- Обобщенный список оценочных слов
  - Использование словаря в разных задачах
- **Вычисление оценок для оценочных слов**

# Вычисление оценок

- Используем модель Марковских случайных полей для моделирование связей между словами
- Построение графа связей между оценочными словами
  - Если два слова часто встречаются близко → схожая тональность
  - Чем дальше слова друг от друга, тем больше распределение приближается к равномерному
- Начальная тональность каждого слова задается его средней оценкой по коллекции текстов

# Вычисление оценок

- Общая энергия системы:

$$E(x, W) = -\sum_{ij} w_{ij} x_i x_j - \sum_i h_i x_i$$

- $w_{ij}$  вес связи между словами  $i$  и  $j$ , обратно пропорциональный среднему расстоянию между ними
- $h_i$  отклонение от средней оценки слова в коллекции
- В построении не участвуют какие-либо словарные ресурсы или ручная разметка
  - Алгоритм может быть использован в любой предметной области!

# Вычисление оценок

- Для поиска MAP оценки распределения вероятностей использовался алгоритм распространения доверия
- Правильность кластеризации составила 82.7%, прирост относительно baseline **5.5%**
- Всего в оценке принимало участие 700 слов
  - Слабая связанность графа
  - Нейтральные и неоднозначные слова

# Примеры оценочных слов с тональностью

■ ОТЛИЧНЕЙШИЙ	+	■ НЕЛОГИЧНЫЙ	-
■ НЕСПЕШНЫЙ	+	■ БЕСПОДОБНЫЙ	+
■ БЕЗДАРНЫЙ	-	■ ПОСРЕДСТВЕННЫЙ	-
■ НЕПРИЯТНО	-	■ ВОСХИТИТЕЛЬНЫЙ	+
■ НЕПОВТОРИМЫЙ	+	■ НЕЕСТЕСТВЕННЫЙ	-
■ ОБАЛДЕННЫЙ	+	■ ШИКАРНЫЙ	+
■ НЕПОНЯТНО	-	■ НЕОБЫЧНО	+
■ ОДНООБРАЗНЫЙ	-	■ НЕОДНОЗНАЧНЫЙ	+
■ НЕЛЕПО	-	■ СКУЧНЫЙ	-
■ ЗАТЯНУТЫЙ	-	■ НЕПРЕДСКАЗУЕМЫЙ	+

# Заключение

- Был предложен новый метод автоматического извлечения оценочных слов на базе нескольких текстовых коллекций
- Были построены словари оценочных слов для нескольких предметных областей и создан обобщенный список оценочных слов для продуктов и услуг
- Данный словарь был оценен ассессорами, с качеством  $P@1000 = 91.4\%$  и использован в разных задачах обработки мнений: задаче переноса классификатора, извлечение мнений из блогов
- Для заданного списка оценочных слов был предложен и оценен алгоритм определения тональности слова

---

Спасибо за внимание!

Вопросы?

