

Извлечение семантических отношений из статей Википедии с помощью алгоритмов ближайших соседей

А.И. Панченко^{2,1}, С.А. Адейкин¹, А.В. Романов¹ и
П.В. Романов¹

¹ МГТУ им. Н.Э. Баумана, Системы Обработки Информации и Управления

² Catholic University of Louvain, Center for Natural Language Processing

17 марта 2012 г.

Plan

Введение

Методы извлечения семантических отношений

Результаты

Заключение

Семантические отношения

В рамках данной работы под семантическими отношениями понимаются:

- **синонимы** (отношения эквивалентности):
 $\langle car, SYN, vehicle \rangle, \langle animal, SYN, beast \rangle$
- **гиперонимы** (иерархические отношения):
 $\langle car, HYPER, Jeep\ Cherokee \rangle, \langle animal, HYPER, crocodile \rangle$
- **ко-гиперонимы** (общий гипероним):
 $\langle Toyota\ Land\ Cruiser, COHYPER, Jeep\ Cherokee \rangle$

Формально:

- $r = \langle c_i, t, c_j \rangle$ – семантическое отношение, где $c_i, c_j \in C$ – слова, такие как *radio* или *receiver operating characteristic*, $t \in T$ – тип семантического отношения, такой как *синонимия* или *гипонимия*
- $R \subseteq C \times T \times C$ – множество семантических отношений
- $R \subseteq C \times C$ – множество нетипизированных отношений

Применение семантических отношений

Семантические отношения представляют знание о языке полезное для различных приложений **автоматической обработки текста (АОТ)**:

- Расширение и рекомендация поискового запроса в ИПС (Hsu et al., 2006)
- Построение вопросно-ответных систем (Sun et al., 2005)
- Категоризация текстовых документов (Tikk et al, 2003)
- Разрешение омонимии (Patwardhan et al., 2003)

Проблема

- Существующие ресурсы часто **недоступны** или **недостаточны** для
 - конкретного приложения
 - предметной области
 - языка

Пример: магазин продающий книги



“Design Patterns: Elements of Reusable Object-Oriented Software”
⇔ “Gang of Four Book” ⇔ GOF

- Как выдать в результате поиска книгу по запросу “GOF”?

Проблема

- Ручное создание требуемых семантических ресурсов:
 - (+) Точный результат
 - (-) Крайне дорогостоящий и трудоемкий процесс
 - (-) Неприменимо в большом количестве случаев
- Существующие методы извлечения отношений:
 - (-) Не обеспечивают достаточной точности
- Поэтому, актуальной задачей является разработка методов автоматического извлечения семантических отношений:

Состояние исследований и разработок

Существующие **методы** извлечения отношений . . .

- **лексико-синтаксические шаблоны** (Snow, 2004)
 - (+) точность, но малое покрытие
 - (-) ручное написание правил извлечения
 - (-) правила зависят от языка и предметной области
- **дистрибутивный анализ** (Филиппович и Прохоров, 2002; Grefenstette, 1994; Curran and Moens, 2002)
 - (+) не требует ручной работы
 - (-) точность

Существующие **метрики** семантической близости основанные на Википедии (Strube and Ponzetto, 2006; Gabrilovich and Markovitch, 2007; Zesch, Muller, and Gurevych, 2008):

- (+) точность
- (+) основные предметные области и языки
- (+) постоянно пополняется пользователями
- (-) **не были использованы для извлечения отношений**

Новизна работы

- Методы извлечения семантических отношений на основе:
 - текстов статей Википедии
 - двух метрик семантической близости – Cos, Overlap
 - двух алгоритмов – KNN, MKNN
- Система Serelex, реализующая предложенные методы
 - открытый исходный код (LGPLv3)

Данные и их предварительная обработка

Данные:

- множество определений D английских слов C
- определение $d \in D$ – первый параграф статьи Википедии, название которой – $c \in C$
- источник статей – DBPedia.org

Предварительная обработка:

- Морфологический анализ (TreeTagger)
- Удаление стоп-слов
- 327.167 определений (237 Мб)
- 775 определений для теста (824 Кб)

```
axiom; in#IN#in traditional#JJ#traditional logic#NN#logic ,#,#, an#DT#an  
axiom#NN#axiom or#CC#or postulate#NN#postulate is#VBZ#be a#DT#a  
...is#VBZ#be not#RB#not proved#VVN#prove ...
```

Алгоритмы извлечения семантических отношений

Метод извлечения семантических отношений

Вход:

- C – множество слов,
- D – множество определений для C
- k – количество ближайших соседей

Выход:

- R – множество пар семантически связанных слов

Алгоритмы

- KNN – Метод ближайших соседей
- MKNN – Метод взаимных ближайших соседей

Метрики семантической близости

- Cos – Косинус угла между векторами определений
- Overlap – Количество общих лемм в определениях

Метрики семантической близости

Вычисляют меру подобия **смысла слов** $c_i, c_j \in C$ на основе подобия определений $d_i, d_j \in D$

Overlap – Количество общих лемм в определениях

- $similarity(c_i, c_j) = \frac{2|(d_i \cap d_j)|}{|d_i| + |d_j|}$
- $|d_j|$ – количество слов в определении $d_j \in D$

Cos – Косинус угла между векторами определений

- $similarity(c_i, c_j) = \frac{\mathbf{f}_i \cdot \mathbf{f}_j}{\|\mathbf{f}_i\| \cdot \|\mathbf{f}_j\|}$
- f_{ik} – частота леммы c_k в определении d_i
- $\mathbf{f}_i = (f_{i1}, \dots, f_{in})$

Алгоритмы KNN

R = ExtractRelations(C, D, k, isMKNN)

Input: C – слова, D – определения слов, k – количество ближайших соседей, isMKNN – если true использовать алгоритм MKNN, иначе KNN

Output: R – множество семантических отношений $\langle c_i, c_j \rangle$ in C X C

```
1. //Вычисление попарной близости между всеми словами C
2. Rmatrix = void
3. for i=0; i<count(C); i++ {
4.     for j=i; j<count(C); j++ {
5.         // Вычисляем семантическую близость двух слов
6.         s_ij = similarity(D(i), D(j))
7.         // Сохраняем наиболее подобные слова
8.         if( count(Rmatrix(C(i))) < k || s_ij > min(Rmatrix(C(i))) )
9.             Rmatrix(C(i)).addOrReplaceMin(C(j))
10.        }
11.    }
12. }
```

Алгоритм МКNN

```

R = ExtractRelations(C, D, k, isMKNN)
Input: C – слова, D – определения слов, k – количество ближайших соседей,
isMKNN – если true использовать алгоритм МКNN, иначе KNN
Output: R – множество семантических отношений <c_i, c_j> in C X C
1. //Вычисление попарной близости между всеми словами C
2. Rmatrix = void
3. for i=0; i<count(C); i++ {
4.     for j=i; j<count(C); j++ {
5.         // Вычисляем семантическую близость двух слов
6.         s_ij = similarity(D(i), D(j))
7.         // Сохраняем наиболее подобные слова
8.         if( count(Rmatrix(C(i))) < k || s_ij > min(Rmatrix(C(i))) ){
9.             Rmatrix(C(i)).addOrreplaceMin(C(j))
10.        }
11.    }
12.)
13.// Вычисление семантических отношений
14.R = void
15.foreach c_i in Rmatrix {
16.    foreach c_j in Rmatrix(c_i) {
17.        if(!isMKNN || Rmatrix(c_j) contains c_i){
18.            R.add(<c_i, c_j>)
19.        }
20.    }
21.)
22.return R

```

- Временная сложность – $O(|C|^2)$
- Пространственная сложность – $O(k|C|)$

Пример работы KNN и МКNN

Computer	Apple	Fruit	
-	0.4	0.0	Computer
-	-	0.8	Apple
-	-	-	Fruit

$$k = 2$$

k ближайших соседей:

- Computer – { **Apple**, Fruit }
- Apple – { **Fruit**, Computer }
- Fruit – { **Apple**, Computer }

Пары для KNN: <Computer, Apple>, <Apple, Fruit>

Пары для МКNN: <**Apple**, **Fruit**>

Программный комплекс Serlex

- <http://github.com/jgc128/serelex>
- Язык: C++
- Используемые библиотеки: STL, boost
- Кроссплатформенная: Windows/Linux, 32/64-bit
- Интерфейс: консольный
- Многопоточность: Не используется
- Лицензия: LGPLv3

Эмпирическая оценка производительности:

- 755 дефиниций - 3 секунды
- 327 168 дефиниций – 3 дня 3 часа 47 минут
- Конфигурация сервера: Linux 2.6.32-cs-kernel с процессором Intel® Xeon® CPU E5606@2.13GHz

Извлеченные отношения

Пример извлеченных отношений R между множеством из 775 слов (MKNN, $k=2$, Overlap):

$$R = \{$$

- $\langle acacia, pine \rangle$, $\langle aircraft, rocket \rangle$,
- $\langle alcohol, carbohydrate \rangle$, $\langle alligator, coconut \rangle$,
- $\langle altar, sacristy \rangle$, $\langle object, library \rangle$,
- $\langle object, pattern \rangle$, $\langle office, crew \rangle$,
- $\langle onion, garlic \rangle$, $\langle saxophone, violin \rangle$,
- $\langle saxophone, clarinet \rangle$, $\langle tongue, mouth \rangle$,
- $\langle watercraft, boat \rangle$, $\langle watermelon, berry \rangle$,
- $\langle weapon, warship \rangle$, $\langle wolf, coyote \rangle$,
- $\langle wood, paper \rangle, \dots$

$$\}$$

Количество извлеченных отношений



Рис.: Зависимость количество извлеченных отношений $|R|$ от количества ближайших соседей k .

Точность извлечения

Алгоритм	Мера подобия	Извлечено	Правильных	Точность
KNN	Cos	1548	1167	0.754
KNN	Overlap	1546	1176	0.761
MKNN	Cos	652	499	0.763
MKNN	Overlap	724	603	0.833

Таблица: Точность извлечения с помощью алгоритмов KNN и MKNN для $k = 2$ и 775 слов.

Альтернативные системы извлечения отношений

- SEXTANT (Grefenstette, 1992) – точность извлечения 75%
- PMI-IR (Turney, 2001) – выбор 1 из 4 синонимов 74 %
- WikiRelate! (Strube and Ponzetto, 2006) – наиболее подобная система
 - не извлекает отношения
 - несколько другие метрики близости
 - использует решетку категорий Википедии
 - исходный код недоступен
 - корреляция около 0.59 с суждениями человека
- Explicit Semantic Analysis (Gabrilovich and Markovitch, 2007)
- Wikipedia/Wiktionary (Zesch, Muller, and Gurevych, 2008)
- PF-IBF (Nakayama et al., 2007)

Заключение:

- Были предложены **новые методы** извлечения семантических отношений из Википедии с помощью алгоритмов ближайших соседей и двух метрик семантической близости.
- Наилучшие результаты (**83% точности**) показал метод MKNN с метрикой Overlap.
- Была реализована **система** с открытым исходным кодом Serelex, реализующая предложенные методы.
- Предложенные **методы характеризуются**:
 - вычислительной эффективностью
 - большим покрытием лексикона, за счет применения Википедии (3.8 млн. терминов на англ.)

Направления дальнейшего исследования:

- Применение разработанного метода для извлечения отношений на русском, французском и немецком языках.
- Повышение точности извлечения за счет анализа структуры полученного графа семантических отношений.