

Извлечение отношений из текстов на естественном языке

Чернявский Илья

СПбНИУ ИТМО
Руководитель: А.А.Шалыто

Санкт-Петербург
2012г

Отношения - тройки вида «слова отношения»(аргумент1, аргумент2).

Примеры:

- Президент сделал заявление о начале проведения реформ
«сделал заявление о» («президент» , «начале проведения реформ»)
- Анна вышла замуж за Петра
«вышла замуж за» («Анна» , «Петра»)

Предложить метод для извлечения отношений из текстов на русском языке.

Для английского языка:

- TextRunner [M.Banko, O.Etzioni, 2008]
- KnowItAll

- 1 Обучить компонент «Chunker»

Пушкин происходил из разветвлённого дворянского рода.

[NP Пушкин] [VP происходил] [NP из разветвлённого дворянского рода]

- 2 Обучить компонент «Extractor»

«происходил из» (Пушкин, разветвлённого дворянского рода)

- 1 Обучить компонент «Chunker»

Пушкин происходил из разветвлённого дворянского рода.

[NP Пушкин] [VP происходил] [NP из разветвлённого дворянского рода]

- 2 Обучить компонент «Extractor»

«происходил из» (Пушкин, разветвлённого дворянского рода)

- 1 Обучить компонент «Chunker»

Пушкин происходил из разветвлённого дворянского рода.

[NP Пушкин] [VP происходил] [NP из разветвлённого дворянского рода]

- 2 Обучить компонент «Extractor»

«происходил из» (Пушкин, разветвлённого дворянского рода)

- 1 Обучить компонент «Chunker»

Пушкин происходил из разветвлённого дворянского рода.

[NP Пушкин] [VP происходил]

[NP из разветвлённого дворянского рода]

- 2 Обучить компонент «Extractor»

«происходил из» (Пушкин, разветвлённого дворянского рода)

- 1 Обучить компонент «Chunker»


Пушкин происходил из разветвлённого дворянского рода.

[NP Пушкин] [VP происходил] [NP из разветвлённого дворянского рода]

- 2 Обучить компонент «Extractor»

«происходил из» (Пушкин, разветвлённого дворянского рода)

- Обучение модели MaxEnt и модели CRF.
- Обучающее множество – 30000 предложений.



Chunker:

...

Мы S B-NP

придумали V B-VP

постоянно ADV B-NP

действующий V I-NP

источник S I-NP

горючей A I-NP

смеси S I-NP

и CONJ I-NP

зажигалку S I-NP

...

Chunker:

...

Мы S B-NP

придумали V B-VP

постоянно ADV B-NP

действующий V I-NP

источник S I-NP

горючей A I-NP

смеси S I-NP

и CONJ I-NP

зажигалку S I-NP

...

Chunker:

...

Мы S B-NP

придумали V B-VP

постоянно ADV B-NP

действующий V I-NP

источник S I-NP

горючей A I-NP

смеси S I-NP

и CONJ I-NP

зажигалку S I-NP

...

Chunker:

...

Мы S B-NP

придумали V B-VP

постоянно ADV B-NP

действующий V I-NP

источник S I-NP

горючей A I-NP

смеси S I-NP

и CONJ I-NP

зажигалку S I-NP

...

[NP Деньги на программы здравоохранения] [VP изымаются в частности]
[NP из местного бюджета]

Extractor:

...

Деньги S O

на PR O

программы S O

здравоохранения S O

изымаются V IN

в частности ADV O

из PR IN

местного A O

бюджета S O

...

[NP Деньги на программы здравоохранения] [VP изымаются в частности]
[NP из местного бюджета]

Extractor:

...

Деньги S O

на PR O

программы S O

здравоохранения S O

изымаются V IN

в частности ADV O

из PR IN

местного A O

бюджета S O

...

Точность (*precision*) – доля найденных правильных отношений среди всех найденных.

Полнота (*recall*) – доля найденных правильных отношений среди всех правильных.

F-Measure:

$$FMeasure = \frac{2 * (precision * recall)}{precision + recall}$$

Chunker:

- **MaxEnt**

Precision: 0.7590

Recall: 0.7887

F-Measure: 0.7736

- **CRF**

Precision: 0.6885

Recall: 0.7315

F-Measure: 0.7094

Extractor:

- **Эвристический классификатор**

Precision: 0.7352

Recall: 0.1424

F-Measure: 0.2386

- **Байесовский классификатор**

Precision: 0.6229

Recall: 0.3247

F-Measure: 0.4269

- **Features:**

- Есть ли существительное в им. падеже;
- Длина chunk'ов;
- Есть ли глагол;
- Есть ли предлог;
- Согласованность по числу;
- Расстояние между chunk'ами и др.

Пушкин [**провёл в**] Царскосельском лицее шесть лет
он [**обращается к**] элегиям
в сентябре он [**прибывает в**] Кишинёв
Новый начальник [**снисходительно относился к**] службе Пушкина
Пушкин [**вступает в**] масонскую ложу в Кишеневе
сам [**пишет в**] своём дневнике
поэт [**пытается обратиться к**] российской древности
поэт [**подаёт**] прошение об отставке
Пушкин [**едет через**] Нижний Новгород
Она [**была начата в**] Болдине
Прощение [**было принято с**] отказом
Пушкин [**был связан**] службой в Петербурге
Пушкин [**отказался от**] неё

- Представление документов в формате RDF (W3C Semantic Web).
- Поисковые системы (RevMiner).
- Автоматическое построение онтологий.

- Проведен анализ эффективности моделей MaxEnt и CRF, эвристического и байесовского классификаторов.
- Построен прототип системы извлечения отношений.

Спасибо за внимание!
Вопросы?