

ИЗВЛЕЧЕНИЕ ИНФОРМАЦИИ ИЗ ТЕКСТОВ: ПОРТРЕТ НАПРАВЛЕНИЯ

Большакова Елена Игоревна
МГУ им. М.В. Ломоносова, Факультет ВМиК
bolsh@cs.msu.su

СОДЕРЖАНИЕ

1. Особенности задачи
2. Выделяемые сущности
3. Технология решения: шаблоны
4. Проект ONTOS и система GATE
5. Задача извлечения терминологии
 - Особенности терминов и их употребления
 - Критерии распознавания
 - Шаблоны для извлечения

ОСОБЕННОСТИ ЗАДАЧИ

- *Information Extraction*
- Специфика задачи – распознавание и извлечение из текста определенной значимой информации - объектов и фактов,
структуризация извлеченной информации
- Приложения:
 - текстовая аналитика (экономическая, производственная, правоохранительная и др.)
 - построение онтологий и тезаурусов, моделей проблемной области

ВЫДЕЛЯЕМЫЕ СУЩНОСТИ

- Именованные сущности:

- Имена персоналий
 - Географические названия
 - Названия фирм и организаций
 - Адреса
 - Даты

- Отношения (связи) выделенных сущностей,
например: *работать в*

Смирнов А. работает в ОА «Альфа» с 1998 г.

- связанные с ними события и факты

получение кредита, слияние компаний...

ТЕХНОЛОГИЯ РЕШЕНИЯ

- Частичный синтаксический анализ : неэффективность и многовариантность синт. разбора
 - *Лингвистические шаблоны*, содержащие лексическую, морфологическую и синтаксическую информацию
 - Лингвистич. шаблон – описание языковой конструкции, ее лексического состава и грамматических свойств:
 N “*работает*” в NP (Noun Phrase)
 - Элементы шаблонов:
 - Словоформы, лексемы (возможно, с указанием части речи/морфологических характеристик)
 - Грамматические конструкции: именные и др. группы

ПРОЕКТ ONTOS

АвиКомп, 2000 – 2010 гг.

- Извлечение под управлением онтологии
- Инструментальная система GATE
- Семейство систем OntosMiner - для разных ЕЯ и ПО
- Цели
 - Построение модели ПО
 - Семантическая навигация по тексту
 - Дайджестирование
 - Реферирование: основа реферата - извлеченная информация

СИСТЕМА GATE КАК ИНСТРУМЕНТ

- Набор стандартных программных компонент (лингвистических процессоров) для обработки текста
- Представление лингвистической информации об обрабатываемом тексте в виде набора *аннотаций*, которые хранятся отдельно от текста
- Графическая среда для сборки приложения из компонент

GATE: ПРИМЕРЫ АННОТАЦИЙ

Сущность «Angela Merkel»

Вид аннотации, позиции в тексте	Содержание аннотации
Lookup 41 47	majorType=person_first, minorType=female
Person 41 54	gender=female, rule=PersonFinal, rule1=PersonFull

Token 41 47	category=NNP, kind=word, length=6, orth=upperInitial, string=Angela
Token 48 54	category=NNP, kind=word, length=6, orth=upperInitial, string=Merkel

GATE : КОМПОНЕНТЫ

Цепочка обработки текста в системе GATE:

- **Tokeniser** - разбиение текста на отдельные токены (числа, знаки препинания, слова)
- **Gazetteer** - создание аннотаций к словам на основании словарных файлов (названия городов, организаций, дней недели и т.д.)
- **Sentence Splitter** - разбиение текста на предложения
- **Part of Speech Tagger** - определение части речи слов на основании словаря и правил
- **Semantic Tagger** - распознавание языковых конструкций и сущностей на основе аннотаций и JAPE-правил
- **OrthoMatcher (Orthographic Coreference)** - соотнесение идентичных сущностей с разными названиями

GATE : ШАБЛОНЫ И ПРАВИЛА

Язык JAPE - запись правил преобразования аннотаций

- Шаблоны для выявляемых конструкций, например:
 {Morph.SpeechPart="Adjective", Morph.Case="Nomative"}
 - шаблон для выявления прилагательных в именит. падеже
- Правила для преобразования аннотаций :
 левая часть – шаблон, правая – преобразование
 нужных аннотаций выявленной конструкции

Rule: Second_name

```
({Token.SemanticType="Name: FName"}):family  
{[А-Я]} {Token.Text=".":} {[А-Я]} {Token.Text=".":}) →  
family.Family={rule="Second_name"} -
```

правило для выявления имен персоналий вида *Иванов И.*
и выделение из них фамилий

ИЗВЛЕЧЕНИЕ ТЕРМИНОВ и СВЯЗЕЙ

- Терминологические слова и словосочетания:
называют понятия проблемной области:
*общий регистр, число с плавающей точкой
технология двойной накачки*
 - Приложения:
 - индексирование текстов
 - навигация по тексту
 - поддержка терминологич. редактирования текстов
 - построение *глоссариев* и *предметных указателей*
 - создание онтологий и тезаурусов
- Часть приложений – обработка отдельного текста, но
не коллекции

ОСОБЕННОСТИ ТЕРМИНОВ

- Большинство словосочетаний – *несвободные* (некомпозиционные), т.е. их смысл не выводится из смысла компонент:
железная дорога, длина слова
- Конвенциональность научно-технических терминов ⇒ необходимость их определения в тексте:
Под прерыванием понимается сигнал...
- Грамматическая структура терминов: чаще всего - именные словосочетания, их можно описать структурными грамматическими образцами:
 - прилагательное-существительное – *логический вывод*,
 - существительное- существительное в род. падеже –
период упреждения

МЕТОДЫ РАСПОЗНАВАНИЯ

- Применение статистических и лингвистических критериев:
- Статистические критерии
Например, функция упорядочивания по статистике:
$$C\text{-Value}(a) = \begin{cases} \log_2 |a| * freq(a), & \text{если } a \text{ не вложено, иначе} \\ \log_2 |a| * (freq(a) - P(Ta)^{-1} * \sum_{b \in Ta} freq(b)) & \end{cases}$$
- где **a** – слово (словосочетание), $|a|$ – его длина,
 $freq(a)$ – частота встречаемости **a** в тексте,
 Ta – множество словосочетаний текста, содержащих **a**,
 $P(Ta)$ – количество словосочетаний, содержащих **a**.
электрический слой - двойной электрический слой

МЕТОДЫ РАСПОЗНАВАНИЯ: ЛИНГВИСТИЧЕСКИЕ КРИТЕРИИ

- грамматические (синтаксические) образцы терминов:
 A N N - *спектральный коэффициент излучения*
- контексты употребления терминов:
effect of T – *effect of drought, effect of cold*
(последствие засухи, заморозков)
such T1 as T2 – *such crimes as money laundering*
(такие преступления, как отмывание денег)
- Лингвистическую информацию можно записать в виде
шаблонов
необходим язык шаблонов и поддерживающие его
средства

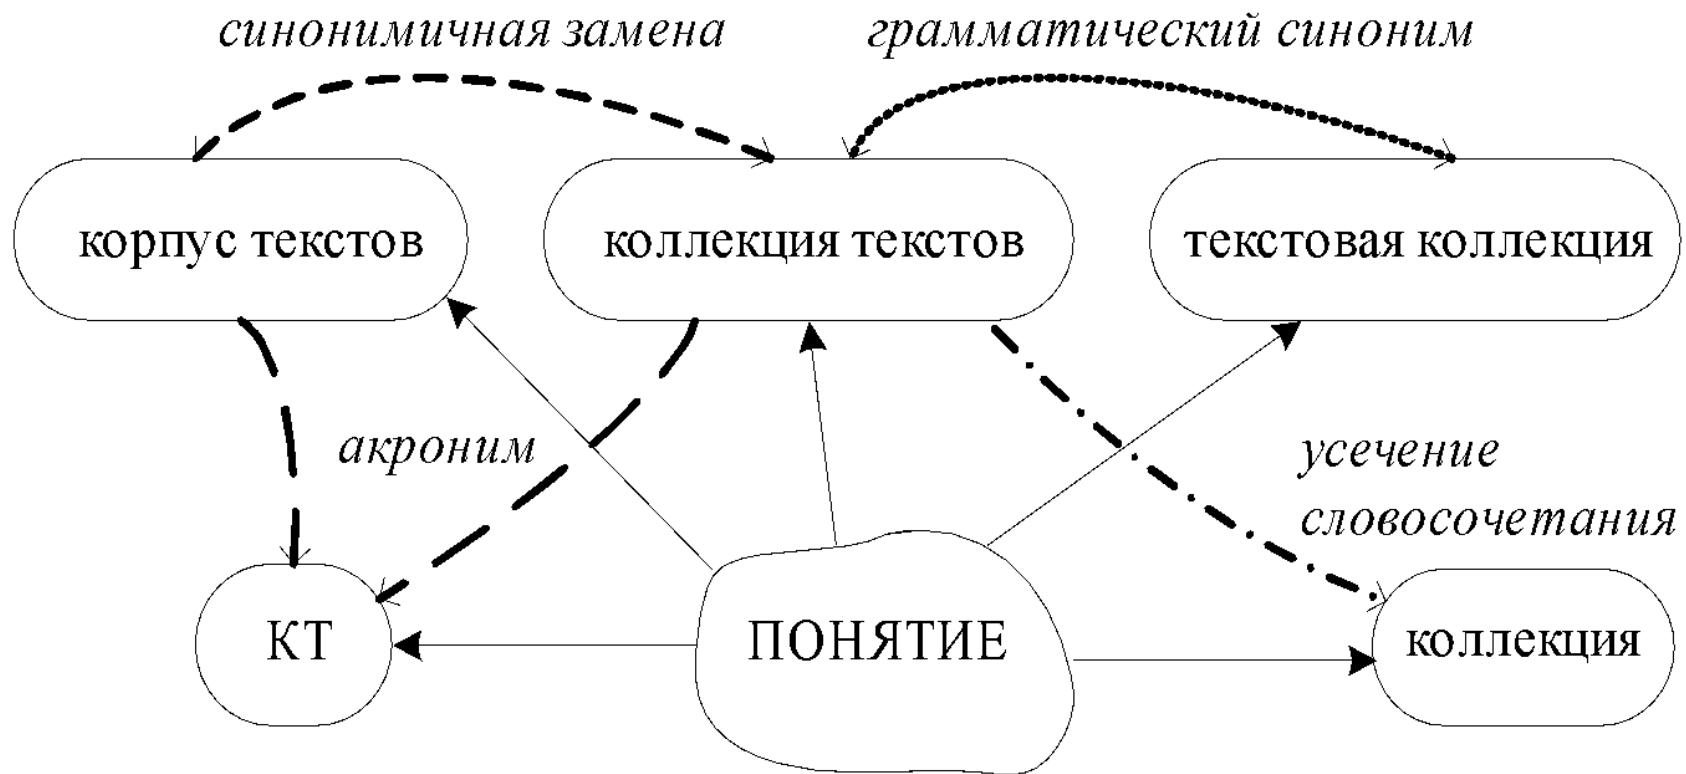
РАСПОЗНАВАНИЕ ТЕРМИНОВ: ТЕКСТОВЫЕ ВАРИАНТЫ

При использовании терминов в тексте они могут образовывать варианты:

- Орфографические варианты: *браузер* - *броузер*
- Морфоварианты: *специсимвол* – *спецзнак*
- Лексико-синтаксические варианты:
механическое напряжение - *напряжение*
дисковый контроллер – *контроллер диска*
- Варианты сокращений: *ЦП*, *авост*

В словаре представлены далеко не все варианты терминов, их необходимо распознавать

ТЕРМИНОЛОГИЧЕСКИЕ ВАРИАНТЫ: ПРИМЕР



РАСПОЗНАВАНИЕ ТЕРМИНОВ: СОЕДИНЕНИЯ ТЕРМИНОВ

Соединения нескольких терминологических словосочетаний:

- Бессоюзные соединения, с разрывом и без разрыва термина:
разрядность внутренних регистров
– *разрядность регистра, внутренний регистр*
- Соединения с союзом:
шинам адреса, данных и управления
– *шина адреса, шина данных, шина управления*

Средство распознавания - лингвистические шаблоны

ШАБЛОНЫ: ЯЗЫК LSPL

Лексико-синтаксический шаблон позволяет задать для элемента-слова:

- часть речи (A, N, V, Ра и т.д.) – A
- индекс – A1 A2 N
- лексему – A<важный>
- морфологические характеристики (имя=значение) – A<важный; case=nom, gen=fem>

Грамматическое согласование элементов шаблона:

A<тяжелый> N <A.gen=N.gen, A.num=N.num, A.case=N.case>

Прилагательное *тяжелый* и существительное согласованы в роде, числе и падеже: *тяжелым вечером, тяжелых камней, тяжелое тело*

ЯЗЫК LSPL-ШАБЛОНОВ: ВОЗМОЖНОСТИ

- $AP = A(A) \mid Pa(Pa)$
- $AN = \{AP\} N <\text{стол}, c=\text{nom}> [“B”] <AP=N> (N)$

Элемент-слово

Альтернативы |

Имя шаблона

Повторение {}

Экземпляр шаблона

Опциональное вхождение []

Условия согласования

Параметры шаблона

LSPL-ШАБЛОНЫ: ПРИМЕРЫ

- Шаблон типичной структуры термина:

A N1 { N2 <case=gen>} (A=N1)

реактивная сила, немаркированный квантор общности

- Шаблон типичной фразы-определения новых терминов:

NP1<c=acc> ["мы"] "назовем" NP2<c=ins> <NP1.n = NP2.n>

*Указанную операцию **назовем** операцией поиска примеров*

- Шаблон образования терминологических вариантов:

N1 N2<c=gen> "," N3<c=gen> {"и"|"или"} N4<c=gen>

#N1 N2<c=gen> , N1 N3<c=gen> , N1 N4<c=gen>

шинам адреса, данных и управления –

шина адреса, шина данных, шина управления

ЗАКЛЮЧЕНИЕ

- В основном – извлечение на основе правил (*rule-based*), все чаще - машинное обучение
- Точность и полнота извлечения
 - зависят от набора шаблонов
 - зависят друг от друга
 - верхняя граница - до 80-90 %
- Сложность задачи (технологическая):
приемлемая полнота и точность достигается
 - на больших массивах текстов
 - обычно в рамках коммерческих компаний

СПАСИБО ЗА ВНИМАНИЕ!