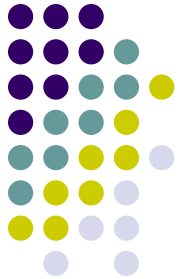

ИЗВЛЕЧЕНИЕ ИНФОРМАЦИИ ИЗ ТЕКСТОВ: ПОРТРЕТ НАПРАВЛЕНИЯ

Большакова Елена Игоревна

МГУ имени М.В.Ломоносова, фак-т ВМК

Летняя школа по АОТиАД, 25 июля 2017

СОДЕРЖАНИЕ

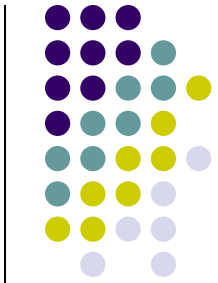

1. Особенности задачи *Information Extraction* (*IE*)
2. Виды извлекаемой информации и особенности ее извлечения
3. Подходы к извлечению информации
4. Инструментальные системы для
5. Оценка качества извлечения, соревнования методов и систем

АКТУАЛЬНОСТЬ ЗАДАЧИ

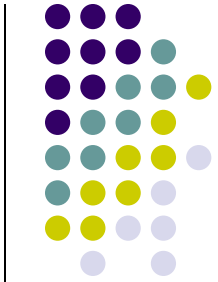

- Рост объема текстовой информации, особенно в сети Интернет: человек не в состоянии охватить ее за приемлемое время
- Нужны программы извлечения и преобразования информации в форму, удобную для дальнейшей обработки
- Возможные приложения:
  - ✓ мониторинг новостных лент
  - ✓ составление дайджестов, рефератов, досье
  - ✓ сбор данных для анализа экономической, производственной и др. деятельности

СПЕЦИФИКА ЗАДАЧИ

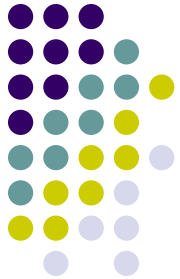

Information Extraction: автоматическое извлечение релевантных данных из текстов на ЕЯ

- Обрабатывается отдельный текст или коллекция текстов, неструктурированные (без метаданных)
- Извлекаются данные, релевантные определенной проблеме, вопросу, теме
- Важно: извлеченные данные
  - ✓ структурируются в виде таблиц, шаблонов
  - ✓ обрабатываются: сортируются, размечаются, отбираются, сохраняются в базах данных
  - ✓ накапливаются в базах знаний

ИЗВЛЕЧЕНИЕ ИНФОРМАЦИИ: ПРИМЕРЫ

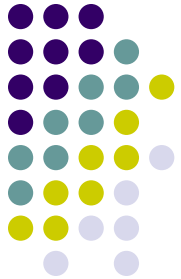

- Извлечение информации о событиях, фактах (деловых визитах):

  Вчера, 1 апреля 2007 года, представители корпорации Пепелац Интернэшнл посетили офис компании Гравицап Продакшнз.

- Извлечение объектов, их атрибутов и отношений:

  Грейс Патриша Келли – американская актриса, мать ныне правящего князя Альбера II.

- Извлечение новых терминов:

  Такие слабовзаимодействующие массивные частицы называют вимпами.

ВИДЫ ИЗВЛЕКАЕМОЙ ИНФОРМАЦИИ

- *Именованные сущности* (*Named Entities, NE*) – значимые объекты : *персоны, названия фирм, белков, марки товаров, геогр. названия* и т.п.
- Атрибуты объектов: для *персоны – должность, место работы*, *телефон*, *подразделение*
- Отношения между объектами: *быть частью*, *быть владельцем*
- Факты/события: *прошла встреча*, *выдан кредит*

А также:

- Термины ПО и их связи, ключевые слова текста
- Отзывы и мнения о товарах, услугах, кино и пр.

ВИДЫ ИЗВЛЕКАЕМОЙ ИНФОРМАЦИИ: ПРИМЕР

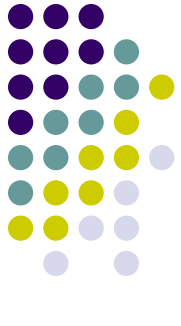

Грейс Патриша Келли
(12.11.1929 – 14.09.1982) – американская актриса,
с 1956 года – супруга князя Монако Ренье III,
10-я княгиня Монако,
мать ныне правящего князя Альбера II.

- Объекты (имен.сущности): ФИО, род занятий +даты
- Отношения:
  – супружество: *Грейс Патриша Келли, Ренье III*
  – быть матерью: *Грейс Патриша Келли, Альбер II*
- Факты и события:
  – *замужество (1956, Грейс П. Келли, Ренье III)*
  – *правящий князь (Монако, Альбер II)*

Можно ли извлечь : *Ренье III – отец Альбера II* ???

ИМЕНОВАННЫЕ СУЩНОСТИ

Изначально именованные сущности – это:

- Имена персоналий: *И. Сечин*, *Ben White*
- Географические названия: *р. Ока*, *гор. Москва*
- Названия компаний/организаций: *РЖД*, *ОАО «Уют»*

Сейчас также выделяют:

- Даты и временные отрезки: *02.03.1913*, *2 p.m.*
- Номера телефонов: *+7(123)456-78-90*
- Адреса: *3-ая улица Строителей д. 25, кв.12*
- Марки товаров: *Nokia*, *Apple*, *Land Rover*
- Обозначения денежных единиц: *руб.*, *$*, *GBP*
- Ссылки на литературу: *[2]*, *[Иванов, 1995]*
- Гены, белки, хим. вещества: $H_2N–CH(R)–COOH$

СЛОЖНОСТИ ИЗВЛЕЧЕНИЯ *NE*

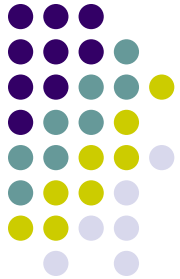

- Большое число разных сущностей/объектов, постоянно появляются новые
- Множество различных способов именования одной и той же сущности: *ВВП, В.В.Путин*

  William H. Gates, *Bill Gates*, *владелец Microsoft, BG*
- Нередко требуется установление *кореференции* имен (тождества обозначаемых объектов – *референтов*)
  ГАИ, *ГИБДД* – это один референт или разные?
- В зависимости от контекста имен. сущность может относиться к разным видам (категориям): *Лена, ВВП*

  В России прошли … – географический объект

  Россия отказалась от … – страна

ОСОБЕННОСТИ ИЗВЛЕЧЕНИЯ ИМЕНОВАННЫХ СУЩНОСТЕЙ

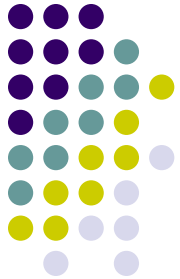

- Опора на соответствующие словари :
  личных имен, географических названий и т.п.
- Учет особенностей наименований:
  - ✓ регистр букв (первая или все большие)
  - ✓ определенные последовательности букв
    (*-ов*, *-дзе* – окончания фамилий,
    -банк, *-инвест* – окончания названий компаний)
  - ✓ внутренняя структура: *ООО, +1(23)45-67*
- Учет контекста (м.б. проверка по всему тексту)
  …станция Зима.., …увидел Зиму…

ОТНОШЕНИЯ И АТРИБУТЫ СУЩНОСТЕЙ

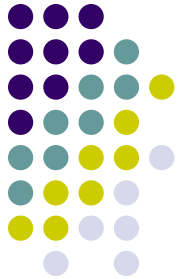

- Атрибуты конкретных объектов
  квартира (продажа/покупка): *адрес, этаж, метраж, количество комнат, лифт, газ, …*
- Отношения (связи) конкретных объектов
  Виды отношений:
  - Общие: *часть-целое*, *причина-следствие*)
  - Зависящие от ПО текста: *работать_в*, *быть_владельцем*, *вступать_в_реакцию*

- При извлечении учитываются типичные конструкции описания атрибутов и отношений
- Сложность: отношения непостоянны

ФАКТЫ И СОБЫТИЯ (*EVENTS*)

- При извлечении факта/события информация структурируется в виде *семантического фрейма*: (набора параметров-атрибутов события)
- Примеры:

Яндекс купил Кинопоиск за 80$ млн. в октябре 2013 г.

Фрейм покупки:

атрибуты:	*Сумма*	*Покупатель*	*Объект*	*Продавец*
	80 млн.$	Яндекс	Кинопоиск	?

Премьер-министр Казахстана Бакытжан Сагинтаев в апреле 2017 посетил офис Microsoft в Сан-Франциско

Фрейм делового визита:

Визитер	*Принимающая сторона*	*Дата*
Бакытжан Сагинтаев	офис Microsoft	04.2017

СЛОЖНОСТИ ИЗВЛЕЧЕНИЯ ФАКТОВ И СОБЫТИЙ

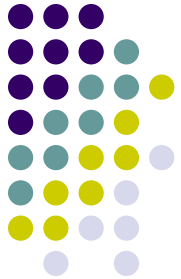

- Событие/факт в тексте может выражаться по-разному

  Минобороны РФ ответило британскому министру обороны…

  В Минобороны РФ ответили на обвинения британского министра…

- Часто сложно найти слово или словосочетание, которое выражает суть события
- Могут встречаться слова, меняющие суть (*почти*, *не*)
- Нередко необходимо слияние частичных описаний, полученных из разных предложений

13

ПОДХОДЫ К ИЗВЛЕЧЕНИЮ ИНФОРМАЦИИ

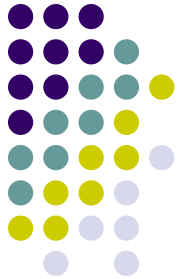

- Машинное обучение: необходим обучающий корпус +
  - ✓ деревья принятия решений (*DT*)
  - ✓ скрытая марковская модель (*HMM*)
  - ✓ модель максимальной энтропии (*MI*)
  - ✓ и др.
- Инженерный подход: применение лингвистических правил и шаблонов, содержащих лексическую и грамматическую информацию об извлекаемой конструкциях
  - ✓ правила и шаблоны составляют эксперты
  - ✓ часто применяются специальные языки записи правил и поддерживающие их системы
- Комбинирование этих подходов

МАШИННОЕ ОБУЧЕНИЕ

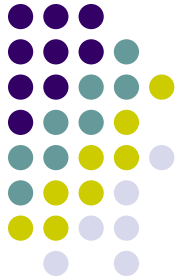

Например, для именованных сущностей:

- Имена и названия размечаются:
  $[Владислав]_{PERS}$ $[Сурков]_{PERS}$ $[встретится]_{O}$ $[с]_{O}$
  $[президентом]_{O}$ $[Абхазии]_{LOC}$ $[Раулем]_{PERS}$ $[Хаджимба]_{PERS}$
- Определяются различные признаки слов:
  – признаки самого токена (слова): регистр букв, лемма, часть речи, длина и др.
  – словарные признаки (вхождение в опред. словарь)
- По этим частным данным выявляются общие закономерности
- Методы машинного обучения различаются способами учета признаков

МАШИННОЕ ОБУЧЕНИЕ: СОВРЕМЕННЫЕ ТЕНДЕНЦИИ

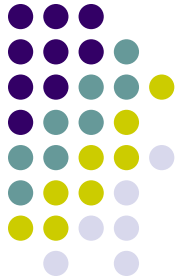

- Применение лингв. ресурсов (Wikipedia, Freebase): классификация сущностей, атрибутов и т.д.
- Поиск естественно размеченных данных
- Учет большого числа признаков разного вида
- Ипользование сложной разметки
- Применение мета-алгоритмов обучения, *bootstrapping:* обучение начинается с небольшого количества размеченных данных, итеративное расширение обучающего множества

ЭТАПЫ ОБРАБОТКИ ТЕКСТА ПРИ ПОДХОДЕ НА ПРАВИЛАХ

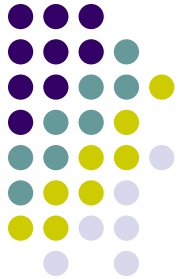

- Графематика (токенизация)
- Морфологический анализ
- Лексический анализ
  - разрешение лексической многозначности
- Синтаксический анализ
  - при использовании *лингвистических шаблонов* часто достаточно частичного синтаксического анализа (*shallow approach*, *shallow parsing*)
- Дискурсивный и семантический анализ
  - анализ анафорических ссылок, кореференции
  - слияние (объединение) извлеченных атрибутов фактов/событий в единое описание

ЛИНГВИСТИЧЕСКИЕ ШАБЛОНЫ

- *Лингвистический шаблон* – описание языковой конструкции, ее лексического состава и грамматических свойств:

  N «работает в» NP
  N «купил» N

  N – существительное
  NP (Noun Phrase) – группа существительного

- Основные элементы шаблонов:
  - Словоформы, леммы: возможно указание части речи/морфологических характеристик
  - Грамматические образцы: именные и др. группы

    A + N – информационная система (A – Adjective)
- Шаблоны могут учитывать особенности слов: регистр букв, последовательности букв

ЛИНГВИСТИЧЕСКИЕ ШАБЛОНЫ: ПРИМЕРЫ

- Объекты и атрибуты:

  ([А-Я] [а-я]+)банк – *Собинбанк*

  A N Ngen – *ведущая актриса театра*

- Отношения между объектами (*NP* – именная группа)

  NP1 «является частью» NP2

  Процессор является частью компьютера

- Факты и события:

  Loc «пошел ко дну» Ship

  Ship «затонул» Loc

  В Бенгальском заливе пошел ко дну корабль ВМС Индии

  Корабль ВМС Индии затонул в Бенгальском заливе

ИЗВЛЕЧЕНИЕ НА ПРАВИЛАХ: СОВРЕМЕННЫЕ ТЕНДЕНЦИИ

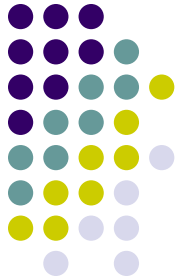

- Автоматическое расширение набора правил
- Автоматизация построения шаблонов и правил
  - Имеется множество пар сущность – отношение
  - В текстах выявляются упоминания этих пар, анализируется контекст (слова слева и справа)
  - Формируются наиболее вероятные шаблоны
  - Эти шаблоны проверяются на других текстах
- Применение инструментальных систем со специализированными языками правил

ИНСТРУМЕНТЫ ПОСТРОЕНИЯ СИСТЕМ ИЗВЛЕЧЕНИЯ

Свободно доступны

- Построение на основе обучения:
  OpenNLP (именованные сущености)
  StanfordCore NLP (все виды *IE*)
  - Есть встроенные машинные классификаторы и возможность построить свои
  - Не ориентированы на русскоязычные тексты
- Построение на основе правил*:*
  GATE, Томита-парсер, *LSPL*
  - Формальный язык правил и шаблонов, с их помощью – настройка на конкретную задачу *IE*
  - Возможность работы с русскими текстами

СИСТЕМА *GATE*

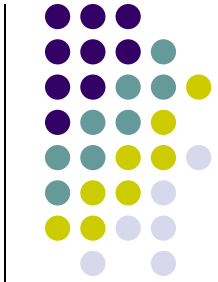

Среда построения *IE*-приложений на любом ЕЯ (*https://gate.ac.uk*) Архитектурные особенности:

- Есть набор стандартных компонентов (процессоры, словари) для обработки текста
- Приложение собирается из этих компонентов (с помощью среды пользователя)
- В ходе обработки текста информация хранится в форме *аннотаций* – наборов атрибутов вида:

  имя_атрибута == *значение_атрибута*
- Анализ текста – последовательное создание и переработка аннотаций по заданным правилам
- Язык лингвистических правил *Jape*

СИСТЕМА *GATE*: *JAPE*-ПРАВИЛА

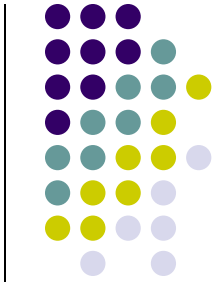

- Правила на языке *Jape* состоят из двух частей:
  - ✓ левая – шаблон для текстового фрагмента
  - ✓ правая – действия с его аннотациями
- Правило для выявления города рождения во фразах вида *Иван родился в Самаре*:

```
Rule: BornPlace
(({Token.kind == word, Token.orth == upperInitial}):
person
{Token.string == "родился"}
{Token.string == "в"}
({Lookup.majorType == "City"}): city)
 --> person.Name = {BirthCity = city.Token.string}
```

ТОМИТА-ПАРСЕР

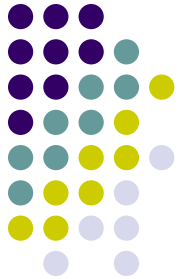

- Система ориентирована на извлечение фактов из текстов на русском языке (https://tech.yandex.ru/tomita/)
- Последовательность этапов обработки текста фиксирована
- Правила извлечения записываются на языке расширенных КС-грамматик (с условиями)
- Широкий набор встроенных помет-ограничений на значения грамматических и неграмматических характеристик слов
- Встроенные средства описания структуры извлекаемых фактов

ТОМИТА-ПАРСЕР: ИЗВЛЕЧЕНИЕ ФАКТОВ

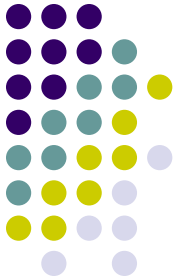

- Пример правила:
  S –> Person<gn–agr[1]> interp(BornFact.Person)
  Born<gn–agr[1]> "в" City interp(BornFact.City);
  где *<gn–agr[1]>* – согласование по роду и числу,
  interp – в какой факт нужно извлечь слово
- Из фразы *Иван родился в Самаре* извлекается факт *BornFact {Person = Иван; City = Самара}*
- Типы фактов описываются отдельно от грамматики
  message BornFact: NFactType.TFact {
  required string Person = 1;
  required string Place = 2; }

LSPL И ЕГО ПРОГРАММНЫЕ СРЕДСТВА

- Декларативный язык для описания конструкций, распознаваемых в РЯ текстах, в виде лексико-синтаксических шаблонов, (*www.lspl.ru*)
- Визуальная среда анализа текстов по шаблонам
- Программные средства поддержки языка позволяют
  - находить в тексте конструкции по их шаблонам
  - преобразовывать найденные конструкции в некоторый текст

Правило для извлечения города рождения из фраз вида *Иван родился в Самаре*:

BornPlace = N V<родиться> "в" City =text> #City

СРАВНЕНИЕ ИНСТРУМЕНТАЛЬНЫХ СИСТЕМ

	GATE	*Томита-парсер*	*LSPL*
Извлечение информации	Нет	Есть	Есть
Визуальная среда	Есть	Нет	Есть
Поддержка РЯ	Недостаточная	Достаточная	Достаточная
Язык шаблонов	Сложный и громоздкий	Мощный для извлечения фактов	Удобный, но менее мощный
Прилагательное в именительном падеже: *JAPE*: {Morph.SpeechPart="Adjective", Morph.Case="Nominative"} Томита-парсер: Adj<gram="nom"> *LSPL*: A<c=nom>			
Особенности	Можно выстроить свою посл-сть этапов анализа	Извлечение фактов	Возможность автоматической генерации шаблонов

ОЦЕНКИ КАЧЕСТВА ИЗВЛЕЧЕНИЯ ИНФОРМАЦИИ

Результаты работы системы

эксперт / система	правильные (positive – P)	неправильные (negative – N)
правильные (P)	True P = TP	False P = FP
неправильные (N)	FN	TN

- Точность (*Precision*) – отношение найденных правильных к общему количеству найденных

```
P = TP / (TP + FP)
```

- Полнота (*Recall*) – отношение найденных правильных к общему количеству правильных

```
R = TP / (TP + FN)
```


28

ДРУГИЕ МЕРЫ ЭФФЕКТИВНОСТИ ИЗВЛЕЧЕНИЯ ИНФОРМАЦИИ

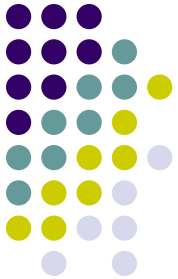

- *F-мера* – соотношение между **P** и **R**

$$F = \frac{(\beta^2 + 1)PR}{\beta^2 R + P}$$

где β – коэффициент относительной важности, обычно $\beta=1$

- Ошибка (*Error*) – отношение неправильно принятых решений к общему числу решений

$$E = (FP + FN) / (TP + FP + TN + FN)$$

- Аккуратность (*Accuracy*) – отношение правильно принятых решений к общему числу решений

$$A = (TP + TN) / (TP + FP + TN + FN)$$

29

СОРЕВНОВАНИЯ СИСТЕМ ИЗВЛЕЧЕНИЯ ИНФОРМАЦИИ

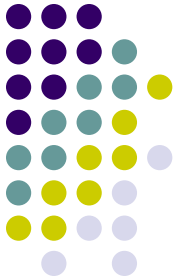

- *MUC* (*Message Understanding Conference*) проводилась с 1987 по 1998 годы
  - ✓ 1995 (*MUC*-6) – служебные перемещения: назначения и отставки
  - ✓ 1998 (*MUC*-7) – запуски космических кораблей и ракет
- *РОМИП* (российский семинар по оценке методов информационного поиска)
  - ✓ 2004 – поиск событий, связанных с персоной
  - ✓ 2005 – выделение именованных сущностей и фактов заданных типов
- *FactRuEval 2016* (в рамках конференции Диалог)

MUC-6 и *MUC*-7

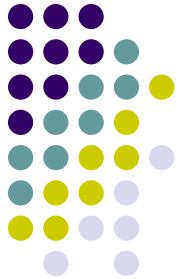

- Примеры атрибутов в *MUC*-7: *запущенный аппарат*, *дата запуска*, *место запуска*, *тип задания* (*военный*, *гражданский*)
- Примеры результатов:

  Извлечение именованных сущностей

  Машинное обучение (*HMM*)

  MUC-6: F=93% *MUC*-7: F=90,4%

  Извлечение на основе правил:

  MUC-6: F=96,4% *MUC*-7: F=93,7%

  Извлечение событий и фактов

  На основе правил: P=90%, R=20%

FactRuEval 2016

- Новостная коллекция
- Три подзадачи выделения:
  - ✓ именованных сущностей (организация, персона, географический объект)
  - ✓ сущностей и их атрибутов
  - ✓ фактов из текстов (найм, сделка, владение, встреча)
- 13 участников, большинство использовали инженерный подход с элементами статистики
- Автоматическая система оценки результатов, в открытом доступе
- Лучшие значения – для 1 и 2 дорожки (F1 = 93%), худшие – для фактов (F1=66%)

32

ЗАКЛЮЧЕНИЕ

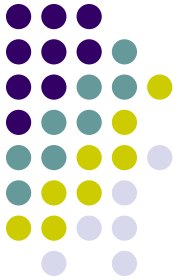

- Задача *IE* актуальна, много приложений
- Подходы к решению:
  – машинное обучение: хорошо работает для извлечения сущностей
  – подход на правилах обычно лучше для выделения событий и фактов
- Направления развития:
  - проведение более глубокого синтаксического анализа и использование синтаксических признаков при машинном обучении
  - визуализация извлеченной и структурированной информации, удобная для человека-аналитика

СПАСИБО ЗА ВНИМАНИЕ!