

Проект

Извлечение фактов

из текста

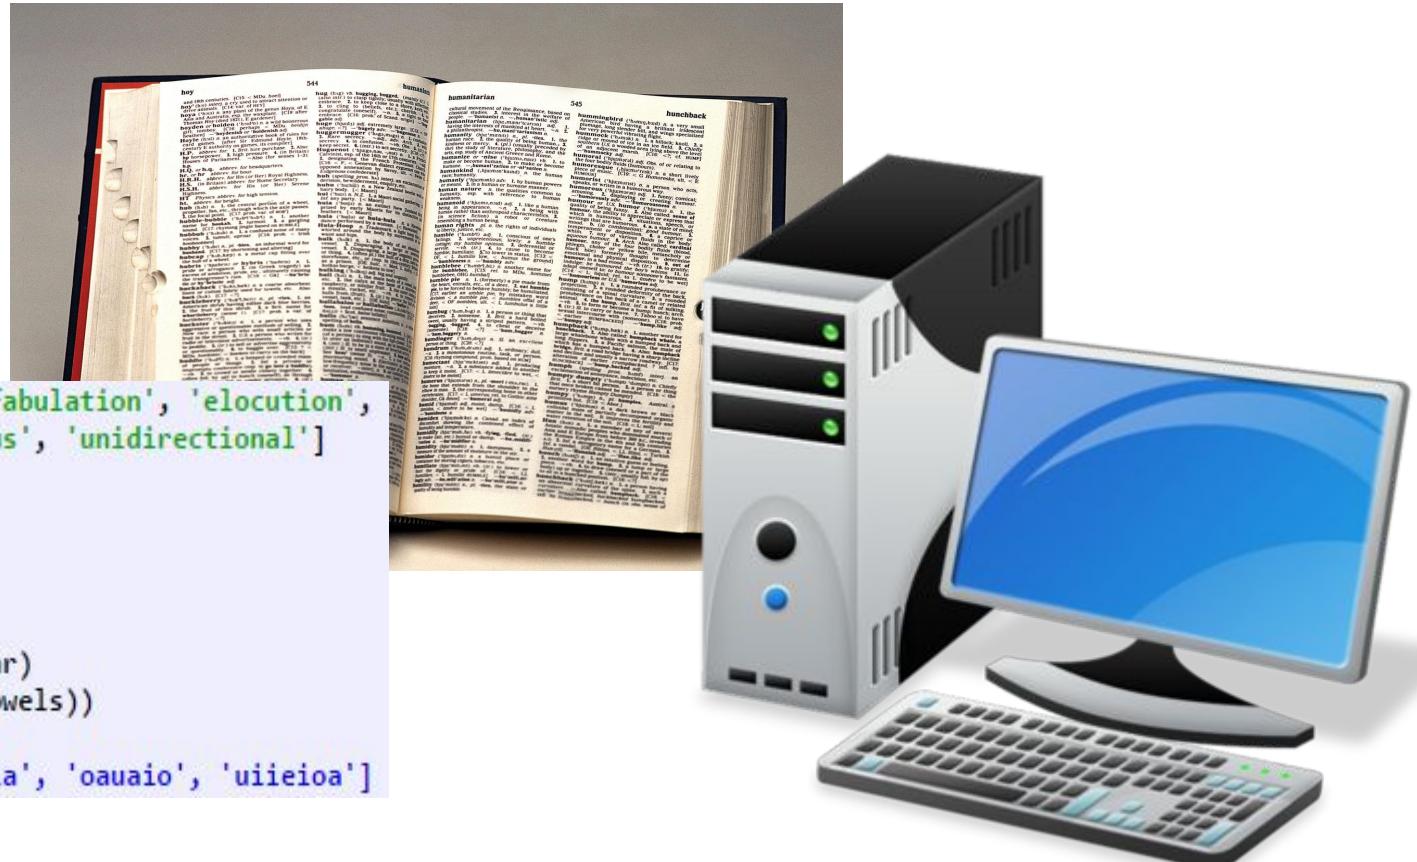
Лаборатория

математической лингвистики

Что такое компьютерная лингвистика?

Компьютерная лингвистика изучает язык с позиции его использования в компьютерных системах.

```
>>> words = ['attribution', 'confabulation', 'elocution',
...           'sequoia', 'tenacious', 'unidirectional']
>>> vsequences = set()
>>> for word in words:
...     vowels = []
...     for char in word:
...         if char in 'aeiou':
...             vowels.append(char)
...     vsequences.add(''.join(vowels))
>>> sorted(vsequences)
['aiuio', 'eaiou', 'eouio', 'euoia', 'oauaio', 'uiieioa']
```



Задачи компьютерной лингвистики:

- автоматическое составление словарей и грамматик;
- анализ естественно-языковых текстов;
- создание и использование текстовых корпусов;
- машинный перевод;
- информационный поиск;
- автореферирование;
- создание систем искусственного интеллекта и др.



- Извлечение фактов (структурированной информации) из неструктурированного текста - **Text Mining**.
- С помощью этой технологии можно представлять данные из текстов на естественном языке в формализованном виде для дальнейшей **машинной обработки**.
- Извлечение фактов - одна из задач **компьютерной лингвистики**.

Где применяются технологии извлечения фактов?

Яндекс – Почта, Новости, Карты и др. сервисы.

Встреча с

Анна Кузина [https://yandex.ru/.../...](#)

Био [new@yandex.ru](#)

Первые Статьи правки Сайты почты

Добрый день!

Место встречи - г. Новосибирск, Морской пр-д, 54 Увидимся 20 августа!



Где применяются технологии извлечения фактов?

Встреча



Anna Kudova anna0204@yandex.com

Кому koi296@yandex.ru

Пересыпь Сделать правоо. Сайтка письма

Добрый день!

Место встречи - г.Новосибирск, Морской пр-т, 54 Увидимся 20 августа!

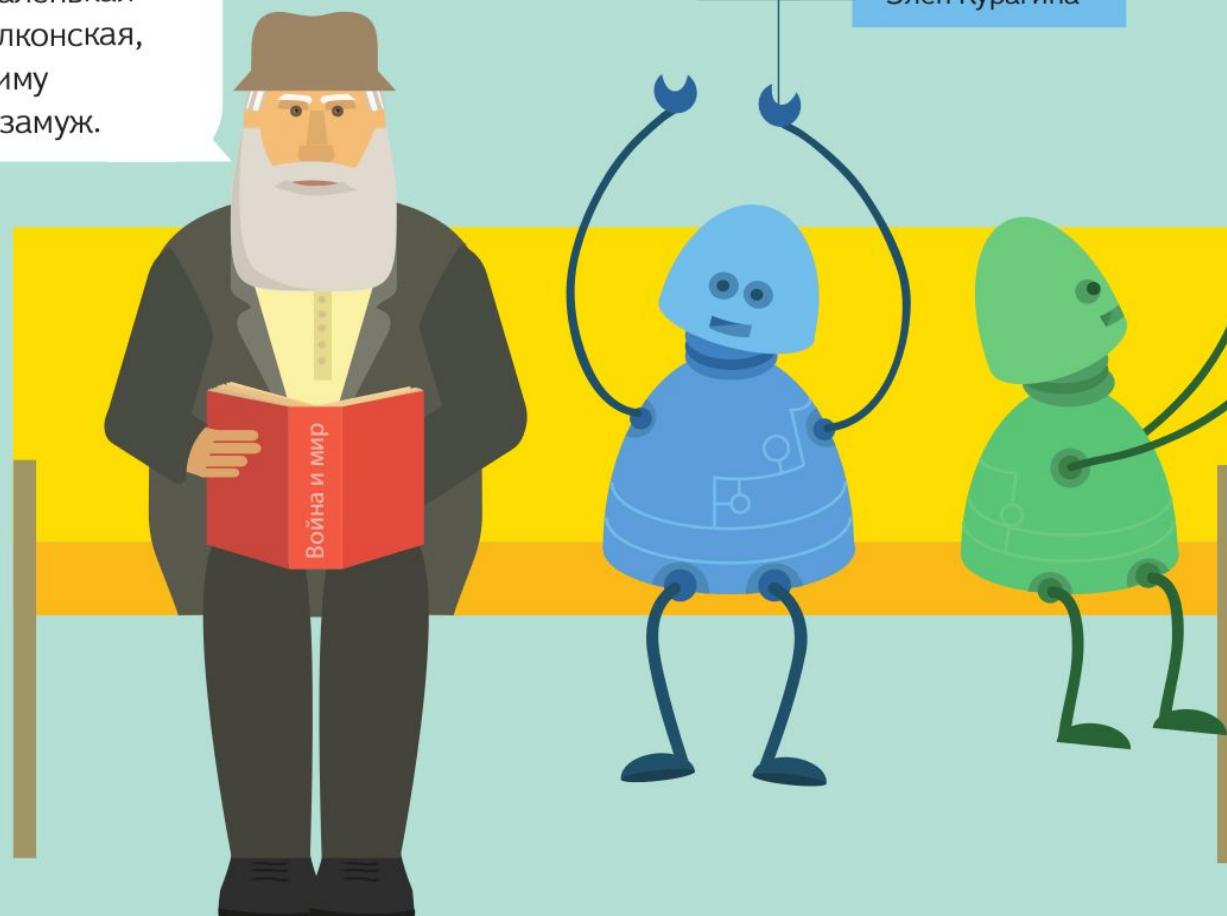


Где применяются технологии извлечения фактов?

- В поисковых системах, например Google и Yandex, для сбора информации о пользователе.
- При автоматическом построении предметных областей.
- Для представления текстовой информации в удобном виде для машинной обработки.

Пример извлечения фактов

Вошла дочь князя
Василия, красавица
Элен, заехавшая
за отцом, чтобы с ним
вместе ехать на праздник
посланника. Приехала
и известная как
самая обворожительная
женщина Петербурга
молодая, маленькая
княгиня Болконская,
прошлую зиму
вышедшая замуж.



Задача проекта:

извлечение фактов из текстов для структурирования информации.

Под «фактом» понимается набор извлеченных сущностей, связанных определенным отношением.

Источник: научные тексты по химии.

Примеры неструктурированного текста:

- В 1771 году **Карл Шееле** получил плавиковую кислоту.
- В природе значимые скопления **фтора** содержатся в основном в минерале **флюорите** (**CaF₂**).
- **Глюкоза** - бесцветное **кристаллическое вещество** сладкого вкуса, **растворимое в воде**.
- При окислении образует **глюконовую кислоту**.

Получаем на выходе:

Название вещества	Формула	Физические свойства	Температура плавления	Температура кипения
глюкоза	C ₆ H ₁₂ O ₆	кристаллическое вещество сладкого вкуса, растворимое в воде	150 °C	
гидроксид меди(I)	CuOH	жёлтое вещество, не растворяется в воде		
аммиак	NH ₃	бесцветный газ с резким запахом	-77.73 °C	-33.34 °C

Инструменты для работы

- **Томита-парсер** — это инструмент для извлечения структурированных данных (фактов) из текста на естественном языке. Это технология, разработанная Яндексом.
- Для извлечения информации из текста с помощью томита-парсера нужно писать **грамматики**.

Грамматика томита-парсера

Так выглядит часть грамматики для томита-парсера (для извлечения места рождения человека):

Born -> Verb<kwtype=born>;

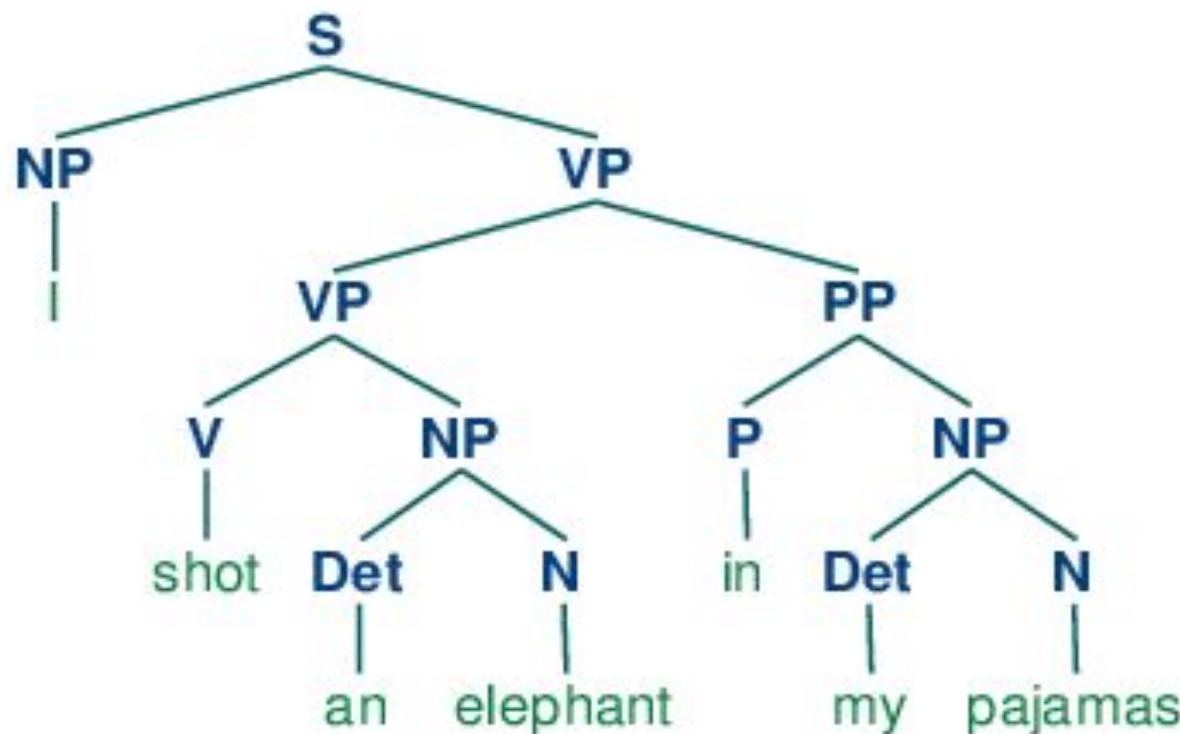
City -> Noun<kwtype=city>;

Person -> AnyWord<gram="имя">;

S -> Person interp(BornFact.Person) Born "в"
City interp(BornFact.Place);

Грамматика томита-парсера

- Язык описания грамматик для томита-парсера построен на основе **порождающих грамматик**.



Источники:

- Блог Яндекса на Хабре

[http://habrahabr.ru/company/yandex/blog/2193
11/](http://habrahabr.ru/company/yandex/blog/219311/)

- [http://habrahabr.ru/company/yandex/blog/2051
98/](http://habrahabr.ru/company/yandex/blog/205198/)

- Скриншоты с Яндекс Почты

Спасибо за внимание!