МЕТОДЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

ГАЗАНОВА Н.Ш.

1. НАПРАВЛЕНИЯ

ПОДРАЗДЕЛЫ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА

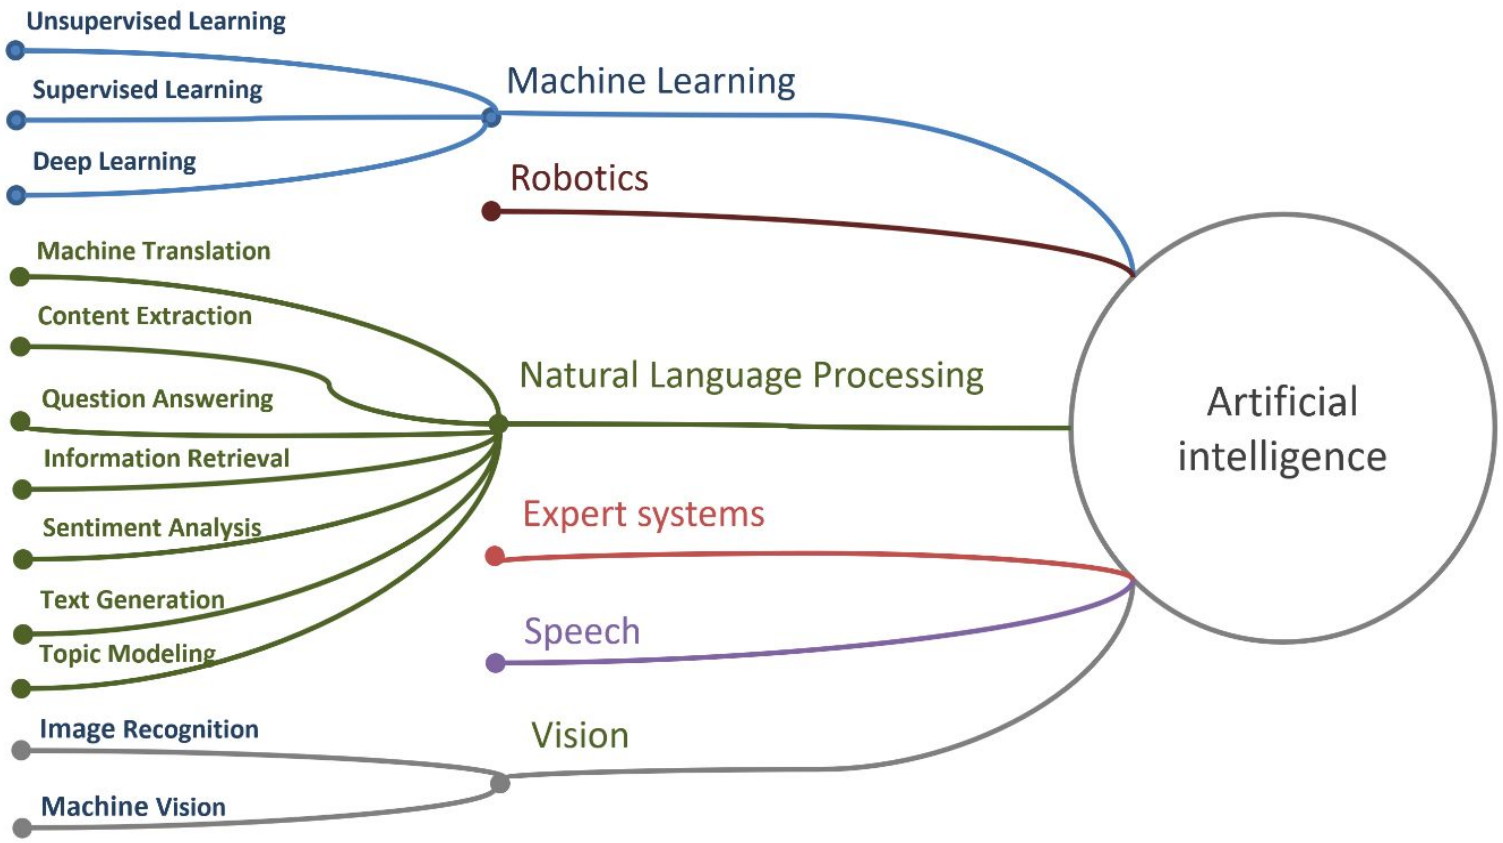

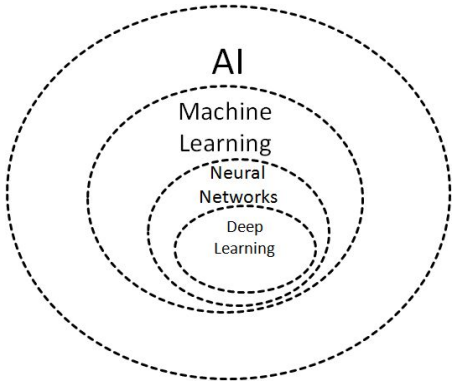

ОБРАБОТКА ЕСТЕСТВЕННОГО ЯЗЫКА

a. Синтаксис
b. Поиск
c. Семантика
d. Векторная модель и машинное обучение

СИНТАКСИС

- Формальные грамматики， грамматики Хомского
- Прагматика， семантика и синтаксис
- Применение синтаксиса для токенизации
- Применения синтаксиса для задач семантики

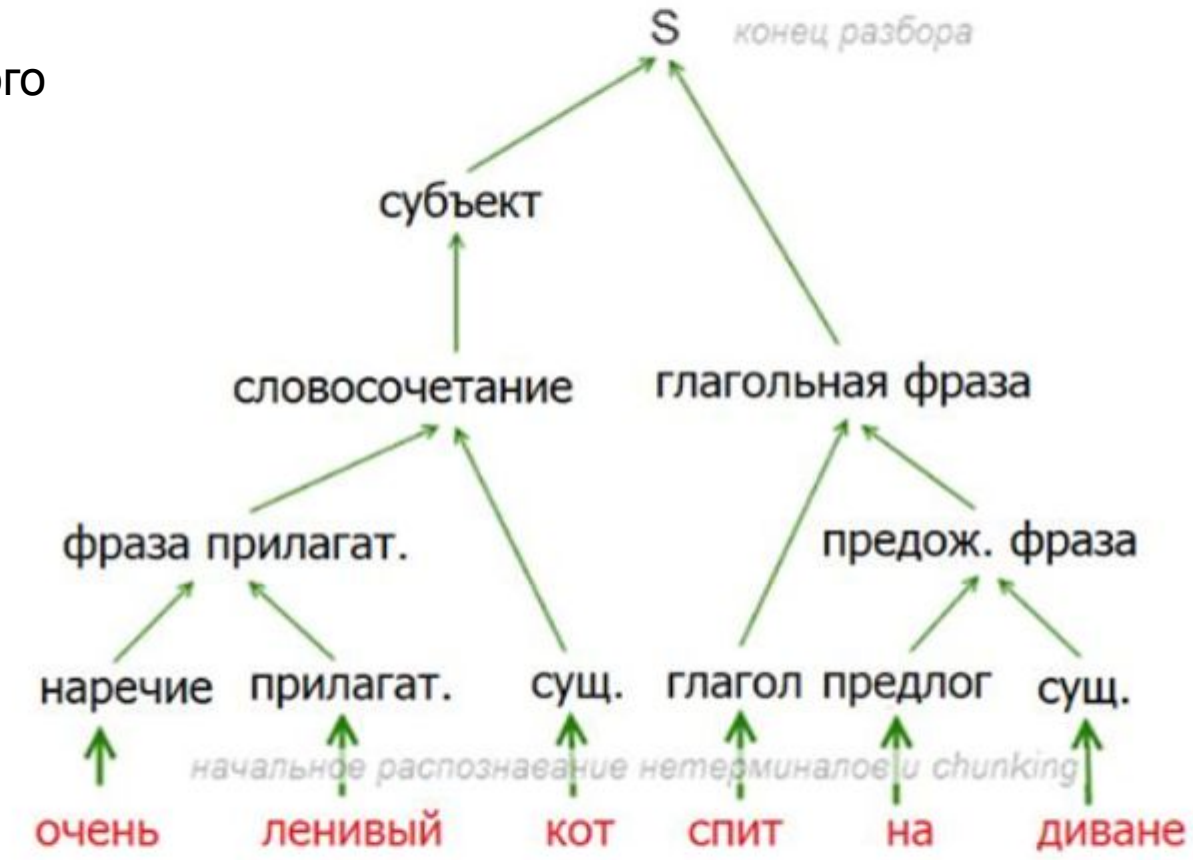

СИНТАКСИС-ИНСТРУМЕНТЫ

— https://yandex.ru/dev/tomita/ — парсер для русского

— https://github.com/natasha/natasha — NLP-библиотека для русского

— https://github.com/kmike/pymorphy2 — склонения и падежи для русского и украинского

— https://deeppavlov.ai/ — анализ, ответы на вопросы, общение

— https://github.com/nlpub/pymystem3 — стеммер для русского

Стемминг - отсечение от слова окончаний и суффиксов, чтобы оставшаяся часть, называемая *stem*, была одинаковой для всех грамматических форм слова.
http://snowball.tartarus.org/algorithms/russian/stemmer.html - алгоритм

ПОИСК

- Предобработка текста
- Построение поискового индекса
- Выполнение запроса
- Закон Ципфа и его влияние на селективность и масштабирование

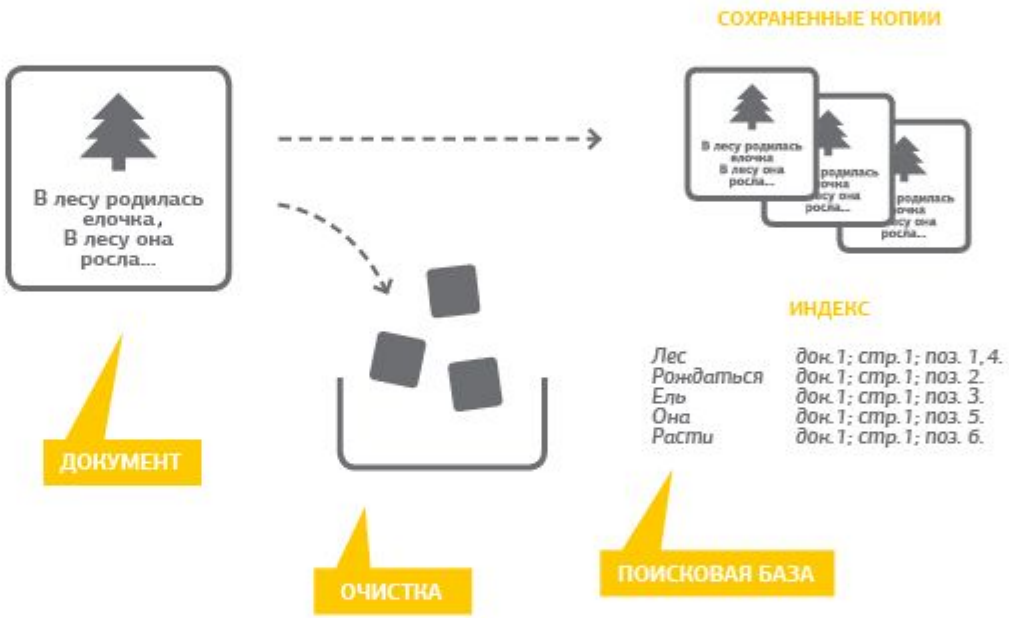

Чтобы понять, что именно ищет пользователь, поисковая система проводит тщательный лингвистический анализ запроса. Сначала определяется язык, на котором был сформулирован запрос. Например, в Яндексе индикатором языка является алфавит, используемый в запросе, а также характерные особенности сочетания букв, присущие различным языковым группам.

Далее проводится работа по трактовке морфологии. Поисковая система различает не только слова из запроса во всех их морфологических формах, но и синонимы, однако при ранжировании предпочтение отдается точному вхождению.
Также поисковым системам приходится разграничивать омонимы (слова с одинаковым написанием, но разным значением).

Например, одно и то же слово может быть истолковано и как глагол, и как существительное.
Определиться с наиболее вероятным списком форм помогает статистика совместной встречаемости слов и грамматических признаков. Для сбора статистики Яндекс использует национальный корпус русского языка и свои собственные корпусы, в которых собрано огромнейшее количество текстов.

ПОИСК

- Предобработка текста
- Построение поискового индекса
- Выполнение запроса
- Закон Ципфа и его влияние на селективность и масштабирование

1—100

Первые сто слов покрывают **37 %** всех текстов.

1. и
2. в
3. не
4. на
5. я
6. быть
7. он
8. с
9. что
10. а
11. по
12. это
13. она
14. этот
15. к
16. но
17. они
18. мы
19. как
20. из
26. что
27. весь
28. год
29. от
30. так
31. о
32. для
33. ты
34. же
35. все
36. тот
37. мочь
38. вы
39. человек
40. такой
41. его
42. сказать
43. только
44. или
45. ещё

СЕМАНТИКА

Дистрибутивная гипотеза и избыточность языка

На небе только и разговоров , что о море и о _____. Там говорят о том , как чертовски здорово наблюдать за огромным огненным шаром , как он тает в волнах . И еле видимый свет , словно от свечи , горит где - то в глубине ..

TF-IDF и терм-документная матрица

Терм-документная матрица представляет собой математическую матрицу, описывающую частоту терминов, которые встречаются в коллекции документов. В терм-документной матрице строки соответствуют документам в коллекции, а столбцы соответствуют терминам. Существуют различные схемы для определения значения каждого элемента матрицы. Одной из таких является схема TF-IDF. Они полезны в области обработки естественного языка, особенно в методах латентно-семантического анализа.

При создании базы данных терминов, используемых в наборе документов, матрица терминов формируется как матрица инцидентности, строки которой соответствуют документам, а элементы строк - наличию соответствующих терминов в этих документах.

СЕМАНТИКА

- Векторная модель : концепты , ортогональность и метрика

Vector Space Model (VSM) – это математическая модель представления текстов, в которой каждому документу сопоставлен вектор, выражающий его смысл. Такое представление позволяет легко сравнивать слова, искать похожие, проводить классификацию, кластеризацию и многое другое. Но обо всём по порядку.

- Метод главных компонент для понижения размерности и выделения ортогональных концептов

Один из основных способов уменьшить размерность данных, потеряв наименьшее количество информации. Изобретён Карлом Пирсоном в 1901 году. Применяется во многих областях, в том числе, в эконометрике, биоинформатике, обработке изображений, для сжатия данных, в общественных науках.

2. ВЕКТОРНЫЕ МОДЕЛИ И МАШИННОЕ ОБУЧЕНИЕ

ЗАДАЧА

Метод главных компонент рассматривает текст как мешок слов . Для коротких текстов это работает хорошо , но для длинных текстов это уже не так . Кроме того , разница между “A убил B” и “B убил A” будет потеряна .

Методы *2vec рассматривают слово в маленьком контексте , что привносит элемент порядка в обучение .
Ваша задача построить поисковый движок на базе doc2vec . * Пример обучения модели doc2vec по ссылке

В УГОДУ СКОРОСТИ

Натренированные векторные представления:

- EN: English word vectors · fastText
- RU: natasha/navec; RusVectōrēs: модели

3. GOOGLE COLAB NOTEBOOK

ТЕСТ

Почему использование Jupyter Notebooks и Google Colab для упаковки кода и текстов сейчас наиболее распространена при обмене решениями в индустрии. Отметьте все верные утверждения:

1. Позволяет использовать документ с кодом без переключения окон

2. Можно просматривать в браузере

3. Позволяет легко получить скомпилированный бинарный файл

4. Можно исполнять без установки ПО на собственный компьютер

ТЕСТ

Почему использование Jupyter Notebooks и Google Colab для упаковки кода и текстов сейчас наиболее распространена при обмене решениями в индустрии. Отметьте все верные утверждения:

1. **Позволяет использовать документ с кодом без переключения окон**

2. **Можно просматривать в браузере**

3. Позволяет легко получить скомпилированный бинарный файл

4. **Можно исполнять без установки ПО на собственный компьютер**

СПАСИБО ЗА ВНИМАНИЕ!