Математические модели в лингвистике

2. Компьютерная лингвистика

Мати Пентус, Александр Пиперски,
Алексей Сорокин

МГУ им. М. В. Ломоносова,
межфакультетский курс,
осенний семестр 2017–2018 учебного года

Математические модели в лингвистике

- Решение практических задач: компьютерная лингвистика (1-я часть семестра)
- Решение научных задач (2-я часть семестра)

Компьютерная лингвистика

- Разные понимания методов и предмета компьютерной лингвистики
- «Компьютерная лингвистика – 1» vs. «Компьютерная лингвистика – 2» [Селегей 2012]

Компьютерная лингвистика – 1

- Формальная, полная и логически непротиворечивая теория языка, которая может использоваться для компьютерного анализа текстов

Компьютерная лингвистика – 2

- Технология и методология решения конкретных практических задач без претензий на общую теорию языка:
  - написание текста
  - машинный перевод
  - поиск и извлечение информации
  - естественно-языковые интерфейсы
  - ...

КЛ–1 и КЛ–2

- Расцвет КЛ–1: 1950-е – 1970-е годы
- Расцвет КЛ–2: 1990-е – 2000-е годы

Русское склонение: КЛ–1

секу́нда ж 1a
му́нда п 0 (языки́ му́нда)
ерунда́ ж 1b—
[1]ры́нда мо ⟨жо 1a⟩ *(истор.: оруженосец)*
[2]ры́нда ж 1a *(судовой колокол)*
дурры́нда мо-жо 1a
гирля́нда ж 1a
о́да ж 1a
свобо́да ж 1a
несвобо́да ж 1a

слобода́ ж 1f
вода́ ж, 1d′ // *устар.* 1f′ ◇ на́ воду // на во́ду; спусти́ться (уйти́ *и т. п.*) по́д воду [// под во́ду]; ходи́ть (пойти́) по́ воду; вы́мыть в дву́х (трёх *и т. д.*) вода́х
подво́да ж 1a
воево́да мо ⟨жо 1a⟩
па́года ж 1a

Решаем задачу

- Задача с Московской традиционной олимпиады по лингвистике и математике для школьников
- Исходим из предположения, что морфологический анализатор построен

Алгоритм

- Привести все слова в заголовках статей и в запросах к начальной форме всеми возможными способами
- Исключить из рассмотрения стоп-слова (предлоги и союзы)
- Найти те заголовки статей, которые пересекаются с запросом хотя бы по одной начальной форме

помятые брюки

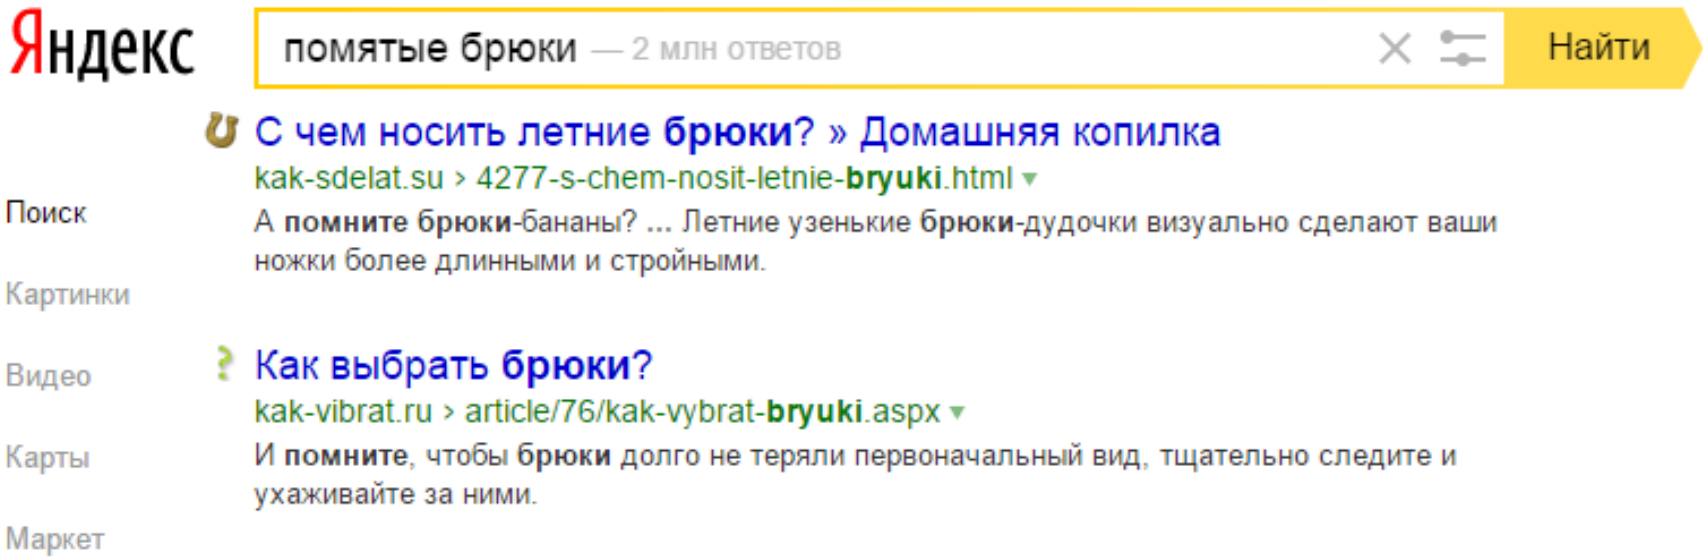

Омонимия

- **Омонимия** — одно из наиболее неудобных свойств для автоматической обработки естественного языка
- В естественной жизни мы почти не замечаем омонимию

Омонимия в юморе

- *Женщина перед свадьбой говорит «Ты мой» и только после свадьбы уточняет, что именно мыть*
- *Из окна дуло. Штирлиц выстрелил, дуло исчезло*

[Санников 2002, 283–284]

Предложение из НКРЯ

- *В кодексе мой грех стоит три года общего режима* [Андрей Рубанов. Сажайте, и вырастет (2005)]
- Сколько слов здесь имеет неоднозначный разбор?

Предложение из НКРЯ

- *мой*, *стоит*, *три*: непонятна начальная форма
- *грех*, *года*, *общего*: непонятны грамматические признаки
- *В*, *кодексе*, *режима*: однозначно

Вывод Mystem (1)

В{в=PR=|в=S,сокр=пр,мн|=S,сокр=пр,ед|=S,сокр=вин,мн|=S,сокр=вин,ед|=S,сокр=дат,мн|=S,сокр=дат,ед|=S,сокр=род,мн|=S,сокр=род,ед|=S,сокр=твор,мн|=S,сокр=твор,ед|=S,сокр=им,мн|=S,сокр=им,ед}
кодексе{кодекс=S,муж,неод=пр,ед}
мой{мой=APRO=вин,ед,муж,неод|=APRO=им,ед,муж|мыть=V,несов,пе=ед,пов,2-л}

Вывод Mystem (2)

грех{грех=S,муж,неод=вин,ед|=S,муж,неод=им,ед|грех=ADV,прдк=}
стоит{стоять=V,несов,нп=непрош,ед,изъяв,3-л|стоить=V,несов=непрош,ед,изъяв,3-л}
три{три=NUM=им|=NUM=вин,неод|тереть=V,несов,пе=ед,пов,2-л}
года{год=S,муж,неод=вин,мн|=S,муж,неод=род,ед|=S,муж,неод=им,мн}

Вывод Mystem (3)

общего{общий=A=вин,ед,полн,муж,од|=A=род,ед,полн,муж|=A=род,ед,полн,сред}
режима{режим=S,муж,неод=род,ед}

NB: даже чуть больше неоднозначностей при разборе, чем мы ожидали

Разрешение омонимии

Можно учесть:

- синтаксическую структуру (КЛ–1)
- контекст (КЛ–1 / КЛ–2)
- частотность (КЛ–2)

Разрешение омонимии

В кодексе мой грех стоит три года общего режима [Андрей Рубанов. Сажайте, и вырастет (2005)]

Как учесть:

- синтаксическую структуру?
- контекст?
- частотность?

Синонимия

- **Синонимия** — один и тот же объект может называться разными способами
- *бегемот = гиппопотам*
- Синонимичными бывают не только слова, но и словосочетания, предложения и тексты

Автоматическое извлечение информации

- Формализованное представление фактов в виде **Кто сделал что с кем где и когда?**
- $\mathit{MergerBetween}(\mathit{company}_1, \mathit{company}_2, \mathit{date})$

Автоматическое извлечение информации

- *Представитель «Аэрофлота» подтвердил РИА Новости планы компании по покупке пакета акций «Трансаэро».*
- *ФАС получила ходатайство «Аэрофлота» о покупке «Трансаэро».*
- *«Аэрофлот» приобрел 75% плюс одну акцию авиакомпании «Трансаэро» за 1 рубль.*

Анафора и кореферентность

- **Анафора** — отсылка к ранее названной сущности с помощью местоимения
- **Кореферентность** — ситуация, когда две или более цепочки слов отсылают к одной и той же сущности
- Эти явления очень усложняют автоматическое извлечение информации из текстов

Анафора и кореферентность

Самая трагическая новость минувшей недели пришла из деревни Лука Новгородской области. Здесь сгорел психоневрологический интернат — из шестидесяти больных спаслись только двадцать три. Всех их вывела из горящего здания санитарка Юлия Ануфриева. Сама она погибла, спасая очередного пациента. Корреспондент «РР» отправилась в деревню Лука, чтобы узнать побольше об этом человеке.

Юля побежала в палату, услышав запах дыма. Угол палаты горел. Она бросилась тушить, но поняла, что это не помогает. <...>

Анафора и кореферентность

- *Юля побежала в палату, услышав запах дыма. Угол палаты горел. Она бросилась тушить*
- *Петя положил книгу на стол. Он был сделан из красного дерева.*

Спортивный репортаж

Предматчевые расклады для «Спартака» в восьмом туре были таковыми, что подопечные Дмитрия Аленичева могли подтянуться к призовой тройке. Ничья ЦСКА и «Зенита», случившаяся в субботу в Химках, и поражение «Локомотива» от «Рубина», давали шансы красно-белым на то, чтобы нагнать лидеров, сравнявшись по очкам с питерцами, и хозяева «Открытие Арены» намерены были воспользоваться такой возможностью. Однако не всё у спартаковцев было так гладко...

Спортивный репортаж

Предматчевые расклады для «Спартака» в восьмом туре были таковыми, что подопечные Дмитрия Аленичева могли подтянуться к призовой тройке. Ничья ЦСКА и «Зенита», случившаяся в субботу в Химках, и поражение «Локомотива» от «Рубина», давали шансы красно-белым на то, чтобы нагнать лидеров, сравнявшись по очкам с питерцами, и хозяева «Открытие Арены» намерены были воспользоваться такой возможностью. Однако не всё у спартаковцев было так гладко...

Прагматика. Знания о мире

- *Вы не знаете, который час?*
- *— Пойдешь со мной вечером в клуб?*
  — У меня завтра утром экзамен.
- *Я видел их семью своими глазами.*
- Очень сложно моделируется как в КЛ–1, так и в КЛ–2

Задачи компьютерной лингвистики

- Распознавание текстов
- Распознавание и синтез речи
- Машинный перевод
- Проверка орфографии, грамматики и стиля
- Информационный поиск

Задачи компьютерной лингвистики

- Классификация и кластеризация текстов
- Фильтрация контента (спам и т. п.)
- Электронные словари
- Вопросно-ответные системы
- Естественно-языковые интерфейсы
- Извлечение информации и мнений

- Санников В. З. 2002. *Русский язык в зеркале языковой игры*. Москва: Языки славянской культуры.
- Селегей В. П. 2012. От автоматической обработки текста к машинному пониманию