

An approach to visual thesaurus exploration: a case study for Russian language

[Слайды на русском во второй половине файла](#)

cand. sc., assistant professor at machine learning and
knowledge representation lab, Innopolis University


Stanislav Protasov

Agenda

- Big text dataset visualization problem
- Overview of approaches to visualization
- Solution schema
- Results and discussion

Problem statement

- 6000+ popular science items (text)
- Questions to the content:
 - What is the distribution of items in knowledge areas?
 - Which knowledge areas are missing or poorly covered?
 - Are there gaps within one knowledge area?
 - What can be an approach to building a recommender system?
 - Any interesting insights?



Approaches to visualization

- Semantic modelling
 - Graph-based vocabulary representation ([WordNet](#))
 - Vector space model (word2vec, transformers, GloVe, fastText)
 - (ANN) models
 - Precomputed embeddings ([rusvectores](#), [natasha/navec](#))


Approaches to visualization

- Dimensionality reduction
 - Global methods
 - PCA minimizes data variance loss (globally)
 - Random Projections preserves pairwise Euclidean distances (globally)
 - Pivot-Mapping allows false positive matches (for search)
 - Local methods
 - Self-organizing maps and elastic maps tunes metric locally
 - t-SNE uses perplexity to manage “neighbourhood” size

Approaches to visualization


- Background data:
 - National corpora of languages ([НКРЯ](#), [COCA](#))
 - Domain-specific corpora (Wikipedia dumps)

Solution schema



$$D(term) = P_{dataset}(term) * \log\left(\frac{P_{NCRL}(term)}{P_{dataset}(term)}\right)$$

Results



Discussion

- “Good” topic clusters, but clustering principles are different (“surnames”, “F1 racers”)
- Using raw wikipedia dumps with no filtering tends to create “garbage” clusters (“surnames”)

Contact me

Stanislav Protasov

s.protasov@innopolis.ru

@sprotasov

Innopolis University

Подход к визуализации тезауруса для его исследования на примере русского языка


к.ф-м.н, доцент лаборатории машинного обучения и
представления данных Университета Иннополис
Станислав Протасов

План презентации

- Постановка задачи визуализации
- Обзор подходов
- Схема решения
- Результаты

Постановка задачи

- Коллекция 6000+ научно-популярных единиц контента (текст)
 - Вопросы, касающиеся контента в целом:
 - Как распределены материалы по областям знаний?
 - Какие области знаний отсутствуют в покрытии или плохо представлены?
 - Есть ли в рамках одной области знаний пробелы в покрытии?
 - Как построить рекомендательную систему на базе?
 - Что там ещё интересного?



Подходы к визуализации

- Моделирование семантики
 - Графовое представление словаря ([WordNet](#))
 - Векторное представление (word2vec, transformers, GloVe, fastText)
 - Модели
 - Предпосчитанные словари ([rusvectores](#), [natasha/navec](#))

Подходы к визуализации

- Понижение размерности
 - Глобальные методы
 - PCA минимизирует потерю дисперсии в данных
 - Random Projections предохраняет попарное Евклидово расстояние (в целом)
 - Pivot-Mapping допускает ложноположительные срабатывания
 - Локальные методы
 - [Карты Кохонена](#) и [упругие карты](#) адаптируют метрику локально
 - [t-SNE](#) использует перплексию для того, чтобы регулировать размер окрестности

Подходы к визуализации



- ФОН:
 - Национальные корпусы языков ([НКРЯ](#), [СОСА](#))
 - Доменные корпусы (Wikipedia dumps)

Схема решения



$$D(term) = P_{dataset}(term) * \log\left(\frac{P_{NCRL}(term)}{P_{dataset}(term)}\right)$$

Результаты



Обсуждение

- “Хорошие” тематические кластера, но с разным признаком кластеризации
- Использование wikipedia dumps в чистом виде без фильтрации приводит к образованию “мусорных” кластеров (“фамилии”)

Контакты

Станислав Игоревич Протасов

s.protasov@innopolis.ru

@sprotasov

Университет Иннополис