

Spoločný český a slovenský workshop projektu European Language Grid

Počítačové spracovanie jazyka na Slovensku

Radovan Garabík

Jazykovedný ústav Ľ. Štúra SAV

2021-10-18

Akademická sféra

- ▶ ťažisko výskumu doteraz
- ▶ primárna orientácia na písaný jazyk
- ▶ primárna orientácia na slovenčinu
- ▶ vieme, ako je financovaná veda na Slovensku

Načo je NLP

- ▶ pre (počítačového) lingvistu: strojové učenie pomáha pri výskume, analýze jazyka a anotovaní jazykových zdrojov
- ▶ pre dátového vedca: anotované jazykové zdroje pomáhajú pri strojovom učení (chceme použiť aj prirodzený jazyk ako dataset)

NLP

- ▶ v súčasnosti prebieha (ďalší) „paradigm shift“ v NLP
- ▶ veľa neoznačovaných dát, málo (prácne) označovaných dát
- ▶ Deep Learning, RNNs, transformers (BERT, GPT-x), unsupervised pretraining, supervised fine-tuning
- ▶ hw náročnosť
- ▶ 2021: posun od akadémie ku komerčnej sfére
- ▶ foundation models
- ▶ big players: Google, MS, Facebook, SAS

Korpusy

- ▶ Slovenský národný korpus (2002 –) 1.3 G <https://korpus.juls.savba.sk>
- ▶ webové korpusy (Aranea...) 4 G <http://aranea.juls.savba.sk>
- ▶ manuálne lematizovaný morfológicky anotovaný korpus, 1.2 M
- ▶ Universal Dependencies
- ▶ špecializované korpusy
 - ▶ hovorený <https://korpus.juls.savba.sk/shk.html>
 - ▶ historický
 - ▶ nárečový
 - ▶ paralelné
- ▶ speech corpora
 - ▶ ÚI SAV
 - ▶ KEMT TUKE
- ▶ webové korpusy
- ▶ Open Data

Základy – lematizácia, MSD

- ▶ tokenizácia (slová), segmentácia (vety) – takmer triviálne, ale vid' SentencePiece...
- ▶ lematizácia, morfológická anotácia (alebo POS)
<https://morphodita.juls.savba.sk>
<https://www.juls.savba.sk/bezdiak/>
 - ▶ JÚLŠ: slovník tvarov slov (morfológická databáza), 111k lemmas, 3.6M entries, 1.3M unique wordforms; morphodita
 - ▶ tvaroslovník
 - ▶ MorfFlex SK
 - ▶ ajka
 - ▶ Elasticsearch (essential data)
 - ▶ Ardevop
- ▶ morphodita
- ▶ v praxi „vyriešený problém“

Syntax

- ▶ (závislostná) syntaktická analýza (parsing)
- ▶ JÚLŠ: manuálne syntakticky anotovaný korpus, 1 M tokenov, 70 k viet
<https://korpus.sk/synt.html>
- ▶ UDPipe <https://lindat.mff.cuni.cz/services/udpipe/>
- ▶ dl4dp

Sémantika

- ▶ sémantická analýza
- ▶ klasika (ontológia): WordNet (10k)
<https://korpus.juls.savba.sk/WordNet.html>
- ▶ word embeddings (\approx 20 jazykov) <https://www.juls.savba.sk/semä.html> (pre ľudí – vyhľadávanie, vizualizácia)
- ▶ ale aj *Lexemes in Wikidata* a *Wikifier*

Pomenované entity

- ▶ Named Entity Recognition <https://www.juls.savba.sk/nerd/>
- ▶ Ardevop
- ▶ TUKE FEI (SpaCy)
- ▶ ručne značkovaný korpus
- ▶ entity linking
- ▶ anonymizácia

Speech

- ▶ ÚI SAV
- ▶ KEMT TUKE
- ▶ Newton Dictate

Rôzne

- ▶ sentiment analysis
 - ▶ Sentigrade (FIIT)
 - ▶ JÚLŠ SAV
- ▶ chatbots

Jazykové modely

- ▶ sk-bert (Ardevop)
- ▶ SlovakBERT (KInIT)

Katalóg zdrojov

- ▶ META-SHARE (neaktuálny!) <https://metashare.korpus.sk/>
- ▶ <https://github.com/essential-data/nlp-sk-interesting-links>
- ▶ <https://github.com/slovak-nlp/resources>
- ▶ European Language Grid

Ďakujem za pozornosť