

Hodnota textových dát

Radovan Garabík

Jazykovedný ústav Ľ. Štúra SAV
3. slovenský ELRC workshop

2021-05-25, Bratislava

Veľkosti korpusov

- ▶ 1 milión – morfologická/syntaktická anotácia
- ▶ 10 miliónov – terminológia
- ▶ 100 miliónov – vreckový slovník (korpus textov zákonov 43M, slovenská wikipédia 50M)
- ▶ 1 miliarda – veľký slovník, word embeddings, špičkové jazykové modely (SNK 1.6G)
- ▶ 10 miliárd – webový korpus (ARANEA)
- ▶ 100 miliárd – anglické webové korpusy

Veľkosti korpusov

- ▶ 1 milión – morfologická/syntaktická anotácia
- ▶ 10 miliónov – terminológia
- ▶ 100 miliónov – vreckový slovník (korpus textov zákonov 43M, slovenská wikipédia 50M)
- ▶ 1 miliarda – veľký slovník, word embeddings, špičkové jazykové modely (SNK 1.6G)
- ▶ 10 miliárd – webový korpus (ARANEA)
- ▶ 100 miliárd – anglické webové korpusy
- ▶ koľko slov človek „spracuje“ za celý život?

Veľkosti korpusov

- ▶ 1 milión – morfologická/syntaktická anotácia
- ▶ 10 miliónov – terminológia
- ▶ 100 miliónov – vreckový slovník (korpus textov zákonov 43M, slovenská wikipédia 50M)
- ▶ 1 miliarda – veľký slovník, word embeddings, špičkové jazykové modely (SNK 1.6G)
- ▶ 10 miliárd – webový korpus (ARANEA)
- ▶ 100 miliárd – anglické webové korpusy
- ▶ koľko slov človek „spracuje“ za celý život?
- ▶ 400 miliónov?

Dostupnosť korpusov

- ▶ Big Data
- ▶ okrem výnimiek a starých textov nie sú dostupné...

Dostupnosť korpusov

- ▶ Big Data
- ▶ okrem výnimiek a starých textov nie sú dostupné...
- ▶ GFDL, CC

Dostupnosť korpusov

- ▶ Big Data
- ▶ okrem výnimiek a starých textov nie sú dostupné...
- ▶ GFDL, CC
- ▶ výnimky zo zákona (právne predpisy, technické normy, náboženské obrady)

Dostupnosť korpusov

- ▶ Big Data
- ▶ okrem výnimiek a starých textov nie sú dostupné...
- ▶ GFDL, CC
- ▶ výnimky zo zákona (právne predpisy, technické normy, náboženské obrady)
- ▶ “the Google way”

Korpus textov zákonov

- ▶ texty zákonov Slovenskej republiky
- ▶ 43 miliónov slov
- ▶ 1955 – 2020
- ▶ <https://www.juls.savba.sk/legalcorp.html>

korpusy ARANEA

- ▶ rodina porovnateľných webových korpusov
- ▶ veľké
- ▶ <http://aranea.juls.savba.sk/>

korpusy ARANEA

- ▶ rodina porovnateľných webových korpusov
- ▶ veľké
- ▶ <http://aranea.juls.savba.sk/>
- ▶ voľne dostupné po registrácii

Word Embedding (vektorová reprezentácia slov)

- ▶ uhádnuť slovo na základe kontextu
- ▶ uhádnuť kontext na základe slova

Word Embedding (vektorová reprezentácia slov)

- ▶ uhádnuť slovo na základe kontextu
- ▶ uhádnuť kontext na základe slova
- ▶ hidden layer je veľká matica, ktorá násobí vstup (vektor) → výstup (vektor)
- ▶ word2vec
- ▶ neodmysliteľný základ počítačového spracovania jazyka
- ▶ zachytáva „významové“ rozdiely medzi slovami – uhol medzi vektormi
 - ▶ $\vec{A} \cdot \vec{B} = |\vec{A}| |\vec{B}| \cos \theta$
 - ▶
$$\cos(\theta) = \frac{\vec{A} \cdot \vec{B}}{|\vec{A}| |\vec{B}|} = \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \sqrt{\sum_{i=1}^n B_i^2}}$$

Implementácia

- ▶ <https://www.juls.savba.sk/semä.html>

Implementácia

- ▶ <https://www.juls.savba.sk/sema.html>
- ▶ Aranea korpusy + SNK
- ▶ linky do korpusov, Google, slovníkov, Wiktionary, iné...
- ▶ vizualizácia

Použitie

- ▶ tezaurus
- ▶ významovo blízke slová
- ▶ nazeráme do myšlienkového modelu „priemerného človeka“

Použitie

- ▶ tezaurus
- ▶ významovo blízke slová
- ▶ nazeráme do myšlienkového modelu „priemerného človeka“
- ▶ neovplyvnené lingvistickými teóriami

Sémantická blízkosť slov

- ▶ $|vodič,šofér| = 0.323$

Sémantická blízkosť slov

- ▶ $|vodič,šofér| = 0.323$
- ▶ $|vodička,šoférka| = 0.549$

Sémantická blízkosť slov

- ▶ $|vodič,šofér| = 0.323$
- ▶ $|vodička,šoférka| = 0.549$
- ▶ $|kľudne,pokojne| = 0.392$

Sémantická blízkosť slov

- ▶ $|vodič,šofér| = 0.323$
- ▶ $|vodička,šoférka| = 0.549$
- ▶ $|kľudne,pokojne| = 0.392$
- ▶ $|parfum,parfém| = 0.192$

Sémantická blízkosť slov

- ▶ $|vodič,šofér| = 0.323$
- ▶ $|vodička,šoférka| = 0.549$
- ▶ $|kľudne,pokojne| = 0.392$
- ▶ $|parfum,parfém| = 0.192$
- ▶ $|Clinton,Bush| = 0.191$

Sémantická blízkosť slov

- ▶ $|vodič,šofér| = 0.323$
- ▶ $|vodička,šoférka| = 0.549$
- ▶ $|kľudne,pokojne| = 0.392$
- ▶ $|parfum,parfém| = 0.192$
- ▶ $|Clinton,Bush| = 0.191$
- ▶ $|Lotyšsko,Litva| = 0.107$

Sémantická blízkosť slov

- ▶ $|vodič,šofér| = 0.323$
- ▶ $|vodička,šoférka| = 0.549$
- ▶ $|kľudne,pokojne| = 0.392$
- ▶ $|parfum,parfém| = 0.192$
- ▶ $|Clinton,Bush| = 0.191$
- ▶ $|Lotyšsko,Litva| = 0.107$
- ▶ $|debil,idiot| = 0.173$

Vektorová aritmetika

- ▶ operácie + a -

Vektorová aritmetika

- ▶ operácie + a -
- ▶ vyváženie

Vektorová aritmetika

- ▶ operácie + a -
- ▶ vyváženie
- ▶ kráľ - muž + žena

Vektorová aritmetika

- ▶ operácie + a -
- ▶ vyváženie
- ▶ kráľ - muž + žena
- ▶ premiér - muž + žena

Vektorová aritmetika

- ▶ operácie + a -
- ▶ vyváženie
- ▶ kráľ - muž + žena
- ▶ premiér - muž + žena
- ▶ pes - on + ona

Vektorová aritmetika

- ▶ operácie + a -
- ▶ vyváženie
- ▶ kráľ - muž + žena
- ▶ premiér - muž + žena
- ▶ pes - on + ona
- ▶ letuška - žena + muž

Vektorová aritmetika

- ▶ operácie + a -
- ▶ vyváženie
- ▶ kráľ - muž + žena
- ▶ premiér - muž + žena
- ▶ pes - on + ona
- ▶ letuška - žena + muž
- ▶ doctor - man + woman

Vektorová aritmetika

- ▶ operácie + a -
- ▶ vyváženie
- ▶ kráľ - muž + žena
- ▶ premiér - muž + žena
- ▶ pes - on + ona
- ▶ letuška - žena + muž
- ▶ doctor - man + woman
- ▶ 007 - 009

Vektorová aritmetika

- ▶ operácie + a -
- ▶ vyváženie
- ▶ kráľ - muž + žena
- ▶ premiér - muž + žena
- ▶ pes - on + ona
- ▶ letuška - žena + muž
- ▶ doctor - man + woman
- ▶ 007 - 009
- ▶ 666 - 555
- ▶ Bratislava - Slovensko + Francúzsko
- ▶ Paris - France + Slovaquie

Ďakujem za pozornosť