

## Podobnost kontextů ve velkých textových korpusech

### PA154 Jazykové modelování (9.1)

Pavel Rychlý

pary@fi.muni.cz

April 27, 2021

## Co to je kontext?

Kontext jsou slova v okolí klíčového slova.

- Jaké okolí?:
  - ▶ následující slovo
  - ▶ předcházející slovo
  - ▶ okno, +1 až +5
  - ▶ okno, -5 až -1
- Ne všechna slova v okolí jsou důležitá.
- Jak určíme důležitost?
  - ▶ nejčastější kolokace – ale to je “the”
  - ▶ (statisticky) nejvýznamnější – jaký vzorec?

## Word Sketch

Jak jej lze vytvořit

- Velký vyvážený korpus
- Vyhledáme závislé prvky (subjects, objects, heads, modifiers etc)
- Seznam kolokací pro každou gramatickou relaci
- Statistika pro třídění každého seznamu

Z Word Sketch můžeme vytvořit thesaurus.

## Významy

Slovo (a jeho některé části) jsou základními nositeli významu

- slovo bez kontextu – žádný význam, mnoho potenciálních významů
- stejné slovo v různých kontextech – různé významy
- slovo v **podobných** kontextech – stejný význam
- co to je kontext?

## Word Sketch

Jednostránkový souhrn chování slova [try online](#)

research as noun 25,537x

usually in plurals (99.1%, percentile 21.9)

↔	⋮	🔍	✕	↔	⋮	🔍	✕	↔	⋮	🔍	✕
	modifier				modifies				subject_of		
scientific	...			grant	...			aim	...		
recent	...			project	...			focus	...		
cancer	...			laboratory	...			investigate	...		
empirical	...			institute	...			show	...		
market	...			finding	...			examine	...		
further	...			contract	...			indicate	...		
Cray	...			programme	...			suggest	...		
medical	...			council	...			reveal	...		
historical	...			fellow	...			explore	...		
applied	...			centre	...			concentrate	...		

## Grammatical Relations Definition

- plain text file
- a set of queries for each GR
- queries contain labels for keyword and collocate
- processing options

## Definice gramatických relací

```
# 'modifier' and 'modify' gramrels definition
*DUAL
=modifier/modify
  2:"AJ." 1:"N.."

# 'and/or' gramrel definition
=and/or
*SYMMETRIC
  1:[] [word="and"|word="or"] 2:[] & 1.tag = 2.tag

# 'adverb' gramrel definition
=adverb
  1:[] 2:"AV."
  2:"AV." 1:[]
```

## Koeficient význačnosti

- počty výskytů ( $word_1$ ,  $gramrel$ ,  $word_2$ )
- $AScore(w_1, R, w_2) = 14 + \log_2 \text{Dice}\left(\frac{\|w_1, R, w_2\|}{\|w_1, R, *\|}, \frac{\|w_1, R, w_2\|}{\|*, *, w_2\|}\right) = 14 + \log_2 \frac{2 \cdot \|w_1, R, w_2\|}{\|w_1, R, *\| + \|*, *, w_2\|}$

## Koeficient podobnosti

- porovnání profilů slov  $w_1$  a  $w_2$
  - pouze důležité (význačné) kontexty
  - jaký je překryv
  - počty ( $word_1$ , ( $gramrel$ ,  $word_i$ )) a ( $word_2$ , ( $gramrel$ ,  $word_i$ ))
- $$Sim(w_1, w_2) = \frac{\sum_{(tup_i, tup_j) \in \{tup_{w_1} \cap tup_{w_2}\}} AS_i + AS_j - (AS_i - AS_j)^2 / 50}{\sum_{tup_i \in \{tup_{w_1} \cup tup_{w_2}\}} AS_i}$$

## Velikosti dat

Velikosti korpusů, jejich slovníků a počty slov v kontextech

Korpus	Velikost	Slov	Lemat	Různé k.	Všechny k.
BNC	111m	776k	722k	23m	63m
SYN2000	114m	1,65m	776k	19m	58m
OEC	1,12g	3,67m	3,12m	84m	569m
Itwac	1,92g	6,32m	4,76m	67m	587m

Velikosti slovníků i počty různých kontextů rostou sublineárně s velikostí korpusu.

## Velikost matice

- Podobnost všech dvojic lemmat
- Matice velikosti  $N^2$ , kde  $N$  je 700k – 5m
- Počet prvků v řádech tera ( $10^{12}$ )
- Matice je naštěstí velice řídká
- Většina hodnot je 0 nebo "skoro" 0
- Dokonce většina celých řádků/sloupců je prázdných

## Praktické velikosti dat

- Výpočet pouze pro slova s minimální četností
- Lépe limitovat počty kontextů než prostých výskytů
- Z kontextů brát pouze statisticky významné

Korpus	MIN	Lemmat	KWIC	CTX
BNC	1	152k	5.7m	608k
BNC	20	68k	5.6m	588k
OEC	2	269k	27.5m	994k
OEC	20	128k	27.3m	981k
OEC	200	48k	26.7m	965k
Itwac	20	137k	24.8m	1.1m

## Praktické velikosti dat

- Matice velikosti  $N^2$ , kde  $N$  je 50k – 200k
- Počet prvků v řádech giga ( $10^{10}$ )
- Hodnota každého prvku vznikne aplikací funkce podobnosti na vektory délky  $K = 500k - 1m$ .
- Přímochařý algoritmus pro výpočet celé matice má časovou složitost  $O(N^2K)$ .
- Složitost je polynomiální, ale algoritmus je prakticky nepoužitelný pro dané rozsahy hodnot.
- Odhadované doby výpočtu jsou v měsících až letech.
- Heuristiky snižují velikosti  $N$  a  $K$  na úkor přesnosti výsledných hodnot.
- Doba výpočtu je potom v řádech dnů s chybou 1–4%.

## Efektivní algoritmus

- I menší matice je velice řídká
- Není potřeba počítat podobnost pro slova, která nemají nic společného,
- tedy nemají žádný společný kontext.
- Hlavní cyklus algoritmu tedy nevedeme přes slova, ale přes kontexty.

## Efektivní algoritmus

- Vstup: seznam všech možných slov v kontextech,  $\langle w, r, w' \rangle$ , s četnostmi výskytů v korpusu
- Výstup: matice podobností slov  $sim(w_1, w_2)$

for  $\langle r, w' \rangle$  in CONTEXTS:

WLIST = set of all  $w$  where  $\langle w, r, w' \rangle$  exists

for  $w_1$  in WLIST:

for  $w_2$  in WLIST:

$sim(w_1, w_2) += f(\text{frequencies})$

## Optimalizace

- Pokud  $|WLIST| > 10000$ , daný kontext přeskochíme.
- Matici  $sim(w_1, w_2)$  během výpočtu nedržíme celou v paměti.
- Opakovaný běh hlavního cyklu pro omezený rozsah  $w_1$ .
- Místo  $sim(w_1, w_2) += x$  generujeme na výstup  $\langle w_1, w_2, x \rangle$ .
- Výstupní seznam potom seřídíme a sčítáme jednotlivé  $x$ .
- Využití TMMS (Two Phase Multi-way Merge Sort) s průběžným sčítáním.
- Místo několika stovek GB třídíme jednotky GB.

## Výsledky

- Algoritmus je řádově rychlejší než přímochařý algoritmus. (18 dnů  $\times$  2 hodiny)

Korpus	MIN	Lemmat	KWIC	CTX	čas
BNC	1	152k	5.7m	608k	13m 9s
BNC	20	68k	5.6m	588k	9m 30s
OEC	2	269k	27.5m	994k	1h 40m
OEC	20	128k	27.3m	981k	1h 27m
OEC	200	48k	26.7m	965k	1h 10m
Itwac	20	137k	24.8m	1.1m	1h 16m

- Bez omezení přesnosti.
- Možnost snadné paralelizace.