

IB047

Četnosti a kolokace

Pavel Rychlý

pary@fi.muni.cz

7. dubna 2025

Obsah korpusu

Jak zjistíme, co je v korpusu?

- přečteme ho – nepraktické
- struktura korpusu: atributy, struktury, metainformace
- seznam typických (častých) slov
 - pro každý atribut (slovo, lemma, značka)
 - pro atributy struktur (autor, datum, ...)
- základní informaci dívají i velikosti seznamů

Type-token ratio

- type-token ratio (TTR) = počet různých slov / počet tokenů
- míra lingvistické diverzity
- je potřeba normalizovat úseky pevné délky (milion slov), průměr z úseků

	tokenů	slov	token/type	type-token ratio
Susanne	150 000	16 000	9,1	0,107
BNC	112 000 000	774 000	145	0,00691
EnTenTen	13 000 000 000	28 000 000	465	0,0021

Obsah korpusu

Poznáte o jaký korpus jde?

	řádků	slov	bajtů
Kniha 1	3.715	37.703	223.415
Kniha 2	1.601	16.859	91.031

Seznamy slov

- seznamy nejčastějších prvků (slov) dávají dobrou charakteristiku obsahu
- sort |uniq -c |sort -rn
- některá slova dávají informaci o jazyce, jiná o typu jazyka, jiná o obsahu

Kniha 1	Kniha 2
the, and, of, to, you, his, in, said, that, I, will, him, your, he, a, my, was, with, s, for, me, He, is, , , it, them, be, The, all, , have, from, , on, her, , , , , are, their, were, they, which, , t, up, , had, there	the, I, to, a, of, is, that, , you, he, and, said, was, , in, it, not, me, my, have, And, are, one, for, But, his, be, The, It, at, all, with, on, will, as, very, had, this, him, He, from, they, , so, them, no, You, do, would, like

Seznamy slov

- seznamy nejčastějších prvků (slov) dávají dobrou charakteristiku obsahu
- sort |uniq -c |sort -rn
- některá slova dávají informaci o jazyce, jiná o typu jazyka, jiná o obsahu

Kniha 1	Kniha 2
the, and, of, to, you, his, in, said, that, I, will, him, your, he, a, my, was, with, s, for, me, He, is, father , , it, them, be, The, all, land , have, from, , on, her, , son , , are, their, were, they, which, sons , t, up, , had, there	the, I, to, a, of, is, that, little , you, he, and, said, was, , in, it, not, me, my, have, And, are, one, for, But, his, be, The, It, at, all, with, on, will, as, very, had, this, him, He, from, they, planet , so, them, no, You, do, would, like

Seznamy slov

- seznamy nejčastějších prvků (slov) dávají dobrou charakteristiku obsahu
- sort |uniq -c |sort -rn
- některá slova dávají informaci o jazyce, jiná o typu jazyka, jiná o obsahu

Kniha 1	Kniha 2
the, and, of, to, you, his, in, said, that, I, will, him, your, he, a, my, was, with, s, for, me, He, is, father , God , it, them, be, The, all, land , have, from, Jacob , on, her, Yahweh , son , Joseph , are, their, were, they, which, sons , t, up, Abraham , had, there	the, I, to, a, of, is, that, little , you, he, and, said, was, prince , in, it, not, me, my, have, And, are, one, for, But, his, be, The, It, at, all, with, on, will, as, very, had, this, him, He, from, they, planet , so, them, no, You, do, would, like

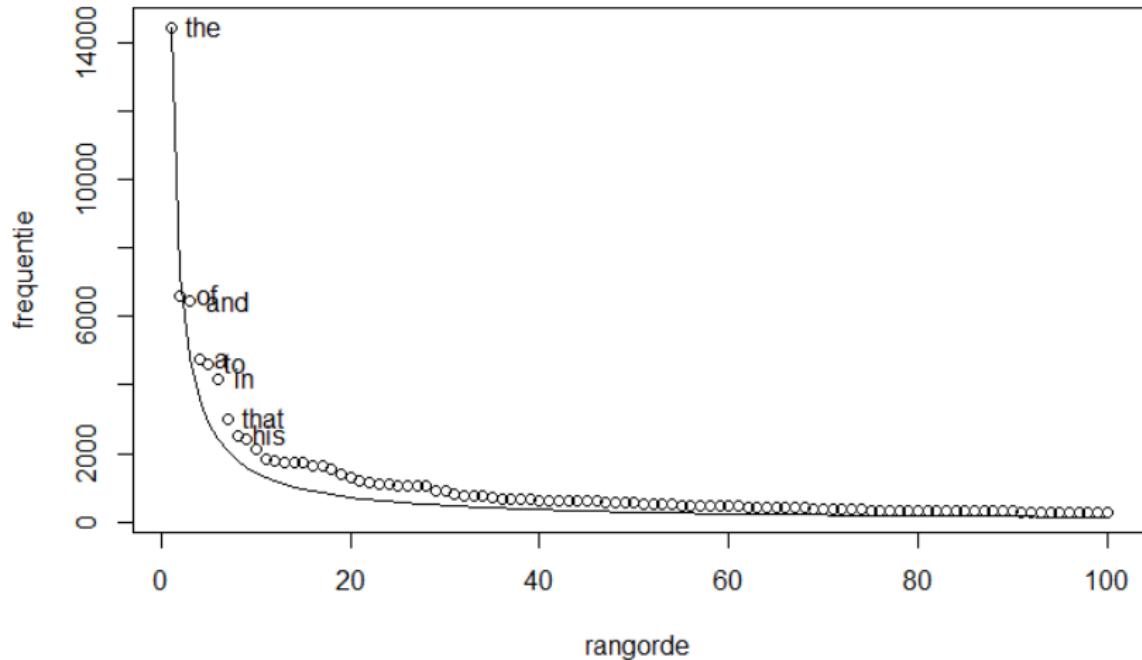
Zipfův zákon

Jaké je rozložení slov v korpusu?

- proč jsou nejčastější slova dobrou charakteristikou?
- nejčastější pokrývají velkou část textu
- $f * r = C$
součin četnosti a pořadí v seznamu slov (dle četnosti) je zhruba konstantní
- slova, slovní spojení
- vlastní jména, velikosti měst

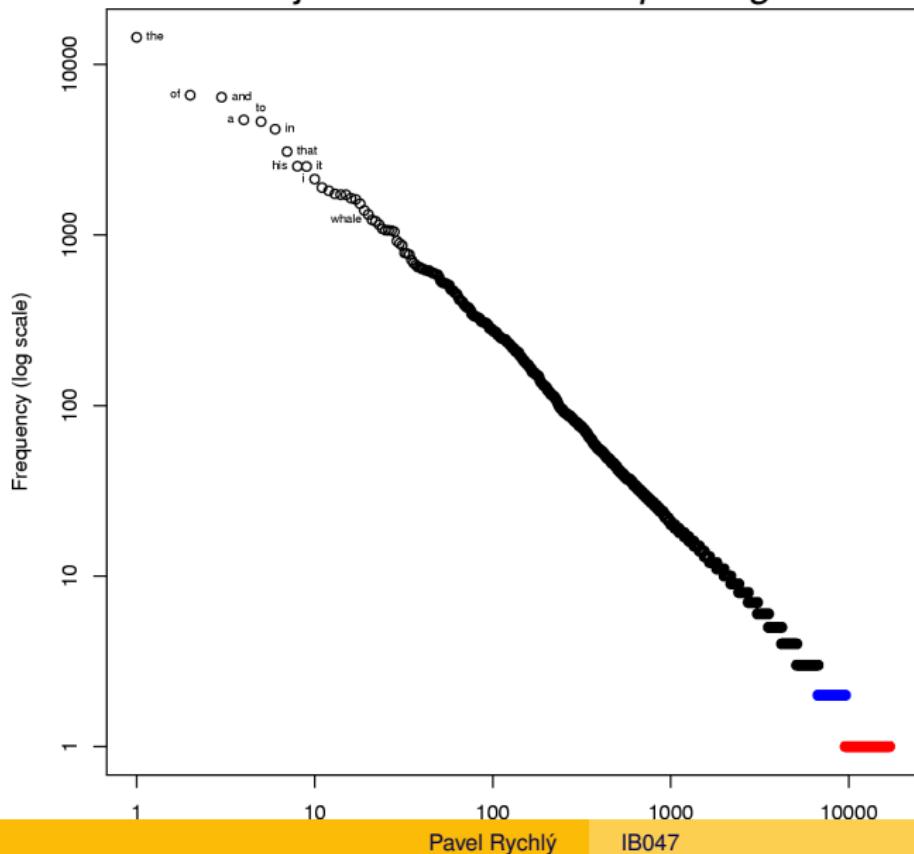
Zipfův zákon

- graf: pořadí – četnost
- $f * r = C$



Zipfův zákon

Velká část slov je s četností 1 = *hapax legomena*



Redukovaná četnost

- pravděpodobnost výskytu slova vs. četnost slova v korpusu
- některá slova jsou pouze v jenom dokumentu, ale mnohokrát
- redukované četnosti normalizují výskytu
- $RF \leq F$
- $RF \geq 1$
- dokumentová četnost (range)
= počet dokumentů obsahujících dané slovo

ARF: average reduced frequency

- četnost slova f
- korpus rozdělíme na f částí
- počítáme počet částí, které dané slovo obsahují
 $\min = 1$, $\max = f$
- rozdelení posuneme o jeden token, znova spočteme počet částí
- ARF = průměr počtu pokrytých částí ze všech posunutí

ALDF: Average Logarithmic Distance Frequency

- četnost slova f , velikost korpusu N
- d_i počet tokenů mezi jednotlivými výskyty slova
- $ALD = \frac{1}{N} * \sum_{i=1}^f d_i \log_2 d_i$
- $ALDF = 2^{ALD}$
- rovnoměrné rozložení: $ALDF = f$
- výpočet lze distribuovat, snadné skládání částí

Kolokace

Jaká slova se vyskytují v kontextech daného výrazu?

- záchodové XXX
- tratoliště XXX
- očitý XXX
- polehčující XXX

Kolokace

Jaká slova se vyskytují v kontextech daného výrazu?

- záchodové XXX
- tratoliště XXX
- očitý XXX
- polehčující XXX

Jak můžeme kolokace najít?

- četnosti
- relativní četnosti
- skóre – asociační míry
- filtrování

Asociační míry

Počítáme na základě kontingenční tabulky.

	$V = v$	$V \neq v$
$U = u$	$E_{11} = \frac{R_1 C_1}{N}$	$E_{12} = \frac{R_1 C_2}{N}$
$U \neq u$	$E_{21} = \frac{R_2 C_1}{N}$	$E_{22} = \frac{R_2 C_2}{N}$

expected frequencies

O_{ij} – pozorované hodnoty (observed) E_{ij} – očekávané hodnoty (expected)

	$V = v$	$V \neq v$
$U = u$	O_{11}	O_{12}
$U \neq u$	O_{21}	O_{22}

$= C_1 \quad = C_2 \quad = N$

observed frequencies

Asociační míry

- T-score: $T = \frac{O_{11} - E_{11}}{\sqrt{O_{11}}} = \frac{f_{xy} - \frac{f_x f_y}{N}}{\sqrt{f_{xy}}}$
- MI-score: $MI = \log_2 \frac{O_{11}}{E_{11}} = \log_2 \frac{f_{xy} N}{f_x f_y}$
- Log-likelihood:
$$LL = -\log_2 \frac{L(O_{11}, C_1, r) L(O_{12}, C_2, r)}{L(O_{11}, C_1, r_1) L(O_{12}, C_2, r_2)}$$
$$L(k, n, r) = r^k (1 - r)^{n-k}$$
$$r = \frac{R_1}{N}; r_1 = \frac{O_{11}}{C_1}; r_2 = \frac{O_{12}}{C_2}$$

Asociační míry

- Minimum sensitivity: $MS = \min\left\{\frac{O_{11}}{C_1}, \frac{O_{11}}{R_1}\right\} = \min\left\{\frac{f_{xy}}{f_x}, \frac{f_{xy}}{f_y}\right\}$
– minimum z relativních četností
- Dice: $D = \frac{2O_{11}}{R_1+C_1} = \frac{2f_{xy}}{f_x+f_y}$
- logDice: $ID = 14 + \log_2 D = 15 + \log_2 f_{xy} - \log_2(f_x + f_y)$

Filtrování

- vybíráme jen ty kolokace, které splňují podmínku na značkách
- ADJ NN
- NN NN
- word sketches – jednostránkový souhrn chování slov

Kolokace slova Prince

↔	☰	✖
modifiers of "prince"		
little	...	say
the little prince		said the little prince
fair	...	ask
fair , little prince		asked the little prince
Oh	...	demand
Oh , little prince		demanded the little prince
dear	...	see
dear little prince		when he saw the little prince coming
prince	...	inquire
prince , dear little prince		inquired the little prince
great	...	repeat
great prince		repeated the little prince , who
verbs with "prince" as object		
say	...	say
		the little prince said to himself
ask	...	come
		saw the little prince coming
demand	...	go
		And the little prince went away
see	...	add
		the little prince added
inquire	...	ask
		the little prince asked
repeat	...	flush
		The little prince flushed
verbs with "prince" as subject		

Word Sketches

Jak se vytváří

- Velký vyvážený korpus
- Vyhledáme závislé prvky (subjects, objects, heads, modifiers etc)
- Gramatické relace definované formou dotazů v CQL
- Seznam kolokací pro každou gramatickou relaci
- Statistika pro třídění každého seznamu

Klíčová slova

- porovnání relativních četností oproti referenčním datům
- Simple Math:

$$s = \frac{f_1 + N}{f_{ref} + N}$$

Klíčová slova

- porovnání relativních četností oproti referenčním datům
- Simple Math:

$$s = \frac{f_1 + N}{f_{ref} + N}$$

Co je v korpusu/textu?

Klíčová slova dávají typická (častá) slova, ale ne obyčejná.