

Jazykové modely a textové korpusy

Pavel Rychlý, Aleš Horák

E-mail: hales@fi.muni.cz
http://nlp.fi.muni.cz/poc_lingv/

Obsah:

- ▶ Jazykové modely
- ▶ Co to je korpus?
- ▶ Anglické a národní korpusy
- ▶ Formáty korpusů
- ▶ Korpusové manažery

n-gramy – pokrač.

Obecně – máme **text** jako řetězec **slov** $W = w_1 w_2 w_3 \dots w_n$

Na vstupu zatím $w_1 w_2 \dots w_{i-1}$, chceme určit **nejpravděpodobnější** w_i

Možnosti:

- ▶ použijeme pravděpodobnost $P(w_i)$ – vypočítáme **unigramy**
- ▶ zpřesnění – **n-gramy**:
 - **bigramy** – $P(w_i|w_{i-1})$
 - **trigramy** – $P(w_i|w_{i-2} w_{i-1})$
- ▶ vyšší n je náročnější na výpočet i na data
- ▶ nejlepší – pravděpodobnost podle **celého předchozího vstupu**

$$P(w_i|w_1 w_2 \dots w_{i-1})$$

n-gramy

Úkol:

Je zadáno n slov textu, jaké **slovo** následuje s **největší pravděpodobností**?

např. **diktování**:

Nově označené $\left\{ \begin{array}{l} \text{láhve} \\ \text{láhvové} \end{array} \right\}$ se dostanou na trh ...

Markovovy modely – pokrač.

$$P(w_i|w_1 w_2 \dots w_{i-1}) = \frac{P(w_1 \dots w_i)}{P(w_1 \dots w_{i-1})}$$

$$P(w_1 \dots w_i) = P(w_1) \cdot P(w_2|w_1) \cdot P(w_3|w_1 w_2) \cdot \dots \cdot P(w_i|w_1 \dots w_{i-1})$$

problém – potřebujeme **n-gramy** pro **velké n**

řešení – **Markovův předpoklad o lokálním kontextu** (řádu n)

Nejbližší kontext (n slov) **nejvíce ovlivňuje pravděpodobnost slova w_i**

Pro $n=1$:

$$P(w_1 \dots w_i) = P(w_1) \cdot P(w_2|w_1) \cdot P(w_3|w_2) \cdot \dots \cdot P(w_i|w_{i-1})$$

$$P(w_i|w_1 w_2 \dots w_{i-1}) = P(w_i|w_{i-1})$$

$$P(w_i|w_{i-1}) = \frac{\text{počet}(w_{i-1} w_i)}{\text{počet}(w_{i-1})} \dots \text{bigramy!}$$

Markovův model – pravděpodobnostní konečný automat pro **všechna slova**

Markovovy modely – využití

Využití jazykových modelů:

- ▶ rozpoznávání řeči
- ▶ určování morfologických a syntaktických kategorií
- ▶ strojový překlad
- ▶ určování vztahů mezi slovy
- ▶ filtrování generovaných textů

Tvorba jazykových modelů – z **textových korpusů**

kvalitní model potřebuje (velmi) **velké korpusy**

Proč velmi velké korpusy

např. **British National Corpus (BNC)** – cca 100 mil.slov, 774 tis. různých slov

různá slova podle **frekvence**:

374,000	2
273,000	3
130,000	10
88,000	20
53,000	50
35,000	100
12,400	500
7,600	1,000
1,000	10,000

podstatné jméno "test":

- ▶ frekvence 15789, pozice 918
- ▶ relace **object-of**: *pass, undergo, satisfy, fail, devise, conduct, administer, perform, apply, boycott*
- ▶ relace **modifier**: *blood, driving, fitness, beta, nuclear, pregnancy*

Proč velmi velké korpusy

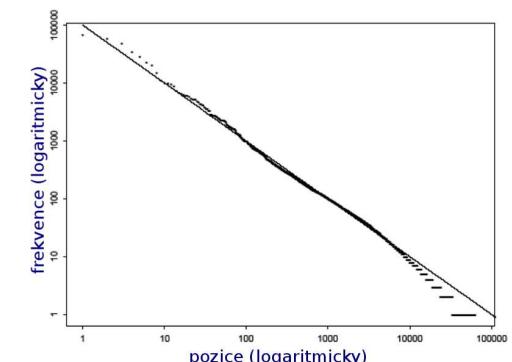
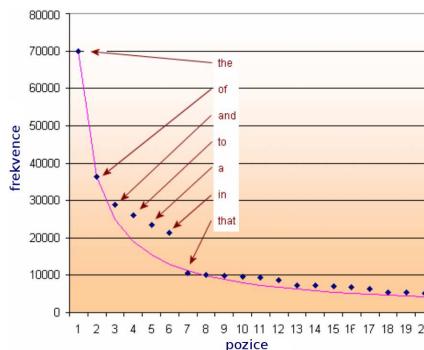
Zipfův zákon (zákon mocniny) distribuce jazyka

$$\text{frekvence} \cdot \text{pozice} = \text{konstanta}$$

tedy

$$\text{pozice} = \text{konst}/\text{frekv}$$

$$\log(\text{pozice}) = \log(\text{konst}) - \log(\text{frekv})$$



Proč velmi velké korpusy

slovní spojení podstatného jména "test":

- ▶ "blood test"
 - v BNC, relace **object-of**: *order (3), take (12)*
 - v enClueWeb16 (70 mld.slov), relace **object-of**: *order (708), perform (959), undergo (174), administer (123), conduct (229), require (676), repeat (80), run (347), request (105), take (1215)*
- ▶ "pregnancy test"
 - v BNC, 26 výskytů, žádná významná slovní spojení
 - v enClueWeb16, relace **object-of**: *take (1765), perform (203), buy (237), administer (40)*

Co to je korpus?

Korpus – skupina dokumentů

Různé typy korpusů:

- ▶ textové
- ▶ mluvené

Textový korpus:

- ▶ soubor textů
- ▶ charakteristiky
 - rozsáhlý (stovky milionů až desítky miliard pozic/slov)
 - v jednotném formátu
 - strukturovaný
 - v elektronické podobě

Typy korpusů

- ▶ vždy záleží na účelu a způsobu použití
- ▶ možnosti
 - jazyk
 - typy textů
 - zdroj dat
 - značkování
 - ...

První korpus

Brown

- ▶ americká angličtina (1961)
- ▶ Brown University, 1964
- ▶ gramatické značkování, 1979
- ▶ 500 textů, 1 mil. slov
- ▶ W. N. Francis & H. Kučera
 - první statistické charakteristiky angličtiny
 - relativní četnosti slov a slovních druhů

BNC

British National Corpus

- ▶ britská angličtina, 10% mluva
- ▶ první velký korpus pro lexikografy
- ▶ vydavatelé slovníků (OUP) + univerzity
- ▶ 1. verze: 1991–1994, 2. verze: World Edition 2000
- ▶ ≈3000 dokumentů, 100 mil. slov
- ▶ gramatické značkování automatickým nástrojem

BoE

Další národní korpusy

Bank of English

- ▶ britská angličtina
- ▶ COBUILD (HarperCollins), University of Birmingham
- ▶ 1991, dále rozšiřován
- ▶ 2002, ≈450 mil. slov

▶ Český národní korpus

- ÚČNK, FF UK
- SYN2000, SYN2005, SYN2010 à 100 mil. slov
- Litera, Synek, BMK, ...

▶ Slovenský, Maďarský, Chorvatský, ...

▶ Americký

Korpusy na FI

vytvořené na FI, příklady:

- ▶ Desam
 - 1996, ručně značkovaný (desambiguovaný)
 - ≈1 mil. slov
- ▶ Czes
 - periodika z webu, z let 1996–1998, další el. zdroje, webové zdroje (crawl)
 - ≈465 mil.
- ▶ *TenTen
 - různé jazyky, ve spolupráci s LCL, UK
 - 1–20 mld. pozic
- ▶ Chyby
 - práce studentů předmětu Základy odb. stylu s vyznačenými chybami
 - ≈400 tis.

Korpusy na FI

spolupráce

- ▶ Dopisy
- ▶ Mluv
- ▶ Kačenka
- ▶ ČNPK
- ▶ 1984
- ▶ Otto
- ▶ Italian
- ▶ Giga Chinese
- ▶ Francouzský, Slovinský, Britská angličtina, ...

Formáty korpusů

1. archiv/kolekce
 - různé formáty, podle zdroje/typu
2. textové banky
 - jednotný formát a základní struktura
 - dokumenty/texty, základní metainformace
3. vertikální text
4. binární data v aplikaci
 - pomocná data pro rychlejší zpracování
 - indexy
 - statistiky

Kódování metainformací

- ▶ escape-sekvence
 - speciální znak mění význam následujících znaků
 - \n, \t, &, <tag>
- ▶ SGML
 - Standard Generalised Markup Language
 - ISO 8879:1986(E)
- ▶ XML
 - Extensible Markup Language
 - W3C, 1998

XML

- ▶ struktura popsána v DTD
- ▶ elementy
 - počáteční, koncová značka
 - <doc>, <head>, </head>, <g/>
- ▶ atributy elementů/značek
 - <doc title="Jak pejsek ..." author="Čapek">
 - <head type="main">
- ▶ entity
 - >, <, &, ´

Standardy pro ukládání textů

- ▶ SGML/XML
- ▶ TEI
 - Text Encoding Initiative (1994)
 - TEI Guidelines for Electronic Text Encoding and Interchange
- ▶ CES, XCES
 - Corpus Encoding Standard

Obsah korpusu

Co je v korpusu uloženo?

- ▶ text
- ▶ metainformace
- ▶ struktura dokumentu
 - odstavce, nadpisy, verše, věty
- ▶ značkování
 - informace o slovech/pozicích
 - morfologie, základní tvary, syntaktické vazby, ...

Vertikální text

- ▶ jednoduchý formát i jeho zpracování
 - každý token na samostatném řádku
 - struktury formou XML značek
 - značkování odděleno tabulátorem (různé atributy k dané pozici)
- ▶ podrobnosti na:
 - <http://nlp.fi.muni.cz/>
 - → Informace pro současné a potenciální spolupracovníky
 - → Textové korpusy
 - → Popis vertikálů

Tokenizace

Rozdělení textu do pozic

- ▶ může silně ovlivnit výsledky dotazování, četnosti i značkování
- ▶ token (pozice) = základní prvek korpusu
- ▶ většinou slovo, číslo, interpunkce
 - bude-li, don't – 4 možnosti:
 1. |don't|
 2. |don| |'t|
 3. |don| |'| |t|
 4. |do| |n't| – v BNC
 - zkratky (s tečkama?)
 - datumy
 - desetinná čísla, ...

Zpracování textů na UNIXu

- ▶ coreutils
 - cat, head, tail, wc, sort, uniq, comm
 - cut, paste, join, tr
- ▶ grep
- ▶ awk
- ▶ sed / perl

Příklady použití coreutils

- ▶ slovník z vertikálního textu

```
cut -f 1 -s desam.vert |sort |uniq -c \
|sort -rn >desam.dict
```

- ▶ jednoduchá tokenizace

```
tr -cs 'a-zA-Z0-9' '\n' <GPL >GPL.vert
cat GPL.vert |sort |uniq -c |sort -rn >GPL.dict
```

- ▶ všechny bigramy

```
tail -n +2 GPL.vert |paste GPL.vert - |sort |uniq -c
|sort -rn
```

Korpusové manažery

- nástroje na zpracování korpusů

- ▶ uložení textu
- ▶ editace/příprava textu
- ▶ značkování
- ▶ rozdělení do pozic (tokenizace)
- ▶ vyhledávání (konkordance)
- ▶ statistiky

Systém Manatee

- ▶ korpusový manažer

- ▶ přímo podporuje

- uložení textu
 - vyhledávání (konkordance)
 - statistiky

- ▶ externí nástroje

- značkování
 - rozdělení do pozic

Systém Manatee

- hlavní zaměření

- ▶ velké korpusy
- ▶ rozsáhlé značkování
 - morfologické, syntaktické, metainformace
- ▶ návaznost na další aplikace/nástroje
 - korpusový editor (CED), tvorba slovníků
- ▶ univerzálnost
 - různé jazyky, kódování, systémy značek

Klíčové vlastnosti

- ▶ modulární systém
- ▶ přístup z různých rozhraní
 - grafické uživatelské rozhraní (Bonito)
 - aplikační programové rozhraní (API)
 - příkazový řádek
- ▶ rozsáhlá data
 - stovky mld. pozic
 - neomezeně atributů a metainformací
- ▶ rychlosť
 - vyhledávání, statistiky

Klíčové vlastnosti

- ▶ multihodnoty
 - zpracování víceznačných značkování
- ▶ dynamické atributy
 - vyhledávání a statistiky na počítaných datech
- ▶ subkorpusy, paralelní korpusy
- ▶ silný dotazovací jazyk
 - dotazy na všechny atributy, metainformace
 - pozitivní/negativní filtry
 - regulární výrazy + booleovské operátory

Klíčové vlastnosti

- ▶ frekvenční distribuce
 - víceúrovňová
 - všechny atributy a metainformace
- ▶ kolokace
 - různé statistické funkce