

Jazykové modely a textové korpusy

Pavel Rychlý, Aleš Horák

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

Obsah:

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

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 ...

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**
ty ale neberou v úvahu předchozí **kontext**
- ▶ nejlepší – pravděpodobnost podle **celého** předchozího vstupu

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

n-gramy:

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

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

Markovovy modely

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 $n = 1$:

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

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

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

(skrytý) Markovův model (hidden Markov model, HMM) – pravděpodobnostní konečný automat pro **všechna slova** a sekvence

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

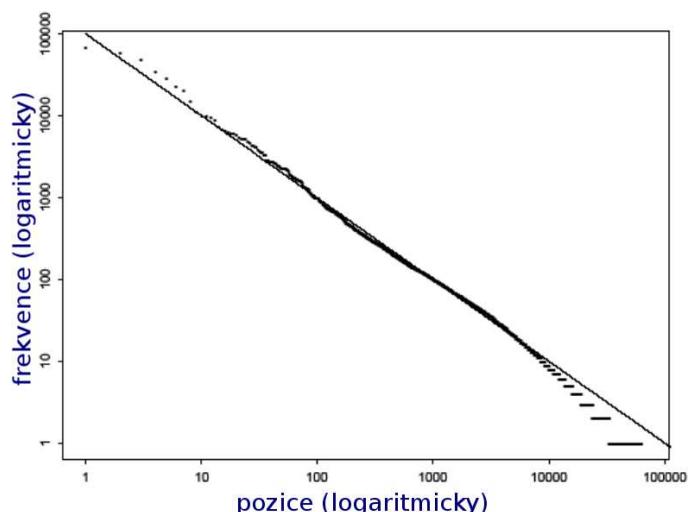
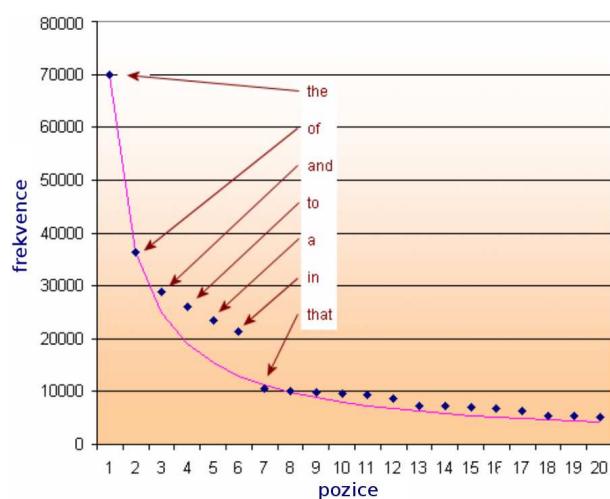
Zipfův zákon (zákon mocniny) distribuce jazyka

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

tedy

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

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



Proč velmi velké korpusy

např. British National Corpus (BNC) – cca 100 mil.slov, 774 tis. různých slov
různá slova podle frekvence:

| | |
|-----------|---------------|
| 400,000 × | freq = 1 |
| 374,000 × | freq ≥ 2 |
| 273,000 × | freq ≥ 3 |
| 130,000 × | freq ≥ 10 |
| 88,000 × | freq ≥ 20 |
| 53,000 × | freq ≥ 50 |
| 35,000 × | freq ≥ 100 |
| 12,400 × | freq ≥ 500 |
| 7,600 × | freq ≥ 1,000 |
| 1,000 × | freq ≥ 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

slovní spojení podstatného jména “test”:

- ▶ “blood test”
 - v **BNC**, 204 výskytů, relace **object-of**: *order* (3), *take* (12)
 - v **enClueWeb** (**70 mld.slov**), 205220 výskytů, relace **object-of**: *order* (2323), *undergo* (808), *administer* (456), *perform* (2783), *screen* (129), *request* (442), *conduct* (860), *refuse* (195), *repeat* (254), *scan* (203), *require* (2345), *recommend* (502), *schedule* (192), *run* (1721), *take* (5673), *interpret* (102), *arrange* (162)
- ▶ “pregnancy test”
 - v **BNC**, 26 výskytů, žádná významná slovní spojení
 - v **enClueWeb**, 54103 výskytů, relace **object-of**: *take* (7953), *administer* (134), *buy* (1094), *undergo* (145), *perform* (560)

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
 - stukturovaný
 - v elektronické podobě

Typy korpusů

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

První korpus

Brown

- ▶ americká angličtina (1961)
- ▶ Brown University, 1964
- ▶ gramatické značkování, 1979
- ▶ 500 textů (à ≈2000 slov), 1 mil. slov
- ▶ W. N. Francis & H. Kučera
 - první statistické charakteristiky anglických slov
 - 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

Bank of English

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

Další národní korpusy

- ▶ Český národní korpus
 - ÚČNK, FF UK
 - SYN2000, SYN2005, ..., SYN2020 à [100 mil. slov](#)
 - SYN – [5 mld. slov](#)
 - autorské korpusy – Čapek, Havlíček, ...
 - mluvené korpusy – ORAL, BMK, DIALEKT, ...
 - diachronní (historický) DIAKORP
 - paralelní a porovnatelné korpusy – InterCorp, Aranea
- ▶ 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/XML Schema
- ▶ 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** (většinou atributy <doc>)
- ▶ **struktura dokumentu**
 - odstavce, nadpisy, verše, věty
- ▶ **značkování**
 - informace o slovech/pozicích
 - morfologie, základní tvary, syntaktické vazby, ...

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 tečkami?)
 - datumy
 - desetinná čísla, ...

Vertikální text

- ▶ **jednoduchý** formát i jeho zpracování
 - každý token na samostatném řádku (\Rightarrow udává **tokenizaci**)
 - **struktury** formou XML značek
 - **značkování** odděleno tabulátorem (různé atributy k dané pozici)

```
<doc n=2 id="CMP/94/10">
<head p="80%">
  Úpadku      úpadek      k1gInSc3
  zabránili  zabránit    k5mAgMnPaP
  výkonem    výkon       k1gInSc7
</head>
<p>
<s p="90%">
  Po          po          k7c6
  několika   několik    k4gFnPc6
  akcích     akce       k1gFnPc6
```

- ▶ podrobnosti na nlp.fi.muni.cz/cs/PopisVertikalu

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
```

Nástroje pro tvorbu velkých korpusů

projekt **corpus.tools**

samostatné nástroje pro dávkové úkoly zpracování textů, např.:

- ▶ **JusText** – inteligentní extrakce textu z webové stránky
- ▶ **Spiderling** – procházení a stahování textů z webu pro daný jazyk
- ▶ **Unitok** – konfigurovatelný tokenizátor pro více jazyků
- ▶ **Onion** – odstraňuje duplicitní texty
- ▶ **Chared** – detekce kódování textu

Korpusové manažery

nástroje na zpracování korpusů

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

Systém Manatee

- ▶ korpusový manažer
- ▶ pro Masarykovu univerzitu dostupný na ske.fi.muni.cz
- ▶ 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