

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

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

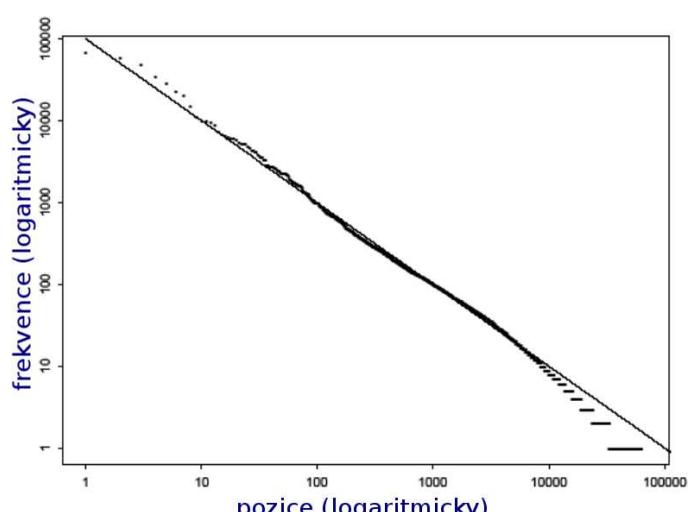
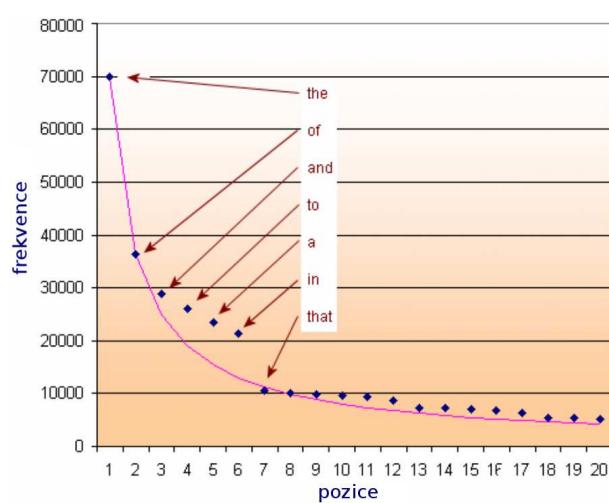
Zipfův zákon (zákon mocniny) distribuce jazyka

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

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 – [4.5 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

Rozdelení 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