

# Jazykové modely a textové korpusy

Pavel Rychlý, Aleš Horák

E-mail: [hales@fi.muni.cz](mailto:hales@fi.muni.cz)  
[http://nlp.fi.muni.cz/nlp\\_intro/](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 { *láhve*  
*láhvové* } 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


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

tedy

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



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



## 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, 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,  $\approx$ 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 značkový (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**
  - `&gt;`, `&lt;`, `&amp;`, `&acute;`;

# 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?)
  - datумы
  - desetinná čísla, ...

## Vertikální text

- ▶ jednoduchý formát i jeho zpracování
  - každý token na samostatném řádku (⇒ 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/PopisVertikalalu](http://nlp.fi.muni.cz/cs/PopisVertikalalu)

# 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**

# System 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
- ▶ **rychlost**
  - 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