

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:

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

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

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:

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

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

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:

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

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

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

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

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

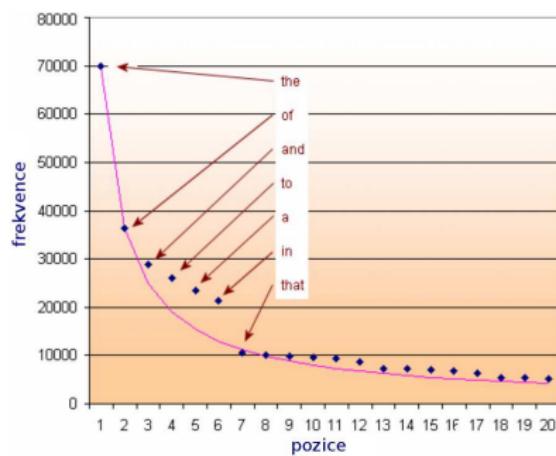
Proč velmi velké korpusy

Zipfův zákon (zákon mocniny) distribuce jazyka

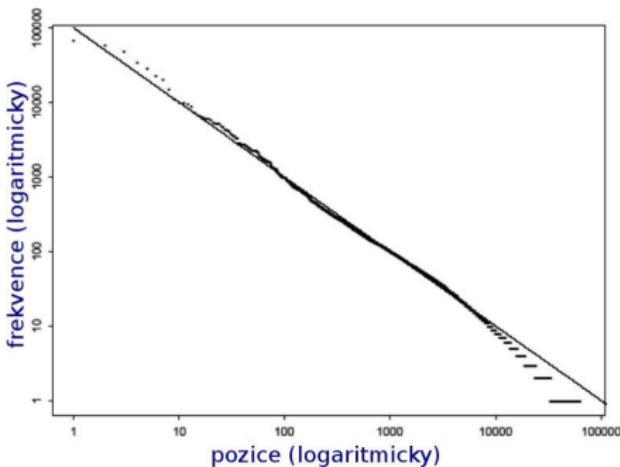
$$\text{frekvence} \cdot \text{pozice} = \text{konstanta}$$

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

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)

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)

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)

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)

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)

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)

Obsah

1 Jazykové modely

- n-gramy
- Markovovy modely
- Proč velmi velké korpusy

2 Co to je korpus?

3 Anglické a národní korpusy

4 Formáty korpusů

- Obsah korpusu
- Nástroje pro tvorbu korpusu

5 Korpusové manažery

- Systém Manatee

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
 - * ...

Typy korpusů

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

Typy korpusů

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

Typy korpusů

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

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**

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

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 – 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

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

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, ...

Obsah

1 Jazykové modely

- n-gramy
- Markovovy modely
- Proč velmi velké korpusy

2 Co to je korpus?

3 Anglické a národní korpusy

4 Formáty korpusů

- Obsah korpusu
- Nástroje pro tvorbu korpusu

5 Korpusové manažery

- Systém Manatee

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

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

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

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

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

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

- 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
 - >, <, &, é

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
 - >, <, &, é

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
 - >, <, &, é

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
 - >, <, &, é

Standardy pro ukládání textů

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

Standardy pro ukládání textů

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

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, ...

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, ...

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, ...

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] [t̚]
 3. [don] ['] [t̚]
 4. [do] [n't] – v BNC
 - zkratky (s tečkami?)
 - datumy
 - desetinná čísla, ...

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] [t̚]
 3. [don] ['] [t̚]
 4. [do] [n't] – v BNC
 - zkratky (s tečkami?)
 - datumy
 - desetinná čísla, ...

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, ...

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, ...

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, ...

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, ...

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

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

Zpracování textů na UNIXu

- coreutils

- cat, head, tail, wc, sort, uniq, comm
- cut, paste, join, tr

- grep

- awk

- sed / perl

Zpracování textů na UNIXu

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

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
```

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
```

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

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

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

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

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

SliDo

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