

# Korpusy textů a jejich využití

Pavel Rychlý, Aleš Horák

E-mail: [hales@fi.muni.cz](mailto:hales@fi.muni.cz)  
[http://nlp.fi.muni.cz/poc\\_lingv/](http://nlp.fi.muni.cz/poc_lingv/)

## Obsah:

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

# Co to je korpus?

- Co to je text, dokument?
  - lecos
- Různé typy korpusů
  - textové
  - mluvené
- Pro potřeby NLP
  - textový korpus

# Co to je korpus?

- Co to je text, dokument?
  - lecos
- Různé typy korpusů
  - textové
  - mluvené
- Pro potřeby NLP
  - textový korpus

# Co to je korpus?

- Co to je text, dokument?
  - lecos
- Různé typy korpusů
  - textové
  - mluvené
- Pro potřeby NLP
  - textový korpus

# Co to je korpus?

- Co to je text, dokument?
  - lecos
- Různé typy korpusů
  - textové
  - mluvené
- Pro potřeby NLP
  - textový korpus

# Co to je korpus?

- Co to je text, dokument?
  - lecos
- Různé typy korpusů
  - textové
  - mluvené
- Pro potřeby NLP
  - textový korpus

# Co to je korpus?

- Co to je text, dokument?
  - lecos
- Různé typy korpusů
  - textové
  - mluvené
- Pro potřeby NLP
  - textový korpus

# Co to je korpus?

- Co to je text, dokument?
  - lecos
- Různé typy korpusů
  - textové
  - mluvené
- Pro potřeby NLP
  - textový korpus



# Textový korpus

- soubor textů
- charakteristiky
  - rozsáhlý (stovky mil. až mld. pozic/slov)
  - v jednotném formátu
  - strukturovaný
  - v elektronické podobě

# Textový korpus

- soubor textů
- charakteristiky
  - rozsáhlý (stovky mil. až mld. pozic/slov)
  - v jednotném formátu
  - stukturovaný
  - v elektronické podobě

# Textový korpus

- soubor textů
- charakteristiky
  - rozsáhlý (stovky mil. až mld. pozic/slov)
  - v jednotném formátu
  - stukturovaný
  - v elektronické podobě

# Textový korpus

- soubor textů
- charakteristiky
  - rozsáhlý (stovky mil. až mld. pozic/slov)
  - v jednotném formátu
  - stukturovaný
  - v elektronické podobě

# Textový korpus

- soubor textů
- charakteristiky
  - rozsáhlý (stovky mil. až mld. pozic/slov)
  - v jednotném formátu
  - stukturovaný
  - v elektronické podobě

# Textový korpus

- soubor textů
- charakteristiky
  - rozsáhlý (stovky mil. až mld. pozic/slov)
  - v jednotném formátu
  - stukturovaný
  - v elektronické podobě

# Typy korpusů

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

# Typy korpusů

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



# Typy korpusů

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

# Typy korpusů

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

# Typy korpusů

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

# Typy korpusů

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

# 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

# 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

# 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



# 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

# 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

# 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

# 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

# SUSANNE

## SUSANNE

- autor Geoffrey Sampson, Sussex University
- kniha *English for the Computer*
- část korpusu Brown ( $\frac{1}{4}$ )
- nové gramatické značkování
- syntaktické značkování

# SUSANNE

## SUSANNE

- autor Geoffrey Sampson, Sussex University
- kniha *English for the Computer*
- část korpusu Brown ( $\frac{1}{4}$ )
- nové gramatické značkování
- syntaktické značkování

# SUSANNE

## SUSANNE

- autor Geoffrey Sampson, Sussex University
- kniha *English for the Computer*
- část korpusu Brown ( $\frac{1}{4}$ )
- nové gramatické značkování
- syntaktické značkování

# SUSANNE

## SUSANNE

- autor Geoffrey Sampson, Sussex University
- kniha *English for the Computer*
- část korpusu Brown ( $\frac{1}{4}$ )
- nové gramatické značkování
- syntaktické značkování



# SUSANNE

## SUSANNE

- autor Geoffrey Sampson, Sussex University
- kniha *English for the Computer*
- část korpusu Brown ( $\frac{1}{4}$ )
- nové gramatické značkování
- syntaktické značkování

## British National Corpus

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

## British National Corpus

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

## British National Corpus

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

## British National Corpus

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

## British National Corpus

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

## British National Corpus

- britská angličtina, 10% mluva
- první velký korpus pro lexikografy
- vydavatelé slovníků (OUP) + univerzity
- 1991–1994, World Edition 2000
- $\approx$ 3000 textů, 100 mil. slov
- gramatické značkování automatickým nástrojem

## Bank of English

- **britská angličtina**
- COBUILD (HarperCollins), University of Birmingham
- 1991, stále rozšiřován
- 2002,  $\approx$ 450 mil. slov



## Bank of English

- britská angličtina
- COBUILD (HarperCollins), University of Birmingham
- 1991, stále rozšiřován
- 2002,  $\approx$ 450 mil. slov

## Bank of English

- britská angličtina
- COBUILD (HarperCollins), University of Birmingham
- 1991, stále rozšiřován
- 2002,  $\approx 450$  mil. slov

## Bank of English

- britská angličtina
- COBUILD (HarperCollins), University of Birmingham
- 1991, stále rozšiřován
- 2002,  $\approx$ 450 mil. slov

# Další národní korpusy

- Český národní korpus
  - ÚČNK, FF UK
  - SYN2000: 100 mil. slov
  - Litera, Synek, BMK, ...
- Slovenský, Maďarský, Chorvatský, ...
- Americký

# Další národní korpusy

- Český národní korpus
  - ÚČNK, FF UK
    - SYN2000: 100 mil. slov
    - Litera, Synek, BMK, ...
- Slovenský, Maďarský, Chorvatský, ...
- Americký

# Další národní korpusy

- Český národní korpus
  - ÚČNK, FF UK
  - SYN2000: 100 mil. slov
    - Litera, Synek, BMK, ...
- Slovenský, Maďarský, Chorvatský, ...
- Americký

# Další národní korpusy

- Český národní korpus
  - ÚČNK, FF UK
  - SYN2000: 100 mil. slov
  - Litera, Synek, BMK, ...
- Slovenský, Maďarský, Chorvatský, ...
- Americký

# Další národní korpusy

- Český národní korpus
  - ÚČNK, FF UK
  - SYN2000: 100 mil. slov
  - Litera, Synek, BMK, ...
- Slovenský, Maďarský, Chorvatský, ...
- Americký



# Další národní korpusy

- Český národní korpus
  - ÚČNK, FF UK
  - SYN2000: 100 mil. slov
  - Litera, Synek, BMK, ...
- Slovenský, Maďarský, Chorvatský, ...
- Americký

# Korpusy na FI

vytvořené na FI, příklady:

- Desam

- 1996, ručně značkový (desambiguovaný)
- $\approx$ 1 mil. slov

- WWW

- periodika z webu, z let 1996–1998
- $\approx$ 100 mil.

- Chyby

- práce studentů předmětu Základy odb. stylu s vyznačenými chybami
- $\approx$ 400 tis.

# Korpusy na FI

vytvořené na FI, příklady:

- Desam
  - 1996, ručně značkový (desambiguovaný)
  - $\approx$ 1 mil. slov
- WWW
  - periodika z webu, z let 1996–1998
  - $\approx$ 100 mil.
- Chyby
  - práce studentů předmětu Základy odb. stylu s vyznačenými chybami
  - $\approx$ 400 tis.

# Korpusy na FI

vytvořené na FI, příklady:

- Desam
  - 1996, ručně značkový (desambiguovaný)
  - $\approx$ 1 mil. slov
- WWW
  - periodika z webu, z let 1996–1998
  - $\approx$ 100 mil.
- Chyby
  - práce studentů předmětu Základy odb. stylu s vyznačenými chybami
  - $\approx$ 400 tis.

# Korpusy na FI

vytvořené na FI, příklady:

- Desam
  - 1996, ručně značkový (desambiguovaný)
  - $\approx$ 1 mil. slov
- WWW
  - periodika z webu, z let 1996–1998
  - $\approx$ 100 mil.
- Chyby
  - práce studentů předmětu Základy odb. stylu s vyznačenými chybami
  - $\approx$ 400 tis.

# Korpusy na FI

vytvořené na FI, příklady:

- Desam
  - 1996, ručně značkový (desambiguovaný)
  - $\approx$ 1 mil. slov
- WWW
  - periodika z webu, z let 1996–1998
  - $\approx$ 100 mil.
- Chyby
  - práce studentů předmětu Základy odb. stylu s vyznačenými chybami
  - $\approx$ 400 tis.

# Korpusy na FI

vytvořené na FI, příklady:

- Desam
  - 1996, ručně značkový (desambiguovaný)
  - $\approx$ 1 mil. slov
- WWW
  - periodika z webu, z let 1996–1998
  - $\approx$ 100 mil.
- Chyby
  - práce studentů předmětu Základy odb. stylu s vyznačenými chybami
  - $\approx$ 400 tis.

# Korpusy na FI

vytvořené na FI, příklady:

- Desam
  - 1996, ručně značkový (desambiguovaný)
  - $\approx$ 1 mil. slov
- WWW
  - periodika z webu, z let 1996–1998
  - $\approx$ 100 mil.
- Chyby
  - práce studentů předmětu Základy odb. stylu s vyznačenými chybami
  - $\approx$ 400 tis.



# Korpusy na FI

vytvořené na FI, příklady:

- Desam
  - 1996, ručně značkový (desambiguovaný)
  - $\approx$ 1 mil. slov
- WWW
  - periodika z webu, z let 1996–1998
  - $\approx$ 100 mil.
- Chyby
  - práce studentů předmětu Základy odb. stylu s vyznačenými chybami
  - $\approx$ 400 tis.

# Korpusy na FI

vytvořené na FI, příklady:

- Desam
  - 1996, ručně značkový (desambiguovaný)
  - $\approx$ 1 mil. slov
- WWW
  - periodika z webu, z let 1996–1998
  - $\approx$ 100 mil.
- Chyby
  - práce studentů předmětu Základy odb. stylu s vyznačenými chybami
  - $\approx$ 400 tis.

# Korpusy na FI

## spolupráce

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

# Korpusy na FI

## spolupráce

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

# Korpusy na FI

## spolupráce

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

# Korpusy na FI

## spolupráce

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

# Korpusy na FI

## spolupráce

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

# Korpusy na FI

## spolupráce

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



# Korpusy na FI

## spolupráce

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

# Korpusy na FI

## spolupráce

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

# Korpusy na FI

spolupráce

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

# Formáty korpusů

- **archiv/kolekce**
  - různé formáty, podle zdroje/typu
- **textové banky**
  - jednotný formát a základní struktura
  - dokumenty/texty, základní metainformace
- **vertikální text**
- **binární data v aplikaci**
  - pomocná data pro rychlejší zpracování

# Formáty korpusů

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

# Formáty korpusů

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

# Formáty korpusů

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

# Formáty korpusů

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



# Formáty korpusů

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

# Formáty korpusů

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

# Formáty korpusů

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

# Formáty korpusů

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

# Formáty korpusů

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

# Kódování znaků

- 8 bitů  $\approx$  256 znaků
  - ASCII – základ 7 bitů
  - kódování pro češtinu
    - ISO-Latin-2, Windows-1250, 852
- Unicode
  - 32bitů na znak
  - UTF-8
    - 1 až 4 byte na znak
  - UTF-16
    - 2 až 4 byte na znak

# Kódování znaků

- 8 bitů  $\approx$  256 znaků
  - ASCII – základ 7 bitů
  - kódování pro češtinu
    - ISO-Latin-2, Windows-1250, 852
- Unicode
  - 32bitů na znak
  - UTF-8
    - 1 až 4 byte na znak
  - UTF-16
    - 2 až 4 byte na znak

# Kódování znaků

- 8 bitů  $\approx$  256 znaků
  - ASCII – základ 7 bitů
  - kódování pro češtinu
    - ISO-Latin-2, Windows-1250, 852
- Unicode
  - 32bitů na znak
  - UTF-8
    - 1 až 4 bytey na znak
  - UTF-16
    - 2 až 4 bytey na znak



# Kódování znaků

- 8 bitů  $\approx$  256 znaků
  - ASCII – základ 7 bitů
  - kódování pro češtinu
    - ISO-Latin-2, Windows-1250, 852
- Unicode
  - 32bitů na znak
  - UTF-8
    - 1 až 4 bajty
  - UTF-16
    - 2 až 4 bajty

# Kódování znaků

- 8 bitů  $\approx$  256 znaků
  - ASCII – základ 7 bitů
  - kódování pro češtinu
    - ISO-Latin-2, Windows-1250, 852
- Unicode
  - 32bitů na znak
  - UTF-8
    - 1 až 4 byty na znak
  - UTF-16
    - 2 až 4 byty na znak

# Kódování znaků

- 8 bitů  $\approx$  256 znaků
  - ASCII – základ 7 bitů
  - kódování pro češtinu
    - ISO-Latin-2, Windows-1250, 852
- Unicode
  - 32bitů na znak
    - UTF-8
      - 1 až 4 byty na znak
    - UTF-16
      - 2 až 4 byty na znak

# Kódování znaků

- 8 bitů  $\approx$  256 znaků
  - ASCII – základ 7 bitů
  - kódování pro češtinu
    - ISO-Latin-2, Windows-1250, 852
- Unicode
  - 32bitů na znak
  - UTF-8
    - 1 až 4 byty na znak
  - UTF-16
    - 2 až 4 byty na znak

# Kódování znaků

- 8 bitů  $\approx$  256 znaků
  - ASCII – základ 7 bitů
  - kódování pro češtinu
    - ISO-Latin-2, Windows-1250, 852
- Unicode
  - 32bitů na znak
  - UTF-8
    - 1 až 4 byty na znak
  - UTF-16
    - 2 až 4 byty na znak

# Kódování znaků

- 8 bitů  $\approx$  256 znaků
  - ASCII – základ 7 bitů
  - kódování pro češtinu
    - ISO-Latin-2, Windows-1250, 852
- Unicode
  - 32bitů na znak
  - UTF-8
    - 1 až 4 byty na znak
  - UTF-16
    - 2 až 4 byty na znak

# Kódování znaků

- 8 bitů  $\approx$  256 znaků
  - ASCII – základ 7 bitů
  - kódování pro češtinu
    - ISO-Latin-2, Windows-1250, 852
- Unicode
  - 32bitů na znak
  - UTF-8
    - 1 až 4 byty na znak
  - UTF-16
    - 2 až 4 byty na znak

# 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`, `&amp;`, `<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, &amp; , <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, &amp; , <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, &amp;, <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, &amp; , <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`, `&amp;`, `<tag>`
- SGML
  - Standard Generalised Markup Language
  - ISO 8879:1986(E)
- XML
  - Extensible Markup Language
  - W3C, 1998



- 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
  - `&gt;`, `&lt;`, `&amp;`, `&acute;`;

- 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
  - `&gt;`, `&lt;`, `&amp;`, `&acute;`

- 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
  - `&gt;`, `&lt;`, `&amp;`, `&acute;`

- 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
  - `&gt;`, `&lt;`, `&amp;`, `&acute;`

- 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
  - `&gt;`, `&lt;`, `&amp;`, `&acute;`;

- 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
  - `&gt;`, `&lt;`, `&amp;`, `&acute;`;

- 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
  - `&gt;`, `&lt;`, `&amp;`, `&acute;`;

- 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
  - `&gt;`, `&lt;`, `&amp;`, `&acute;`;



- 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
  - `&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

# 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

# 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
- 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
- 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
- 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
- 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
- struktura dokumentu
  - odstavce, nadpisy, verše, věty
- značkování
  - informace o slolech/pozicích
  - morfologie, základní tvary, syntaktické vazby, ...

# 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, ...

# 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, ...

# 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, ...

# 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, ...



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

# 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

# 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

# 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



# 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

# 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

# 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

# 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

# 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

# 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

# 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

# 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
```

# Korpusové manažery

## nástroje na zpracování korpusů

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



# Korpusové manažery

## nástroje na zpracování korpusů

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

# Korpusové manažery

## nástroje na zpracování korpusů

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

# Korpusové manažery

## nástroje na zpracování korpusů

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

# Korpusové manažery

## nástroje na zpracování korpusů

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

# Korpusové manažery

nástroje na zpracování korpusů

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

# System Manatee

- korpusový manažer
- přímo podporuje
  - uložení textu
  - vyhledávání (konkordance)
  - statistiky
- externí nástroje
  - značkování
  - rozdělení do pozic

# System Manatee

- korpusový manažer
- přímo podporuje
  - uložení textu
  - vyhledávání (konkordance)
  - statistiky
- externí nástroje
  - značkování
  - rozdělení do pozic

# System Manatee

- korpusový manažer
- přímo podporuje
  - uložení textu
  - vyhledávání (konkordance)
  - statistiky
- externí nástroje
  - značkování
  - rozdělení do pozic



# System Manatee

- korpusový manažer
- přímo podporuje
  - uložení textu
  - vyhledávání (konkordance)
  - statistiky
- externí nástroje
  - značkování
  - rozdělení do pozic

# System Manatee

- korpusový manažer
- přímo podporuje
  - uložení textu
  - vyhledávání (konkordance)
  - statistiky
- externí nástroje
  - značkování
  - rozdělení do pozic

# System Manatee

- korpusový manažer
- přímo podporuje
  - uložení textu
  - vyhledávání (konkordance)
  - statistiky
- externí nástroje
  - značkování
  - rozdělení do pozic

# System Manatee

- korpusový manažer
- přímo podporuje
  - uložení textu
  - vyhledávání (konkordance)
  - statistiky
- externí nástroje
  - značkování
  - rozdělení do pozic

# System 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

# 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

# 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



# 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

# 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

# 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

# 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
  - až 2 mld. pozic
  - neomezeně atributů a metainformací
- rychlost
  - vyhledávání, statistiky

# Klíčové vlastnosti

- modulární systém
- přístup z různých rozhraní
  - grafické uživatelské rozhraní (Bonito)
  - aplikační programové rozhraní (API)
  - příkazový řádek
- rozsáhlá data
  - až 2 mld. pozic
  - neomezeně atributů a metainformací
- rychlost
  - vyhledávání, statistiky

# Klíčové vlastnosti

- modulární systém
- přístup z různých rozhraní
  - grafické uživatelské rozhraní (Bonito)
  - aplikační programové rozhraní (API)
  - příkazový řádek
- rozsáhlá data
  - až 2 mld. pozic
  - neomezeně atributů a metainformací
- rychlost
  - vyhledávání, statistiky

# Klíčové vlastnosti

- modulární systém
- přístup z různých rozhraní
  - grafické uživatelské rozhraní (Bonito)
  - aplikační programové rozhraní (API)
  - příkazový řádek
- rozsáhlá data
  - až 2 mld. pozic
  - neomezeně atributů a metainformací
- rychlost
  - vyhledávání, statistiky



# Klíčové vlastnosti

- modulární systém
- přístup z různých rozhraní
  - grafické uživatelské rozhraní (Bonito)
  - aplikační programové rozhraní (API)
  - příkazový řádek
- rozsáhlá data
  - až 2 mld. pozic
  - neomezeně atributů a metainformací
- rychlost
  - vyhledávání, statistiky

# Klíčové vlastnosti

- modulární systém
- přístup z různých rozhraní
  - grafické uživatelské rozhraní (Bonito)
  - aplikační programové rozhraní (API)
  - příkazový řádek
- rozsáhlá data
  - až 2 mld. pozic
  - neomezeně atributů a metainformací
- rychlost
  - vyhledávání, statistiky

# Klíčové vlastnosti

- modulární systém
- přístup z různých rozhraní
  - grafické uživatelské rozhraní (Bonito)
  - aplikační programové rozhraní (API)
  - příkazový řádek
- rozsáhlá data
  - až 2 mld. pozic
  - neomezeně atributů a metainformací
- rychlost
  - vyhledávání, statistiky

# Klíčové vlastnosti

- modulární systém
- přístup z různých rozhraní
  - grafické uživatelské rozhraní (Bonito)
  - aplikační programové rozhraní (API)
  - příkazový řádek
- rozsáhlá data
  - až 2 mld. pozic
  - neomezeně atributů a metainformací
- rychlost
  - vyhledávání, statistiky

# Klíčové vlastnosti

- modulární systém
- přístup z různých rozhraní
  - grafické uživatelské rozhraní (Bonito)
  - aplikační programové rozhraní (API)
  - příkazový řádek
- rozsáhlá data
  - až 2 mld. pozic
  - neomezeně atributů a metainformací
- rychlost
  - vyhledávání, statistiky

# Klíčové vlastnosti

- modulární systém
- přístup z různých rozhraní
  - grafické uživatelské rozhraní (Bonito)
  - aplikační programové rozhraní (API)
  - příkazový řádek
- rozsáhlá data
  - až 2 mld. pozic
  - neomezeně atributů a metainformací
- rychlost
  - vyhledávání, statistiky

# Klíčové vlastnosti

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

# Klíčové vlastnosti

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



# Klíčové vlastnosti

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

# Klíčové vlastnosti

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

# Klíčové vlastnosti

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

# Klíčové vlastnosti

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

# Klíčové vlastnosti

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

# Klíčové vlastnosti

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

# Klíčové vlastnosti

- multihodnoty
  - zpracování víceznačných značkování
- dynamické atributy
  - vyhledávání a statistiky na počítaných datech
- subkorpusy
- 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



# Klíčové vlastnosti

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

# Klíčové vlastnosti

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

# Klíčové vlastnosti

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

# Klíčové vlastnosti

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