

# Word Level Analysis

Pavel Šmerk

Natural Language Processing Centre, Faculty of Informatics  
Masaryk University, Brno, Czech Republic

16. 5. 2014

# Motivation

## chladnička s mrazákem

Přibližný počet výsledků: 1 940 000 (0,16 s)

### [Volně stojící chladničky s mrazákem dole | MALL.CZ](#)

Nabízíme zajímavou nabídku volně stojících chladniček s **mrazákem** dole značek AEG, Amica, baumatic, Fagor, LG a další. Vše pohodlně do 24 hodin u vás.

### [DATART | Ledničky](#)

Chladničky kombinované s mrazákem nahoře. Americké chladničky. Auto, přenosné ... NO FROST **chladnička s mrazákem**. Doprava Datart. Přidat do porovnání ...

### [Lednice A++ - Heureka.cz](#)

A++, kombinované, volně stojící, 230 l , 180 cm , **Mrazák**. Úsporná kombinovaná **chladnička** Gorenje RK 61820 W je řazena do energetické třídy A++. Police ve ...

### [Bílé zboží > Chladničky > Mrazák dole - Srovnání cen - Zalevno.cz](#)

Porovnejte si ceny zboží z kategorie Bílé zboží > **Chladničky > Mrazák dole** - najdete nejlevnější obchod.

# Motivation

- Many applications need a tool for “clustering” of word forms appearing in texts:
  - *chladniček*
  - *chladničky*
  - *chladničkách*  $\iff$  *chladnička*
  - *chladničce*
  - ...
- Indexing, searching, keyword extraction, ...
- And almost all NLP tools

# Word Level Processing Data for Czech

- For almost 12 M word forms (incl. colloquial forms):
  - lemma (canonical form, dictionary form)
  - grammatical information: part of speech, number, case etc.
- Word form *stroj* has 3 interpretations:
  - lemma *stroj*, nominative
  - lemma *stroj*, accusative
    - noun, masculine animated, singular
  - lemma *strojit*,
    - verb, 2<sup>nd</sup> person, singular, imperative mood

# Possible Applications

- Various types of analyses:
  - word form  $\Rightarrow$  lemma (many types of searching/indexation)
    - *nebral*  $\Rightarrow$  *brát/nebrat* (úplatky)
    - *nejstaršího*  $\Rightarrow$  *nejstarší/starý* (člověk)
    - *chladnička*  $\Rightarrow$  *chladničky* (as a class)
    - *bavlna*  $\Leftrightarrow$  *bavlněný* (word derivation)
  - word form/lemma + gram. info.  $\Rightarrow$  word form
    - e.g. salutation generation: *pane Procházko*
  - word form/lemma  $\Rightarrow$  all word forms
  - word form  $\Rightarrow$  lemma + full/partial grammatical information
- The analysis is very fast
  - approx. 1 million word forms per second

# Processing Unknown Words

- Some word forms in processed texts are unknown:
  - terms *polydaktylie*, neologisms *klausoviny*, typos *bizardního*, colloquial words *plaťáky*, etc.
- An ending of the word form is able to determine e.g.
  - lemma: *klausoviny*  $\Rightarrow$  *klausovina*
  - grammatical information: *bizardního*  $\Rightarrow$  genitive, etc.
  - derivational relations: *plaťáky*  $\Rightarrow$  *plaťákový*
- Texts from a particular domain allows grouping of unknown word forms:
  - *polydaktylie*, *polydaktiliích*, *polydaktylí*, ...  $\Leftrightarrow$  *polydaktylie*
  - $\Rightarrow$  extension of data or more precise “guessing”

# Resolving Ambiguities Using Context

- An extreme case *Stroj ženu holí.*
  - *Já stroj ženu holí, ty stroj ženu holí, ten stroj ženu holí.*
- Usual case is e.g. *stát*
  - noun: *Stát jsem já.*
  - verb: *Celá továrna musela hodinu stát.*
  - at the part of speech level, it is a bigger problem for English
- The context of the word determines its interpretation
  - rules and/or statistical data describe typical contexts of nouns, verbs, etc.
  - using such information one can tell that *stát* is noun/verb

# Example of Contexts — Word Sketches

## stát podstatné jméno

<a href="#">a modifier</a>	<a href="#">938517</a>	<a href="#">-0.8</a>	<a href="#">gen 2</a>	<a href="#">274456</a>	<a href="#">-0.7</a>	<a href="#">post verb</a>	<a href="#">143087</a>	<a href="#">-0.8</a>
spojený	<a href="#">223381</a>	12.28	hlava	<a href="#">20922</a>	8.7	dotovat	<a href="#">433</a>	6.3
členský	<a href="#">137993</a>	11.83	zastupování	<a href="#">2716</a>	8.24	mocť	<a href="#">15773</a>	5.93
americký	<a href="#">29942</a>	9.01	složka	<a href="#">5263</a>	7.9	hodlat	<a href="#">528</a>	5.87
demokratický	<a href="#">12202</a>	8.46	majetek	<a href="#">5793</a>	7.85	dlužít	<a href="#">342</a>	5.87

## stát sloveso

<a href="#">has subj</a>	<a href="#">942837</a>	<a href="#">-3.7</a>	<a href="#">post v</a>	<a href="#">184481</a>	<a href="#">-1.5</a>	<a href="#">is subj of</a>	<a href="#">127156</a>	<a href="#">-0.5</a>
zázrak	<a href="#">4433</a>	7.12	čelo	<a href="#">11624</a>	9.36	zavázat	<a href="#">469</a>	6.58
nehoda	<a href="#">4438</a>	6.87	pozadí	<a href="#">2507</a>	7.83	hospodařit	<a href="#">517</a>	6.56
socha	<a href="#">3587</a>	6.72	fronta	<a href="#">2654</a>	7.72	zůstat	<a href="#">3245</a>	6.5
kostel	<a href="#">3714</a>	6.39	přepočť	<a href="#">1098</a>	7.35	přispívat	<a href="#">1021</a>	6.46



# Spellchecking and Diacritics Restoration

- Data also allow spellchecking and diacritics restoration:

Result of tool CZ accent

Pred domem zastekal cerny pes.

Před domem zaštěkal černý pes.

# Universality

- All the mentioned processes can be
  - tuned for a specific domain
    - using texts from this domain
  - applied to a language other than Czech
    - (Slovak, Polish, German, English, ...)

# Latest Applications

- Seznam.cz, Yandex.ru, Aukro.cz, Václav Havel Library
  - indexing and searching
- Information System of Masaryk University
  - other universities and schools (FHS UK, JAMU, VŠFS, . . . )
  - affiliate projects (theses.cz, odevzdej.cz, repozitar.cz)
  - indexing, searching and plagiarism detection
- “Internetová jazyková příručka”
  - online source on Czech orthography and grammar
  - NLP Centre data were a starting point for word form tables

# Conclusions

- Word level processing of texts allows:
  - various types of base word determining  
which forms are to be grouped together
  - ambiguity resolution according to the context
  - word form generation
  - spellchecking, diacritics restoration
- The tools/data can be domain specific and for various languages