

# Vybrané aktuální projekty Centra ZPJ

Vojtěch Kovář, Zuzana Nevěřilová

E-mail: [xkovar3@fi.muni.cz](mailto:xkovar3@fi.muni.cz), [xpopelk@fi.muni.cz](mailto:xpopelk@fi.muni.cz)  
[http://nlp.fi.muni.cz/poc\\_lingv/](http://nlp.fi.muni.cz/poc_lingv/)

Obsah:

- ▶ Automatické rozpoznání významů slov
- ▶ TextPerience: Experience the Text

## Automatické rozpoznání významů slov

Kontext:

- ▶ „One-click dictionary”
- ▶ post-editing lexicography

Cíl – word sense induction, WSI:

- ▶ vstup: označkovaný korpus + slovo
- ▶ výstup: rozdelení významů pro dané slovo
- ▶ výstup: indikátory významů

Usnadnění práce pro editora slovníku:

- ▶ pouze editace draftu hesla
- ▶ DWS (dictionary writing system) musí podporovat snadnou editaci významů

# Metody

Kolokace a dokumenty:

- ▶ dokument obvykle obsahuje pouze 1 význam
- ▶ jedna kolokace často znamená 1 význam

Word embeddings:

- ▶ vektor slova může být součtem více vektorů
- ▶ = významů
- ▶ hledáme nejlepší rozdělení

## Kolokace a dokumenty

Algoritmus:

- ▶ pokud má kolokace **dost** dokumentových souvýskytů s nějakou kolokací v již existujícím clusteru, přidej ji do clusteru
- ▶ jinak vytvoř nový cluster
- ▶ **dost** = funkce frekvence slova (1/5000)
- ▶ významy = clustery
- ▶ indikátory významů = kolokace

Problémy:

- ▶ princip "1 sense per collocation" ne vždy funguje
- ▶ kolokace se všemi významy slova
- ▶ parametry jsou důležité
- ▶ (min. freq. = 100, min. score = 3)

## Příklad

# Word embeddings

Skip-gram:

- ▶ pro každé slovo  $W$
- ▶ pravděpodobnost, že určité slovo se vyskytne v okolí  $W$

Adaptive skip-gram (Adagram):

- ▶ pro každé slovo  $W$  a index významu
- ▶ pravděpodobnost, že určité slovo se vyskytne v okolí  $W$
- ▶ musíme předem určit počet významů

Výstup:

- ▶ vektory pro jednotlivé významy
- ▶ indikátory významů = podobná slova (blízké vektory)

## Adagram – příklad

Lodička:

- ▶ střevíček kozačka botka bota páskový balerína balerínka podpatek
- ▶ člun kajak pramice kanoe parník lod'ka lod'ka kánoe
- ▶ skořápka skořápkový rozkrajování lod'ka košíček pouštění zvoneček věneček
- ▶ lod'ka sandál bota botka teniska vratký polobotka bosý
- ▶ teniska tričko mikina gumáček vestička gumák bota džíny

# Úspěšnost

Základní vyhodnocení (10 víceznačných slov, asi 30 významů):

	Precision	Recall
Docs CZ	46 %	61 %
Adagrams CZ	38 %	61 %
Docs DK	67 %	84 %
Adagrams DK	18 %	35 %

Poznámky:

- ▶ čistota korpusu může mít velký vliv
- ▶ špatně definovaný úkol, spolehlivé vyhodnocení je problém

## Výhody a nevýhody

Kolokace a dokumenty:

- ▶ závislé na gramatice pro slovní profily (sketch grammar), značkování apod.
- ▶ problém s kolokacemi všech významů
- ▶ technicky přímočaré
- ▶ propojené s korpusovým manažerem
- ▶ snadno se ladí

Word embeddings:

- ▶ černá skříňka – prakticky nejde ladit
- ▶ musíme předem určit počet významů
- ▶ není snadné určit, do kterého významu patří konkrétní výskyt
- ▶ výpočetně náročné
- ▶ nezávislé, potřebujeme pouze texty

# Možná vylepšení

Kombinace:

- ▶ vytvoříme vektory pro kolokace, ty pak budeme clusterovat

Detekce kolokací se všemi významy:

- ▶ vytvoříme matici dokumentových souvýskytů všech kolokací
- ▶ hledáme skupinky
- ▶ kolokace se všemi významy bude možné poznat

## TextPerience: Experience the Text



Upload a document or enter an URL

File uploaded  
120932 bytes

HyperText Markup Language  
(HTML)



Extract text from the document

The text extraction quality depends on the data format and the way it was created. Extraction method Justext, the content is encoded in utf-8. language: English

[SEE THE TEXT](#)



See what we can recognize in the text

We use linguistic analysis, corpus tools, and mathematics.

offer board  
easyJet  
policy Scent  
food Range  
product  
Chris\_Ratcliffe  
42\_pér\_cent  
April Bloomberg\_FinanceIn  
Gatwick  
Ryanair Greece  
British\_Airways Cruz  
BA Turkey  
Greg\_Balfour easyJet  
Gatwick\_Airport

# TextPerience: Experience the Text

- ▶ a demo application
- ▶ complete processing pipeline from data to knowledge:
  1. convert an uploaded file to text
  2. detect language
  3. apply keyword search
  4. recognize named entities
  5. perform Wikipedia search of the keywords
  6. evaluate the results
- ▶ so far, keywords in 12 languages (cs, sk, en, de, fr, it, es, vi, pl, hu, da, ru)
- ▶ so far, named entities in 5 languages (cs, en, es, de, ru)

## TextPerience I: Extract Texts from Files

After a successful MIME type guessing . . .

- ▶ use Apache Tika for Office-like texts and PDFs
- ▶ use JusText for extracting text from web pages, Pomikálek (2011)
- ▶ take plain texts as they are

many other file types:

- ▶ tables (Excel, TSV, CSV)
- ▶ presentations
- ▶ images (OCR)
- ▶ source codes (plain text with a particular extension)
- ▶ videos (subtitles)
- ▶ . . .

# TextPerience I: Extract Texts from Files

“repair” extracted texts:

- ▶ distorted diacritics in PDFs
- ▶ headers, footers, page numbers
- ▶ hyphenation

# TextPerience I: Extract Texts from Files

selecting the right content from web pages:

JusText parameters vs. customization

<b>Sekunda, která rozděluje svět.</b>	
<b>Půlka lidí slyší něco jiného než vy</b>	
final class	good
cotext-free class	short
heading	True
length (in characters)	66
number of characters within links	0
link density	0.000
number of words	11
number of stopwords	5
stopword density	0.455
html.body.div.div.div.div.div.div.h1	

## TextPerience II: Detect Language(s)

the langid module, Lui and Baldwin (2012)

- ▶ trained for  $\approx$  90 languages, excl. cestina
- ▶ Naive-Bayes classifier on letter n-grams
- ▶ good for longer texts
- ▶ noise reduction needed (HTML tags and entities, URLs, non-words etc.)
- ▶ how about multi-lingual documents?

## TextPerience III: Keyword Search

“language independent” way: TF-IDF

- ▶ tokenize the text
- ▶ detect POS
- ▶ assume keywords to be only nouns
- ▶ lemmatize nouns
- ▶ compute TF-IDF on lemmata
- ▶ what about **keyphrases**?

# TextPerience III: Keyword Search

## Tagging and Lemmatization: a very simplistic approach

- ▶ find a word form in corpus (limit to 10 occurrences)
- ▶ save the most frequent lemma and tag
- ▶ works for all POS-annotated corpora with lemmatization
- ▶ fast and “independent” but not very precise

# TextPerience III: Keyword Search

## TF-IDF on noun lemmata

- ▶ corpora of different sizes for different languages
- ▶ precomputed  $d_f$ s in our corpora
- ▶ what about words not present in our corpora?

# TextPerience IV: Named Entity Recognition

Stanford NER with different models, Finkel et al. (2005)

- ▶ ready to use models for es, en, de
- ▶ training data for cs and ru (see IA161) → new models
- ▶ very different model parameters for e.g. English and German
- ▶ apply models for a language on close languages (e.g. es model on fr)
- ▶ for training models, we need NE annotated corpus

# TextPerience V: Wikipedia Search

use of API MediaWiki (2015)

- ▶ for each keyword/NE try to get the most relevant Wikipedia article
- ▶ no keyword scoring employed
- ▶ no graph-based scoring employed
- ▶ no generalization methods
- ▶ different sizes of Wikipedias in different languages

# TextPerience VI: Evaluation

users can click on the evaluation icons  

- ▶ 443 files
- ▶ 1541 evaluations:
  - entities: 586 correct, 220 incorrect
  - keywords: 401 correct, 150 incorrect
- ▶ no learning from evaluations

## Conclusion and Further Work

1. convert an uploaded file to text
  - repair texts from PDFs
2. detect language
  - detect multi-lingual documents, noise reduction
3. apply keyword search
  - better ways to fast lemmatization
  - keyword search in multi-lingual documents
  - keyphrase search (what is a phrase?)
4. recognize named entities
  - evaluation of existing models
  - evaluation of using existing models on close languages
5. perform Wikipedia search of the keywords
  - keyword weighting
  - graph algorithms for disambiguation
  - generalization methods (Wikipedia categories)
6. evaluate the results
  - learning methods

# Try It

Try TextPerience

<http://nlp.fi.muni.cz/projects/textexperience>

## References |

- Finkel, J. R., Grenager, T., and Manning, C. (2005). Incorporating non-local information into information extraction systems by gibbs sampling. In Proceedings of the 43rd Annual Meeting on Association for Computational Linguistics, ACL '05, pages 363–370, Stroudsburg, PA, USA. Association for Computational Linguistics.
- Lui, M. and Baldwin, T. (2012). Langid.py: An Off-the-shelf Language Identification Tool. In Proceedings of the ACL 2012 System Demonstrations, ACL '12, pages 25–30, Stroudsburg, PA, USA. Association for Computational Linguistics.
- MediaWiki (2015). API:Search — MediaWiki, The Free Wiki Engine.
- Pomikálek, J. (2011). jusText. software.