

# PA153 Natural Language Processing

## 10 – Manic Miners

(topic mining, opinion mining, named entity recognition)

Karel Pala, Zuzana Nevěřilová

Centrum ZPJ, FI MU, Brno

13. ledna 2020

1 Text Analysis “without Analysis”

2 Topic Recognition

3 Named Entity Recognition

4 Opinion Mining

# Text Analysis “without Analysis”

The idea:

we can extract information about text without any deep analysis.

e.g. text encoding, text length, language, number of paragraphs, lines, words . . .

Can we extract information about *meaning* without any deep analysis?

# Text Analysis “without Analysis”

The idea:

we can extract information about text without any deep analysis.

e.g. text encoding, text length, language, number of paragraphs, lines, words . . .

Can we extract information about *meaning* without any deep analysis?

Yes but . . .

## Text Analysis “without Analysis”: why?

Typical text analysis proceeds on several levels:  
text segmentation (sentences, tokens), morphological analysis, tagging,  
clause recognition, syntactic parsing, lexical analysis, logical analysis,  
semantic analysis

## Text Analysis “without Analysis”: why?

Typical text analysis proceeds on several levels:  
text segmentation (sentences, tokens), morphological analysis, tagging,  
clause recognition, syntactic parsing, lexical analysis, logical analysis,  
semantic analysis

- no task is 100%, errors propagate to subsequent analyses
- each level contains phenomena that are hard to cover
- not all tasks contribute equally to solving a problem
- many levels = many applications, sometimes processor/memory demanding

## Text Analysis “without Analysis”: advantages

- we focus on a particular problem
- find solution for that particular problem with a certain (high) accuracy
- the tailored solution is very often better/cheaper/faster/more accurate than a general pipeline

## Text Analysis “without Analysis”: general approaches

- some parts of the text are more important than others
- we can identify the important ones and focus only on them

## Text Analysis “without Analysis”: general approaches

- some parts of the text are more important than others
- we can identify the important ones and focus only on them

stoplists, frequency metric TF-IDF, co-occurrence metrics (e.g. pointwise mutual information, PMI), ...

tokenization, POS-tagging, normalization (lowercase, punctuation removal, ...)

## Topic Recognition (Rozpoznávání témat)

Čistý zisk energetické společnosti ČEZ za tři čtvrtletí letošního roku meziročně klesl o 4,7 procenta na 31,7 miliardy korun. Tržby se meziročně snížily o 0,3 procenta na 161,9 miliardy korun. Hlavním důvodem poklesu byly odpisy aktiv kvůli regulacím evropského energetického sektoru a související snížování velkoobchodních cen elektřiny , sdělila firma . Výsledek je tak výrazně pod očekáváním. Analytici totiž předpokládali, že čistý zisk ČEZ stoupne o víc než čtyři procenta na 34,8 miliardy korun. Společnost také oznámila, že kvůli snížení velkoobchodních cen elektřiny a regulatorním zásahům do evropského energetického sektoru snížila celoroční výhled čistého zisku na 35 miliard korun . Původně počítala s výsledkem o 2,5 miliardy vyšším. " Očekávané celoroční výsledky hospodaření ČEZ odrážejí současný stav energetiky v Evropě . Fakt, že na naše výsledky tato krize doléhá později a výrazně méně než na naše evropské konkurenty, reflektuje zejména naši úspěšnou strategii předprodejů elektřiny na roky dopředu a důraz na vnitřní úspory," uvedl k výsledkům předseda představenstva a generální ředitel Daniel Beneš .

# Topic Recognition (Rozpoznávání témat)

Čistý zisk energetické společnosti ČEZ za tři čtvrtletí letošního roku meziročně klesl o 4,7 procenta na 31,7 miliardy korun. Tržby se meziročně snížily o 0,3 procenta na 161,9 miliardy korun. Hlavním důvodem poklesu byly odpisy aktiv kvůli regulacím evropského energetického sektoru a související snížování velkoobchodních cen elektřiny, sdělila firma. Výsledek je tak výrazně pod očekáváním. Analytici totiž předpokládali, že čistý zisk ČEZ stoupne o víc než čtyři procenta na 34,8 miliardy korun. Společnost také oznámila, že kvůli snížení velkoobchodních cen elektřiny a regulatorním zásahům do evropského energetického sektoru snížila celoroční výhled čistého zisku na 35 miliard korun. Původně počítala s výsledkem o 2,5 miliardy vyšším. "Očekávané celoroční výsledky hospodaření ČEZ odrážejí současný stav energetiky v Evropě. Fakt, že na naše výsledky tato krize doléhá později a výrazně méně než na naše evropské konkurenty, reflekтуje zejména naší úspěšnou strategii předprodejů elektřiny na roky dopředu a důraz na vnitřní úspory," uvedl k výsledkům předseda představenstva a generální ředitel Daniel Beneš.

# Topic Recognition (Rozpoznávání témat)

- keyword extraction (extrakce klíčových slov)
- keyphrase extraction (extrakce klíčových frází)
- classification to pre-defined categories (e.g. sports, politics, hobbies...)

Datasets with predefined categories: 20 newsgroups, Reuters

Classification into unknown groups = clustering  
unsupervised approaches (k-nearest neighbors, Latent Dirichlet Allocation – LDA, ...)

# Topic Recognition (Rozpoznávání témat)

- keyword extraction (extrakce klíčových slov)
- keyphrase extraction (extrakce klíčových frází)
- classification to pre-defined categories (e.g. sports, politics, hobbies...)

Datasets with predefined categories: 20 newsgroups, Reuters

Classification into unknown groups = clustering  
unsupervised approaches (k-nearest neighbors, Latent Dirichlet Allocation – LDA, ...)

# Keyword Extraction: common approaches

- statistical: need of reference corpus
  - ▶ word frequency
  - ▶ word collocations and co-occurrences
  - ▶ TF-IDF (short for term frequency-inverse document frequency)
  - ▶ RAKE (Rapid Automatic Keyword Extraction) [Rose et al., 2010]
- deep learning: need of training data

# Keyphrase Extraction

- similar task as the keyword extraction
- key n-grams (1 word = unigram, 2 words = bigram)
- compare n-gram frequencies with those in the reference corpus
- n-gram frequencies are **not** comparable for different  $n$ s

more language dependent than keyword extraction

# Keyphrase Extraction, To|P|icks project

- ① input text is a (short) corpus
- ② a small Czech corpus (Czes2) is a reference corpus
- ③ partial syntactic analysis searches for noun phrases (NP): keyphrase candidates
- ④ score candidate phrases: n-gram frequency in input corpus / n-gram frequency in reference corpus
- ⑤ convert NPs to nominative
- ⑥ boost candidate score with subphrase score
- ⑦ boost candidate score if contains named entities
- ⑧ unboost candidate score if contains numbers or it is too short

## To|P|icks: language (in)dependency

- we assume tokens (text tokenization is weakly language dependent)
  - we measure n-gram lemmata (lemmatization is language dependent)
  - frequency ratio (reference corpus of a particular language needed)
  - partial syntactic analysis (NP patterns are language dependent)
  - named entity recognition (partially language dependent)
- 
- no complete NLP pipeline
  - no explicit semantic analysis

# To|Picks: evaluation

Čistý zisk energetické společnosti ČEZ za tři čtvrtletí letošního roku meziročně klesl o 4,7 procenta na 31,7 miliardy korun. Tržby se meziročně snížily o 0,3 procenta na 161,9 miliardy korun. Hlavním důvodem poklesu byly odpisy aktiv kvůli regulacím evropského energetického sektoru a související snižování velkoobchodních cen elektřiny, sdělila firma. Výsledek je tak výrazně pod očekáváním. Analytici totiž předpokládali, že čistý zisk ČEZ stoupne o více než čtyři procenta na 34,8 miliardy korun. Společnost také oznámila, že kvůli snížení velkoobchodních cen elektřiny a regulatorním zásahům do evropského energetického sektoru snížila celoroční výhled čistého zisku na 35 miliard korun. Původně počítala s výsledkem o 2,5 miliardy vyšším. "Očekávané celoroční výsledky hospodaření ČEZ odrážejí současný stav energetiky v Evropě. Fakt, že na naše výsledky tato krize doléhá později a výrazně méně než na naše evropské konkurenty, reflekтуje zejména naši úspěšnou strategii předprodejů elektřiny na roky dopředu a důraz na vnitřní úspory," uvedl k výsledkům předseda představenstva a generální ředitel Daniel Beneš.

What is a good keyphase?

⇒ in general: is the output of the program correct?

- keyword/keyphrase detection is not a precisely formulated problem
- how to measure difference between the output and the gold standard

# Named Entity Recognition (rozpoznávání pojmenovaných entit)

named entity = person name, location, organization, product name, brand name, artwork, date, time

- often uppercase (counterexample: German, Arabic)
- often several words (overlap with tasks concerning multi-word expressions, MWE)
- often contains foreign words
- often contain non-words (e.g. AK-47)

# Named Entity Recognition: motivation(s)

*Kdo chce vidět Idiota, nechť se dostaví do ředitelny.*

(Obecná škola)

## Named Entity Recognition: motivation(s)

*Kdo chce vidět **Idiota**, nechť se dostaví do ředitelny.*

(Obecná škola)

## Named Entity Recognition: motivation(s)

*Kdo chce vidět **Idiota**, nechť se dostaví do ředitelny.*

(Obecná škola)

*I read I served the king of England and I watched it in the cinema.*

## Named Entity Recognition: motivation(s)

*Kdo chce vidět **Idiota**, nechť se dostaví do ředitelny.*

(Obecná škola)

*I read I served the king of England and I watched it in the cinema.*

# Named Entity Recognition: approaches

- **gazetteers**
  - ▶ list of person names (baby name suggestion sites, name statistics)
  - ▶ list of location (post offices, Open Street Map)
  - ▶ company register (Czech ARES)
  - ▶ artwork listings (IMDB, ČSFD, Goodreads, Databáze knih)
  - ▶ product lists (Heureka.cz, Seznam zboží, Amazon, e-bay)
- patterns in texts: e.g. acronym definitions, operating system (OS)
- patterns in particular types of text: e.g. Mr. X, CTO of Y, ...
  - ▶ Association for ...
  - ▶ Úřad pro ...
- machine learning approaches: conditional random fields (CRFs)
- deep learning: gazetteer information + CRFs incorporated into the neural network

# Named Entity Recognition: approaches

- gazetteers
  - ▶ list of person names (baby name suggestion sites, name statistics)
  - ▶ list of location (post offices, Open Street Map)
  - ▶ company register (Czech ARES)
  - ▶ artwork listings (IMDB, ČSFD, Goodreads, Databáze knih)
  - ▶ product lists (Heureka.cz, Seznam zboží, Amazon, e-bay)
- patterns in texts: e.g. acronym definitions, operating system (OS)
- patterns in particular types of text: e.g. Mr. X, CTO of Y, ...
  - ▶ Association for ...
  - ▶ Úřad pro ...
- machine learning approaches: conditional random fields (CRFs)
- deep learning: gazetteer information + CRFs incorporated into the neural network

# Named Entity Recognition: approaches

- gazetteers
  - ▶ list of person names (baby name suggestion sites, name statistics)
  - ▶ list of location (post offices, Open Street Map)
  - ▶ company register (Czech ARES)
  - ▶ artwork listings (IMDB, ČSFD, Goodreads, Databáze knih)
  - ▶ product lists (Heureka.cz, Seznam zboží, Amazon, e-bay)
- patterns in texts: e.g. acronym definitions, operating system (OS)
- patterns in particular types of text: e.g. Mr. X, CTO of Y, ...
  - ▶ Association for ...
  - ▶ Úřad pro ...
- machine learning approaches: conditional random fields (CRFs)
- deep learning: gazetteer information + CRFs incorporated into the neural network

# Named Entity Recognition: approaches

- gazetteers
  - ▶ list of person names (baby name suggestion sites, name statistics)
  - ▶ list of location (post offices, Open Street Map)
  - ▶ company register (Czech ARES)
  - ▶ artwork listings (IMDB, ČSFD, Goodreads, Databáze knih)
  - ▶ product lists (Heureka.cz, Seznam zboží, Amazon, e-bay)
- patterns in texts: e.g. acronym definitions, operating system (OS)
- patterns in particular types of text: e.g. Mr. X, CTO of Y, ...
  - ▶ Association for ...
  - ▶ Úřad pro ...
- machine learning approaches: conditional random fields (CRFs)
- deep learning: gazetteer information + CRFs incorporated into the neural network

# Named Entity Recognition: approaches

- gazetteers
  - ▶ list of person names (baby name suggestion sites, name statistics)
  - ▶ list of location (post offices, Open Street Map)
  - ▶ company register (Czech ARES)
  - ▶ artwork listings (IMDB, ČSFD, Goodreads, Databáze knih)
  - ▶ product lists (Heureka.cz, Seznam zboží, Amazon, e-bay)
- patterns in texts: e.g. acronym definitions, operating system (OS)
- patterns in particular types of text: e.g. Mr. X, CTO of Y, ...
  - ▶ Association for ...
  - ▶ Úřad pro ...
- machine learning approaches: conditional random fields (CRFs)
- deep learning: gazetteer information + CRFs incorporated into the neural network

# Named Entity Recognition in Czech: project CNER

- list of given names and family names (in all cases)
- list of named entities from Wikipedia (mostly nominative)
- list of product names from Heureka.cz (nominative only)
- list of book/film names
- regular expressions (date, time, amount+currency ... )
- law identifiers

# NER Challenges

- NE boundary detection
- punctuation inside NE (Čtyři vraždy stačí, drahoušku)

# NER Challenges

- NE boundary detection
- punctuation inside NE (Čtyři vraždy stačí, drahoušku)
- NE inflection (Mnohé mám dodnes před očima: Erži z Kočičí hry, Runu z Radúze a Mahuleny, Čapkou Matku, Bontovou z Přísných milenců, Isabelu z Cesty Karla IV. do Francie a zpět, Hejtmanku z Revizora, Matku z Kočky na rozpálené plechové střeše. . . )

# NER Challenges

- NE boundary detection
- punctuation inside NE (Čtyři vraždy stačí, drahoušku)
- NE inflection (Mnohé mám dodnes před očima: Erži z Kočičí hry, Runu z Radúze a Mahuleny, Čapkou Matku, Bontovou z Přísných milenců, Isabelu z Cesty Karla IV. do Francie a zpět, Hejtmanku z Revizora, Matku z Kočky na rozpálené plechové střeše. . . )
- high ambiguity **It** is a scary novel by Stephen King. I know it.

# NER Challenges

- NE boundary detection
- punctuation inside NE (Čtyři vraždy stačí, drahoušku)
- NE inflection (Mnohé mám dodnes před očima: Erži z Kočičí hry, Runu z Radúze a Mahuleny, Čapkou Matku, Bontovou z Přísných milenců, Isabelu z Cesty Karla IV. do Francie a zpět, Hejtmanku z Revizora, Matku z Kočky na rozpálené plechové střeše. . . )
- high ambiguity It is a scary novel by Stephen King. I know it.
- NE nesting (The picture of Dorian Gray)

# NER Challenges

- NE boundary detection
- punctuation inside NE (Čtyři vraždy stačí, drahoušku)
- NE inflection (Mnohé mám dodnes před očima: Erži z Kočičí hry, Runu z Radúze a Mahuleny, Čapkou Matku, Bontovou z Přísných milenců, Isabelu z Cesty Karla IV. do Francie a zpět, Hejtmanku z Revizora, Matku z Kočky na rozpálené plechové střeše. . . )
- high ambiguity It is a scary novel by Stephen King. I know it.
- NE nesting (The picture of Dorian Gray)
- NE synonymy (Karel Schwarzenberg–Karel Jan Nepomuk Josef Norbert Bedřich Antonín Vratislav Menas kníže ze Schwarzenbergu–Karl Johannes Nepomuk Josef Norbert Friedrich Antonius Wratislaw Mena Fürst zu Schwarzenberg–Šláfenberk)

# NER Challenges

- NE boundary detection
- punctuation inside NE (Čtyři vraždy stačí, drahoušku)
- NE inflection (Mnohé mám dodnes před očima: Erži z Kočičí hry, Runu z Radúze a Mahuleny, Čapkou Matku, Bontovou z Přísných milenců, Isabelu z Cesty Karla IV. do Francie a zpět, Hejtmanku z Revizora, Matku z Kočky na rozpálené plechové střeše. . . )
- high ambiguity It is a scary novel by Stephen King. I know it.
- NE nesting (The picture of Dorian Gray)
- NE synonymy (Karel Schwarzenberg–Karel Jan Nepomuk Josef Norbert Bedřich Antonín Vratislav Menas kníže ze Schwarzenbergu–Karl Johannes Nepomuk Josef Norbert Friedrich Antonius Wratislaw Mena Fürst zu Schwarzenberg–Šláfenberk)
- homonymy (Queen Elisabeth: person, another person, ship, car, musical band)

## NER Evaluation: Typical scheme

- true positives (X is recognized as NE and it is a NE)
- true negatives (X is recognized as non-NE and it is not a NE)
- false positives (X is recognized as NE but it is not)
- false negatives (X is recognized as non-NE but it is a NE)

## NER Evaluation: Typical scheme

- true positives (X is recognized as NE and it is a NE)
- true negatives (X is recognized as non-NE and it is not a NE)
- false positives (X is recognized as NE but it is not)
- false negatives (X is recognized as non-NE but it is a NE)

confusion matrix (matice záměn):

		prediction	
gold standard		+	-
+	true positive	false negative	
	false positive	true negative	

## NER Evaluation: Typical scheme

- true positives (X is recognized as NE and it is a NE)
- true negatives (X is recognized as non-NE and it is not a NE)
- false positives (X is recognized as NE but it is not)
- false negatives (X is recognized as non-NE but it is a NE)

confusion matrix (matice záměn):

		prediction	
gold standard		+	-
+	true positive	false negative	
	false positive	true negative	

overall accuracy (celková správnost):  $Acc = \frac{TP+TN}{TP+TN+FP+FN}$

overall error (celková chyba):  $Err = \frac{FP+FN}{TP+TN+FP+FN}$

## NER Evaluation: Typical scheme

- true positives (X is recognized as NE and it is a NE)
- true negatives (X is recognized as non-NE and it is not a NE)
- false positives (X is recognized as NE but it is not)
- false negatives (X is recognized as non-NE but it is a NE)

confusion matrix (matice záměn):

		prediction	
gold standard		+	-
+	true positive	false negative	
	false positive	true negative	

overall accuracy (celková správnost):  $Acc = \frac{TP+TN}{TP+TN+FP+FN}$

overall error (celková chyba):  $Err = \frac{FP+FN}{TP+TN+FP+FN}$

precision (přesnost):  $\frac{TP}{TP+FP}$

recall (pokrytí/úplnost):  $\frac{TP}{TP+FN}$  F-measures (F-míry): combination of precision and recall

# Opinion mining, sentiment analysis: motivations

Klidně se nazvou Věci veřejné, slíbí vám transparentnost, antikorupci, žádné dinosaury a již zítra si sednou do vlády s největšími dinosaury, sami iniciují zachování akcí na doručitele a uzavřou „veřejnou“ tajnou hradní dohodu. Klidně se nazvou TOP – v překladu tradice – odpovědnost – prosperita a do čela si postaví provařeného politického turistu, nejneodpovědnější persónu v oblasti financí v politice a sedětou z vás zaživa kůži.

- to distinguish fact and opinions (levels of subjectivity)
- to monitor public opinion

# Opinion mining: methods

- key phrases detection: politika, odpovědnost, dinosaurus, dohoda
- NER: Věci veřejné, TOP
- evaluative expressions (hodnotící výrazy): provázený,  
nejneodpovědnější, tajný, dinosaurus, persóna, sedět kůži zaživa
- partial syntactic analysis: to assign opinion to the right target

## Opinion Mining: sentiment lexicons

positive: awesome, cool, great, beautiful, amazing, advantage, improve

negative: stupid, over-complicated, break, lose, difficult, bad

neutral, evaluative in particular contexts: thin (phone vs. steak), economy

*He: Do you want to go get some dinner on Friday night?*

*You: Not with this economy.*<sup>1</sup>

Bing Liu's Sentiment Lexicon: <https://www.cs.uic.edu/~liub/FBS/sentiment-analysis.html#lexicon>

### challenges

- the target of the evaluation
- multiple targets with different sentiment
- evaluative neologisms
- sarcasm

---

<sup>1</sup><https://www.urbandictionary.com/define.php?term=Economy>

## Conclusion: Extraction of \* from texts

- without complete NLP pipeline
- tailored to needs of a particular NLP task
- rule-based, statistical, machine learning, deep learning methods
- different degree of language dependency
- difficult to evaluate (difficult to set the correct output for all inputs)

# Odkazy I

-  Diatelová, I. (2013 [cit. 2013-11-24]).  
Urálivé, vulgární a rasistické projevy na internetových diskusních fórech [online].  
Bakaláøská práce, Masarykova univerzita, Filozofická fakulta.
-  Liu, B. (2004-2012).  
Opinion mining, sentiment analysis, and opinion spam detection.  
<http://www.cs.uic.edu/~liub/FBS/sentiment-analysis.html>.
-  Rose, S., Engel, D., Cramer, N., and Cowley, W. (2010).  
*Automatic Keyword Extraction from Individual Documents*, pages 1 – 20.