

# IB047

## Automatické značkování

Pavel Rychlý

pary@fi.muni.cz

28. dubna 2021

# Automatické značkování

- vstup text
- výstup text + morfologické značky, příp. základní tvary
- různé přístupy
  - pravidlové
  - statistické
  - neuronové sítě
- trénování na označovaných datech
- s pomocí externích zdrojů (morfologické databáze), velkých (neoznačovaných) korpusů
- vyhodnocení na **nazávislých** datech

# Vyhodnocení značkování

## Porovnání proti *pravdě* (Gold Standard)

Všechny	DET	PRON	<<
tři	NUM	NUM	
světy	NOUN	NOUN	
si	PRON	PRON	
vzájemně	ADV	ADV	
trvale	ADV	ADV	
povídají	VERB	VERB	
a	CCONJ	CCONJ	
ovlivňují	VERB	VERB	
se	PRON	ADP	<<

- 10 tokenů, 2 chyby
- úspěšnost (accuracy):  $8/10 = 80\%$
- chybovost (error rate):  $2/10 = 20\%$

$$accuracy = \frac{correct}{alltokens} \quad errorrate = 1 - accuracy$$

Při možnosti více značek pro jeden token

- precision – přesnost

$$precision = \frac{tp}{tp + fp}$$

- recall – pokrytí

$$recall = \frac{tp}{tp + fn}$$

- accuracy – úspěšnost

$$accuracy = \frac{tp + tn}{tp + tn + fp + fn}$$

- každý token jedna značka:  $acc = prec = rec$

- pravděpodobnosti značek, slov, ...
- odhad pravděpodobností z trénovacích dat

	počet výskytů	pravděpodobnost
<i>se</i>	16289	
<i>se PRON</i>	14966	$P(\text{PRON} \textit{se}) = 14966/16289 = 0.919$
<i>se ADP</i>	1323	$P(\text{ADP} \textit{se}) = 1323/16289 = 0.081$

- volíme nejpravděpodobnější značku

- (ne-)nulová pravděpodobnost pro neviděné jevy
- snížení posti pro časté jevy, určení posti pro neviděné jevy
- Good-Turing

$$N = \sum_{r=1}^{max} rN_r$$

$$p_0 = N_1 / N$$

$$p_r = \frac{(r+1)S(N_{r+1})}{rS(N_r)}$$

- pravidla: *slovo není VERB pokud je předchozí slovo “the”*
- hlavně dříve:
  - ruční vytváření + případné ověřování v korpusu
- automatiké učení pravidel (Brillův tagger)
- většinou méně robustní

- formou učení jsou podobné statistickým metodám
- velký rozvoj zhruba od roku 2014
- využití jednoduchých nástrojů pro word embeddings  
mapování *slovo* → *300D vektor čísel*
- pro složitější modely nemáme vysvětlení



# Kombinování přístupů

- ořezávací pravidla + dořešení víceznačností statistikou
- použití ručního slovníku  $\approx$  pravidla
- hlasování/váhování různých přístupů

desamb.sh:

```
tecky.pl | majka -p -f majka.w-lt \  
| guesser.pl | remove.pl remove.znacky \  
| disna d | statdesam.pl
```

## KernelTagger

- most probable PoS tag for annotated words
- derive a PoS tag from 5 most similar words (kernel trick)
- word similarities from a big corpus

# Word Similarity Computation

- context: one preceding and one following word
- logDice salience  $D(w_a, c)$  of word  $w_a$  and context  $c$ .
- count only contexts with  $D(w_a, c) > 0$
- similarity of words  $w_a$  and  $w_b$ :

$$\text{sim}(w_a, w_b) = \frac{\sum_c \min(D(w_a, c), D(w_b, c))}{\sum_c D(w_a, c) + \sum_c D(w_b, c)}$$

- Sketch Engine Thesaurus
- word embeddings similarity