

Automatická detekce podstatné informace z telefonních hovorů

Sandra Tukačová

Zpracováno dle článku

A Context-Aware NLP Approach For Noteworthiness Detection in Cellphone Conversations

Autoři: **Francesca Bonin, Jose San Pedro, Nuria Oliver**
Telefonica Research (Barcelona)

COLING 2014, the 25th International Conference on Computational Linguistics
Dublin, Ireland, August 23-29 2014

<http://anthology.aclweb.org/C/C14/C14-1004.pdf>

K čemu to je?

- ▶ Ve světě velké množství hovorů
- ▶ Uživatelé sami žádají možnost záznamu – až 40 %
- ▶ Předcházení hrozob

Získání dat

- ▶ Výběr dobrovolníků
- ▶ Záznam hovorů (796)
- ▶ Poloautomatický přepis hovorů do textové podoby
- ▶ Ruční anotace vlastního hovoru účastníky

Rozdělení dat

- ▶ Množina G (bez problémových) – 659 hovorů
 - ▶ 22 474 replik
 - ▶ Z toho jen 671 označeno jako podstatné (2.98 %)
- ▶ Podmnožina A (45 %) – 295 hovorů – alespoň 1 anotace
 - ▶ 10, 642 replik
 - ▶ Z toho 671 označeno jako podstatné (6.3 %)

Typy anotací

- ▶ Podání informace (Giving Information) 47 %
- ▶ Žádost o informaci (Requesting Information) 22 %
- ▶ Referování o nějaké události (*Reporting on an Action*) 3 %
- ▶ Jiné (Other) 26 %
 - ▶ Pozdravy
 - ▶ Vyjádření souhlasu

Obsahové rysy

CONTENT FEATURES	
C-BoW (Bag of Words)	
BoW	BoW for all words (except hapax)
C-T (Turn-based)	
NE	Presence (or frequency) of NEs (Person, Location, Organization, Numbers, Dates, Misc.)
TLN	Turn length in # words normalized
PoS	PoS distribution
TF	Max and Mean term frequency
IDF	Max and Mean inverse document frequency
C-D (Dynamic)	
Rep	Repetition between t and t-1,t+1,t-2,t+2
Int	Presence (or total amount) of Int. pro./adj. in t-1
Q	Presence (or total amount) of question in t-1
C-C (Conversational)	
Dur	Duration of the call (# turns and # words)
Cent	Conversation centrality
Spk	Speaker
Dom	Speaker dominance

Kontextové rysy

CONTEXT FEATURES	
X-C (Call-based)	
X-C-T	Time of the call
X-C-Loc	Location of the call
X-C-Day	Day of the call
X-C-Obj	Objective of the call
X-U (User-based)	
X-U-G	Gender
X-U-A	Age
X-U-I	Income
X-U-E	Education
X-U-Ms	Marital Status

Výpočet F-score

$$F_1 = 2 \cdot \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}}$$

Harmonický průměr

- Přesnost = kolik z vybraných je relevantní
- Pokrytí = kolik z relevantních je vybráno

Zhodnocení výsledků

- ▶ Dosud nebyla zveřejněna žádná studie se stejným zaměřením
- ▶ Nejpodobnější je studie Banerjee and Rudnický, 2009
 - ▶ Co si zapsat z porady
 - ▶ Nízká mezianotátorská shoda
 - ▶ Lidští anotátoři F-score = 0,38
 - ▶ Systém (rozhodovací stromy) F-score = 0,14
- ▶ Popisovaná studie
 - ▶ Poznámky z telefonních hovorů
 - ▶ Učení s učitelem F-score = 0,32
 - ▶ Kombinace obsahových i kontextových rysů

Závěr

- ▶ První krok k inteligentnímu systému, který by byl schopen anotovat telefonní hovory
- ▶ Důležité je, že je schopen do analýzy pojmout i kontext hovoru, a tím výrazně zpřesnit výsledky
- ▶ F-score získané použitím kombinace obsahových a kontextových rysů se blíží F-score lidských anotátorů

Zdroje

- ▶ http://en.wikipedia.org/wiki/F1_score
- ▶ http://en.wikipedia.org/wiki/Precision_and_recall
- ▶ BANERJEE, Satanjeev; RUDNICKY, Alexander I. An extractive-summarization baseline for the automatic detection of noteworthy utterances in multi-party human-human dialog. In: *Spoken Language Technology Workshop, 2008. SLT 2008. IEEE.* IEEE, 2008. p. 177-180.
- ▶ http://repository.cmu.edu/cgi/viewcontent.cgi?article=2352&context=comps_ci