

Lexical Normalization for Dutch Social Media Texts

Lexical Normalization

nee ! :-D kzal nog es vriendelijk doen lol
 nee ! :-D ik zal nog eens vriendelijk doen lol

tgaat goed , vdg rustig aan .
 Het gaat goed , vandaag rustig aan .

social ppl r annoying
 social people are annoying

aaah buenoo esqe digo pa qe madrugara este jajaja
 ah bueno es que digo para qué madrugará este jajaja

nekomu je sarkazm detektor crknu
 nekomu je sarkazem detektor crknil

Performance Per Corpus

Is normalization for Dutch more difficult?

MoNoise

Rob van der Goot @robvander · Jul 30
 @GJ Huidge parsers scoren maaar 60% op tweets! #fail

Generation

Orig. Word	LookupList
scoren #fail	alst hahahaha
scoren #fail	als het haha

word2vec	Aspell
mss dinnetje	grapjee feliciteren
mssn dinnie	grapje feliciteren
missch vriendinnetje	grapjes flecteren
misschien dinnetjes	greetje fluctueren

Split	word.*
kheb datis	ech waarsch
k heb dat is	echt waarschijnlijk
	echo waarschuw
	echeltje waarschuwt

Ranking

Features:

- isOrig
- Word2vec dist.
- Aspell dist.
- isSplit
- word.*
- N-grams Wiki
- N-grams Twitter
- dict
- length
- containsAlpha
- origFeats

Random Forest Classifier

Rob van der Goot and Gertjan van Noord. MoNoise: Modeling Noise Using a Modular Normalization System. In CLIN Journal 2017

New Dataset

- Annotate capitalization consistently
- Annotate tokenization in a separate layer
- Do not include phrasal abbreviations ('lol' → 'laughing out loud')
- Make publicly available
- No Flemish → Dutch
- Annotate POS dev/test data
- Annotate categories?^a
- Annotate Universal Dependencies?

Rob Van der Goot, Rik Van Noord, and Gertjan Van Noord. A taxonomy for in-depth evaluation of normalization for user generated content. In Proceedings of LREC 2018

Beneficial for Parsing?

new pix comming tomorroe

Rob Van der Goot and Gertjan Van Noord. Parser Adaptation for Social Media by Integrating Normalization. In Proceedings of ACL 2017

Rob Van der Goot and Gertjan Van Noord. Modeling Input Uncertainty in A Neural Network Dependency Parser. In Proceedings of EMNLP 2018 Brussels

Try it!

www.let.rug.nl/rob/monoise