

Sentimentanalyse for norsk tekst

SANT @ NRK

Erik Velldal og Lilja Øvrelid

Institutt for informatikk, Universitetet i Oslo

29. november 2017





- ▶ Språkteknologigruppa, Institutt for Informatikk, UiO.
- ▶ 12 ansatte (4 faste).
- ▶ Lingvistikk + maskinlæring.
- ▶ Kjært barn: language engineering, computational linguistics, language technology, natural language processing / NLP.
- ▶ Foreløpig mye som mangler for norsk,
- ▶ inkludert ressurser for sentimentanalyse (SA).

Hva er SA?




- ▶ Aka *opinion mining*.
- ▶ Identifisere subjektive meninger som uttrykkes i tekst.
- ▶ Forskjellig granularitet:
- ▶ Positiv / negativ?
- ▶ Ulike klasser av følelser.
- ▶ Dokument-nivå vs setnings- og frase-nivå.
- ▶ Eksempler på bruksområder: mediaovervåking, markedsanalyse, 'produktsporing', opinion- og trendanalyse, og mye mer.

- ▶ Sentiment Analysis for Norwegian Text
- ▶ Samarbeid mellom LTG/IFI, Schibsted, Aller og NRK.
- ▶ Har søkt NFR/IKTPLUSS om en PhD + en postdok.
- ▶ Foreløpig fått invitget midler til en halvårig pilot.

Hva vi skal snakke om

- ▶ Hva er målet?
- ▶ Hva har vi gjort i **fase 1?** (jun.–nov.)
- ▶ Hva er planen videre; **fase 2?** (2018 – 2021)



- ▶ **Veiledet maskinlæring:** krever at vi har **eksempler** å lære fra.
- ▶ Vi må altså **manuelt annotere** tekst for å lage treningsdata.
- ▶ Noe av det vi har søkt om NFR-midler for.

Terningkast

- ▶ I det halvårige prøveprosjektet (fase 1):
- ▶ Begynner med mer grovkornet SA; **dokument-nivå**.
- ▶ Ide: **terningkast** for anmeldelser som eksempler.
- ▶ Representerer grad av positivitet/negativitet.
- ▶ Tren modeller til å predikere terningkast for en ny tekst.



- ▶ To vit.ass.'er: Eivind og Cathrine.
- ▶ Norwegian Review Corpus
- ▶ NoReC.
- ▶ <https://github.com/ltgoslo/norec>
- ▶ Publikasjon sendt til fagfellevurdering.
- ▶ I gang med å trene baseline-modeller for å predikere terningkast.

Source	# Reviews
VG	11,888
Dagbladet	5,305
Stavanger Aftenblad	5,146
P3.no	5,017
DinSide.no	2,944
Fædrelandsvennen	2,296
Bergens Tidene	1,675
Aftenposten	923
Total	35,194

- ▶ **Hente ut anmeldelser**
 - ▶ Sortere ut feil (manglende terningkast, duplisert tekst, osv).
 - ▶ Splitte samleankmeldelser
- ▶ Identifisere og normalisere **meta-informasjon**:
 - ▶ Terningkast, url, dato, kategori, osv
- ▶ Normalisere mark-up; felles **mellomformat** i HTML
- ▶ **Hente ut relevant tekst**
- ▶ **Preprosessering** av tekst:
 - ▶ Språkgjenkjenning (med *langid.py*): BM / NN.
 - ▶ Setningssplitting, tokenisering, lemmatisering, PoS-tagging, dependensparsing (med UDPipe), representert i formatet CoNLL-U.
 - ▶ Inkluderer også scripts for å generere versjon i rå tekst.

Anmeldelser per kategori



Category	# Reviews
Screen	13,085
Music	12,410
Literature	3,530
Products	3,120
Games	1,765
Restaurants	534
Stage	530
Sports	118
Misc	102
Total	35,194


1	Men	men	CCONJ	3	cc
2	ikke	ikke	ADV	3	advmod
3	forvent	forvente	VERB	0	root
4	god	god	ADJ	5	amod
5	brukervennlighet	brukervennlighet	NOUN	3	obj
6	,	\$,	PUNCT	3	punct
7	det	det	PRON	8	obj
8	får	få	VERB	3	conj
9	du	du	PRON	8	nsubj
10	nemlig	nemlig	ADV	8	advmod
11	ikke	ikke	ADV	8	advmod
12	.	\$.	PUNCT	3	punct

metadata.json




```
"705084": {  
    "title": "F-A-N-T-A-S-T-I-S-K",  
    "authors": [ "Leif Tore Lindø" ],  
    "rating": 6,  
    "category": "music",  
    "day": 7,  
    "month": 12,  
    "year": 2015,  
    "excerpt": "Det var for sånne konserter Gud fant opp sekseren.",  
    "id": 705084,  
    "language": "nb",  
    "source": "sa",  
    "source-category": "konsert",  
    "source-id": 203726,  
    "source-tags": [ "Anmeldelse", "Musikk", "Konsertanmeldelse" ],  
    "split": "train",  
    "tags": [ "concert" ],  
    "url": "http://www.aftenbladet.no/article/sa-203726b"  
},
```


Anmeldelser per terningkast




Terningkast per kilde



Terningkast per kategori



Terningkast per kategori: P3 alene



- ▶ 5017 P3-anmeldelser over 3 kategorier (screen=2294, music=2216, games=507)
- ▶ Snitt er for kun de tre P3-kategoriene men for alle kilder.

- ▶ **Inn:** dokument / tekst
- ▶ **Ut:** tall 1–6
- ▶ **Strategier**
 - ▶ Klassifikasjon
 - ▶ Regresjon
- ▶ **Evaluering**
 - ▶ Accuracy
 - ▶ R^2 score (1 er best, kan være negativ).
- ▶ **Dokumentrepresentasjon**
 - ▶ doc2vec (100 dim.)
 - ▶ Bag-of-words (BoW)
- ▶ **Verktøy:** Gensim (for doc2vec), Scikit-learn til resten.
- ▶ <https://github.com/ltgoslo/norec-baselines>

Model	Acc	R^2
BoW+classification	0.50	0.18
BoW+regression	0.46	0.29
doc2vec+classification	0.44	0.07
doc2vec+regression	0.40	0.14
Majority-class	0.37	-0.6
Random choice	0.17	-2.40

- Merk at dette er ment som en **bunnlinje** for videre eksperimenter.

- ▶ Leverte **rapport** for fase 1 til NFR 10. nov.
- ▶ **Presentasjon for NFR** 4. des.
- ▶ Så får vi vite innen jul om vi får finansiering for fase 2
- ▶ = 1 postdoc + 1 PhD.
- ▶ **Plan for fase 2:**
 - ▶ SA-leksikon
 - ▶ Mer finkornet annotasjon
 - ▶ Dyp læring for både setnings-nivå (LSTM) og dokument-nivå (CNN).