

# Applying automatically parsed corpora to the study of language variation

Jelke Bloem, Arjen Versloot, Fred Weerman

# Language variation

- Grammars often contain optionality
  - Same meaning, different form
- Grammatical variation phenomena are multivariate in nature
  - Rules can only outline the variation
- On what basis do we choose between the options?

# Dative alternation

- A word order variation in English:
  1. He gave [**his friend**] [**the ticket**]
  2. He gave [**the ticket**] to [**his friend**]
- No simple rule on when to use one or the other
- Probabilistically modeled using 14 variables
  - i.e. animacy of recipient, pronominality of recipient, given-ness (Bresnan et al., 2007)
- Switchboard corpus (3M words, 2360 instances)

# Automatically parsed corpora

- Fewer annotation resources required
  - More data
- Exact definition of construction
- Flexible
- Contains errors ('random' or systematic)
- Annotation may be a limiting factor

```
(@root="word" or @root="heb" or  
@root="ben") and  
(parent::node[( @cat="rel" or  
@cat="ssub" or @cat="oti" or  
@cat="cp" or @cat="svan" or  
@cat="ahi") ] or  
parent::node[@rel="vc" and  
parent::node[( @cat="smain" or  
@cat="sv1")]] or  
parent::node[@cat="inf" and
```

# Case study: Verbal clusters

## ■ A word order variation in Dutch:


1. ik denk dat ik het begrepen heb  
I think that I it understood have
2. ik denk dat ik het heb begrepen  
I think that I it have understood

## ■ Frisian, German: Only green order

understood have | have understood

# Explaining the variation (Coussé et al, 2008)

- (Regional) linguistic background
  - Single speaker variation?
- Mode of communication
- **Semantic factor**
- Discourse factor
  - Priming by previous syntactic structures



## Corpus study (de Sutter, 2009)

- “De Standaard” part of CONDIV corpus (3.2M words)
- Controlled for regional, register and diachronic variation
- Strict cluster criteria:
  - Only ‘hebben’ (*to have*) ‘zijn’ and ‘worden’ (*to be*) auxiliaries
  - Only complement clauses with ‘dat’ (*that*)
- Multivariate logistic regression model (10 variables)
- 2.390 manually verified clusters, 66.99% red order

# Large-scale analysis

- Too limited definition of ‘verbal cluster’ by de Sutter (2009)
  - Unnecessary in a multivariate model
- Can be scaled up using large, automatically annotated corpora
  - Larger sample size
  - Coverage of more cluster types



# Automatically annotated corpus

In 1832 ontdekte Michael Faraday dat in een zoutoplossing stoffen **ontleed worden** als er een elektrische stroom doorheen **gestuurd wordt** en dat die ontleding afhankelijk is van de stroom .

Op de terechtstelling van zijn moeder in 1587 reageerde hij in het geheel niet , vermoedelijk omdat hij daardoor als afstammeling van Hendrik VII het recht op opvolging van de Engelse koningin Elizabeth **kon behouden** .

Enkele weken na de bijzetting in de Nieuwe Kerk verscheen een advertentie in de dagbladen waarin bekend **gemaakt werd** dat Juliana afzag van de erfenis van haar vader .

Na hertellen van de stemmen bleek dat Chen inderdaad de verkiezingen **gewonnen had** , zij het met een miniem verschil .

Toen tsaar Nicolaas II van Rusland , een neef van George via zijn moeder , Koningin Alexandra ( de moeder van Nicolaas II was tsarina Maria Fjodorovna , de zuster van Koningin Alexandra ) omwille van Russische Revolutie in 1917 **onttroond werd**

Een boekhandel is een bedrijf waar men boeken **kan kopen** .

Echter wordt er bij een hogere intensiteit absoluut gezien meer vet verbrand ook al is de verhouding vet-koolhydraten dat **gebruikt wordt** minder .

Omdat dit onderzoek niet direct **gekoppeld is** aan bruikbare toepassingen , wordt vaak gedacht dat het maatschappelijk niet relevant is .

Omdat invloedsmijnen **kunnen reageren** op verstoringen in het aardmagnetisch veld ( magnetische mijnen ) zijn de mijnenvegers zoveel mogelijk van de eerder genoemde a-magnetische materialen gebouwd .

Unusual come however results have been block do research find 2002 published as word Data on can either now

- Wikipedia part of “Lassy Large” corpus
- 145M tokens, 411.623 clusters, 71.65% **red** order
- Syntactic annotation lets us formally define various types of clusters using DACT (X-path queries)
- Dependency trees (+ features)
- May contain errors: 88.38% parser accuracy

# Variables of the original study (de Sutter, 2009)

- Accented syllable distance     ... naar hun **au-to** **is ge-lo-pen** n=4
- Separable main verb         ... heeft **afgewassen** (*has washed up*)
- Constituent after cluster    ... heeft **gezien** **dat het gebeurde**
- Length of the middle field    ... dat [hij naar hun auto] **is gelopen** n=4
- Type of auxiliary             copular-*zijn*/passive-*zijn*/time/*worden*
- Syntactic persistence        ...**afgewassen heeft** en (...) **weggelopen is**
- Main verb frequency        ... naar hun auto **is gelopen**
- Pre-verbal constituent: Informativity and inference

# Variables in Lassy Large corpus


## ~~Accented syllable distance~~

- Separable main verb
- Constituent after cluster
- Length of the middle field
- Type of auxiliary

## ~~Syntactic persistence~~

- Main verb frequency
- Pre-verbal constituent: Informativity and inference

understood have | have understood



# Additional cluster types

## ■ Main clause

- Rechters kunnen in principe niet worden ontslagen.  
Judges can in principle not be dismissed.

## ■ Infinitival clusters

- ... waardoor de reclame weer op tv te zien was  
... thus the ad again on tv to see was

## ■ Aux/mod *worden hebben zijn / kunnen zullen willen laten mogen moeten blijven hoeven*

- ... dat iedereen hem ongestraft doden mocht  
... that everyone him with impunity kill **may**

# Model comparison

Feature	De Sutter (2009)	This study
<b>Separable main verb</b>		
No	1.00	1.00
Yes	3.87	4.92
<b>Constituent after cluster</b>		
None	1.00	1.00
Complement of main verb	0.47	-
Complement of preverbal noun	1.21	-
Comp. or adjunct of main verb	-	51.44
Comp. or adjunct of preverbal N.	-	0.44
<b>Length of middle field</b>		
0-2 words	1.00	1.00
3-5 words	2.03	2.42
6-8 words	2.29	3.23
9-11 words	2.29	3.34
12-14 words	2.57	3.33
>14 words	1.98	3.15

Feature	De Sutter (2009)	This study
<b>Type of auxiliary</b>		
Copular <i>zijn</i>	1.00	-
Auxiliary of time	18.30	-
Passive <i>zijn</i>	7.82	-
<i>zijn</i>	-	1.00
<i>worden</i>	11.73	1.19
<i>hebben</i>	-	2.19
modal	-	132.42
<b>Main verb frequency</b>	(from CELEX)	(Lassy Large)
$\beta$	2.44 <sup>E-06</sup>	3.73 <sup>E-08</sup>
Std. Error	7.74 <sup>E-07**</sup>	1.05 <sup>E-08***</sup>
<b>Inherence</b>		
No	1.00	1.00
Yes	2.26	2.10
<b>Information value</b>		
Low	1.00	1.00
Intermediate	1.41	1.21
High	1.94	1.11

The values are **odds ratios**, measuring effect size

OR=2.00 means: if this feature is present instead of the baseline, red order is 2 times more probable

understood have | have understood

| Applying automatically parsed corpora to  
the study of language variation

# Model predictive power

Concordance index c

Model	C-index	Nr. of features	Data
De Sutter (2009)	0.8030	10	AUX/Sub only
Full model	0.8635	9	All clusters
Small model	0.7649	7	AUX/Sub only

Full model intercept = 0.6035

- \* Values actually not directly comparable
- \* c=0.5 is chance level, but the gold standard is not 1...

# Stepwise regression

- Minimize Akaike Information Criterion (AIC)
- Indicates relative importance of the features

Feature	AIC
0. <none>	490828
1. Type of auxiliary	413913
2. Constituent after cluster	349852
3. Finiteness	338758
4. Length middle field	332781
5. Clause type	325857
6. Frequency main verb	324371
7. Inherence	323201
8. Separable verb	322519
9. Information value	322000



# Replication summary

- Effect sizes largely similar to previous work
- Variables hold within a bigger model
- Cluster order is more or less affected by all variables
- Some variables could not be measured

# Additional features

Feature	De Sutter (2009)	This study
<b>Infinitival clusters</b>		
No	-	1.00
Yes	-	0.03
<b>Clause type</b>		
Subordinate clause	-	1.00
Main clause	-	0.34

- Red pure-infinitival cluster (but only with *hoeven* ‘need’)

... zodat de machinist niet in de locomotief zelf **hoeft te zijn**

... so that the operator not in the locomotive itself need to be

- Red main clause

Rechters kunnen in principe niet **worden ontslagen**.

Judges can in principle not be dismissed.

# Dutch Europarl corpus as part of Lassy Large corpus

- European Parliament proceedings texts
- 138.304 clusters, 86.78% red order!
- Variable effects largely similar

Feature	Europarl model	Wiki model
<i>zijn</i>	1.00	1.00
<i>worden (to be)</i>	1.62	1.19
<i>hebben (to have)</i>	2.57	2.19
modal	323.46	132.42
None	1.00	1.00
Comp. or adjunct of main verb	31.22	51.44
Comp. or adjunct of preverbal noun	0.46	0.44

# Semantic factor: Collostructional analysis

(Stefanowitsch & Gries, 2003)

- Relationship between a construction (red/green) and the words that fill its slots

... *that I it VERB have*

... dat ik het **begrepen** heb

... dat ik het **gezien** heb

... dat ik het **gehoord** heb

... dat ik het **geschopt** heb

... *that I it have VERB*

... dat ik het **heb gemaakt**

... dat ik het **heb bedacht**

... dat ik het **heb gehoord**

... dat ik het **heb beschreven**

- Calculate most strongly associated **collexemes**

- Fisher's Exact Test or other association measure

# Collostructional analysis

Auxiliary, subordinate clause clusters only, cutoff=15

## Main verbs

			Odds ratio - Red - Green
1	---	afkondigen (proclaim)	inf    29    0
2	---	neerzetten (put down)	inf    24    0
3	---	uitmaken (make out)	inf    21    0
4	---	aanhouden (keep on)	inf    21    0
5	---	optekenen (draw up)	inf    19    0
6	---	overgeven (surrender / throw up)	inf    18    0
7	---	aanschaffen (purchase)	inf    17    0
8	---	uitschrijven (unsubscribe)	inf    16    0
9	---	plaatsvinden (take place)	33.34 182    3
10	---	indienen (send in)	22.95 42    1

Pattern?

# Collostructional analysis

Auxiliary, subordinate clause clusters only, cutoff=100, no particle verbs

Main verbs -----	Odds ratio - Red - Green
1 -- verplichten (to oblige) ST	20.44 13 182
2 -- zien (to see) ST	17.36 148 1751
3 -- danken (to thank)	14.02 20 288
4 -- vinden (to find) ST	13.96 87 830
5 -- herkennen (to recognize) ST	7.08 20 97
6 -- relateren (to relate) ST	6.70 22 101
7 -- huwen (to marry)	5.94 28 11
8 -- besmetten (to infect)	4.87 24 80
9 -- wijten (to blame)	4.33 32 95
10 -- bestemmen (to assign)	4.28 61 179

Main verbs -----	Odds ratio - Red - Green
1 -- staan (to stand)	7.81 583 51
2 -- gaan (to go)	6.74 751 76
3 -- hebben (to have)	6.40 882 94
4 -- zitten (to sit)	5.70 200 24
5 -- zijn (to be)	5.50 2583 317
6 -- waarnemen (to percieve)	5.32 233 30
7 -- ondergaan (to undergo)	5.11 179 24
8 -- gooien (to throw)	5.06 133 18
9 -- blijven (to stay)	4.68 748 109
10 -- geworden (to become)	4.42 2509 383

Patterns: Semantic classes? Stative/dynamic verbs?

# Conclusions

- Replicated and extended a linguistic study using an automatically annotated corpus
- Comprehensive model of Dutch verbal clusters
- Automatic approach is easily extended
  - Study regional/register/diachronic variation
- de Sutter (2009)'s variables generalize to another domain
- Larger sample allows more detailed analysis

# Discussion

- Extend further:
  - Corpus of Spoken Dutch
  - A corpus with author/region/time metadata
  - Larger verbal clusters
- Semantics: more can be done
- Automatically annotated corpora for:
  - Dative alternation
  - ‘that’-optionality
  - Any other probabilistic phenomenon
- New types of corpora as NLP tools get better

understood have | have understood

# References

- J. Bresnan, A. Cueni, T. Nikitina, R. H. Baayen, et al. Predicting the dative alternation. *Cognitive foundations of interpretation*, pages 69–94, 2007.
- Coussé, E., Arfs, M., & De Sutter, G. (2008). Variabele werkwoordsvolgorde in de Nederlandse werkwoordelijke eindgroep. Een taalgebruiksgebaseerd perspectief op de synchronie en diachronie van de zgn. rode en groene woordvolgorde. In G. Rawoens (Ed.), *Taal aan den lijve. Het gebruik van corpora in taalkundig onderzoek en taalonderwijs* (pp. 29–47). Gent: Academia Press.
- Stefanowitsch, A., & Gries, S. T. (2003). Collostructions: Investigating the interaction of words and constructions. *International journal of corpus linguistics*, 8(2), 209-243.
- Sutter, G. D. (2009). Towards a multivariate model of grammar: The case of word order variation in Dutch clause final verb clusters. *Describing and modeling variation in grammar*, 204, 225-254.