

Automatic Induction of Semantic Classes for German Verbs

Sabine Schulte im Walde
Institut für Maschinelle Sprachverarbeitung (IMS)
Universität Stuttgart

DGfS Jahrestagung 2003
AG 6 : *Semantisches Wissen im Lexikon*
Universität München

Goals

- Automatic acquisition of high-quality and large-scale lexical resource for NLP applications: German semantic verb classes
- Theoretical investigation of relationship between verb behaviour and meaning components
- Development of clustering methodology suitable for the demands of natural language

Overview

1. Theoretical aspects of verb classes
2. German verbs and verb classes
3. Clustering methodology
4. Corpus-based statistical lexical acquisition → verb description
5. Clustering experiments and results
6. NLP applications of lexical verb class information

Verb Classes

verb meaning components \leftrightarrow *verb behaviour*

To a certain extent, the lexical meaning components of a verb determine its behaviour, particularly with respect to the choice of its arguments.

Existing Verb Classes

- German (Schumacher 1986; Ballmer and Brennenstuhl 1986)
- English (Levin 1993)
- French (Saint-Dizier 1996)
- Spanish (Vázquez et al. 2000)

German Verb Classes: Constitution

- 168 German verbs → 43 semantic classes
- Class size: 2-7 verbs (\varnothing 3.9 verbs per class)
- Ambiguity: 8 verbs with 2 senses
- High and low frequency verbs: $8 \leq \text{freq} \leq 71,604$
- Basis: semantic intuition
- Relation to Levin (1993), consistency with Schumacher (1986)

German Semantic Verb Classes (1)

1. *Aspect* : anfangen, aufhören, beenden, beginnen, enden
2. *Propositional Attitude* : ahnen, denken, glauben, vermuten, wissen
3. *Desire*
 - (a) *Wish* : erhoffen, wollen, wünschen
 - (b) *Need* : bedürfen, benötigen, brauchen
4. *Transfer of Possession (Obtaining)* : bekommen, erhalten, erlangen, kriegen
5. *Transfer of Possession (Giving)*
 - (a) *Gift* : geben, leihen, schenken, spenden, stiften, vermachen, überschreiben
 - (b) *Supply* : bringen, liefern, schicken, vermitteln₁, zustellen
6. *Manner of Motion*
 - (a) *Manner of Locomotion* : gehen, klettern, kriechen, laufen, rennen, schleichen, wandern
 - (b) *Rotation* : drehen, rotieren
 - (c) *Rush* : eilen, hasten
 - (d) *Means* : fahren, fliegen, rudern, segeln
 - (e) *Flotation* : fließen, gleiten, treiben

German Semantic Verb Classes (2)

7. *Emotion*
 - (a) *Origin* : ärgern, freuen
 - (b) *Expression* : heulen₁, lachen₁, weinen
 - (c) *Objection* : ängstigen, ekeln, fürchten, scheuen
8. *Manner of Look on the Face* : gähnen, grinsen, lachen₂, lächeln, starren
9. *Perception* : empfinden, erfahren₁, fühlen, hören, riechen, sehen, wahrnehmen
10. *Manner of Articulation* : flüstern, rufen, schreien
11. *Moaning* : heulen₂, jammern, klagen, lamentieren
12. *Communication* : kommunizieren, korrespondieren, reden, sprechen, verhandeln
13. *Statement*
 - (a) *Announcement* : ankündigen, bekanntgeben, eröffnen, verkünden
 - (b) *Constitution* : anordnen, bestimmen, festlegen
 - (c) *Promise* : versichern, versprechen, zusagen
14. *Observation* : bemerken, erkennen, erfahren₂, feststellen, realisieren, registrieren
15. *Description* : beschreiben, charakterisieren, darstellen₁, interpretieren
16. *Presentation* : darstellen₂, demonstrieren, präsentieren, veranschaulichen, vorführen
17. *Speculation* : grübeln, nachdenken, phantasieren, spekulieren

German Semantic Verb Classes (3)

18. *Insistence* : beharren, bestehen₁, insistieren, pochen
19. *Teaching* : beibringen, lehren, unterrichten, vermitteln₂
20. *Position*
 - (a) *Bring into Position* : legen, setzen, stellen
 - (b) *Be in Position* : liegen, sitzen, stehen
21. *Production* : bilden, erzeugen, herstellen, hervorbringen, produzieren
22. *Renovation* : dekorieren, erneuern, renovieren, reparieren
23. *Support* : dienen, folgen₁, helfen, unterstützen
24. *Quantum Change* : erhöhen, erniedrigen, senken, steigern, vergrößern, verkleinern
25. *Opening* : öffnen, schließen₁
26. *Existence* : bestehen₂, existieren, leben
27. *Consumption* : essen, konsumieren, lesen, saufen, trinken
28. *Elimination* : eliminieren, entfernen, exekutieren, töten, vernichten
29. *Basis* : basieren, beruhen, gründen, stützen
30. *Inference* : folgern, schließen₂
31. *Result* : ergeben, erwachsen, folgen₂, resultieren
32. *Weather* : blitzen, donnern, dämmern, nieseln, regnen, schneien

Verb Class Scene Description: Aspect Verbs

Verbs: *anfangen, aufhören, beenden, beginnen, enden*

Scene : [*E* An event] begins or ends, either internally caused or externally caused by [*I* an initiator]. The event may be specified with respect to [*T* tempus], [*L* locus], [*X* an experiencer], or [*R* a result].

Frame Roles: Initiator, Event

Modification Roles: Temporal, Local, eXperiencer, Result

Levin class: 55.1 (*Aspectual Verbs → Begin Verbs*)

Schumacher class: 2.1 (*Verben der speziellen Existenz*
→ *Verben der Existenzsituierung*)
beenden is not classified.

Verb Class Frame Variants: Aspect Verbs (1)

Frame	Participating Verbs & Corpus Examples
n_E	+ anfangen, aufhören, beginnen / + _{adv} enden / \neg beenden Nun aber muß [_E der Dialog] anfangen bevor [_E der Golfkrieg] angefangen hatte damit [_E die Kämpfe] aufhören . Erst muß [_E das Morden] aufhören . [_E Der Gottesdienst] beginnt . [_E Das Schuljahr] beginnt [_T im Februar]. [_X Für die Flüchtlinge] beginnt nun [_E ein Wettlauf gegen die Zeit]. [_E Sein kurzes Zwischenspiel] bei der Wehrmacht endete ... [_R glimpflich]. [_E Die Ferien] enden [_R mit einem großen Fest]. [_E Druckkunst] ... endet [_R beim guten Buch]. [_E Die Partie] endete [_R 0:1]. [_L An einem Baum] endete in Höchst [_E die Flucht] ... [_E Der Informationstag] ... endet [_T um 14 Uhr].

Verb Class Frame Variants: Aspect Verbs (2)

Frame	Participating Verbs & Corpus Examples
n_I	<p>+ anfangen, aufhören / \neg beenden, beginnen, enden</p> <p>[_I Die Hauptstadt] muß anfangen. ... daß [_I er] [_T pünktlich] anfing. Jetzt können [_I wir] nicht einfach aufhören. Vielleicht sollte [_I ich] aufhören und noch studieren.</p>
$n_I a_E$	<p>+ anfangen, beenden, beginnen / \neg aufhören, enden</p> <p>Nachdem [_I wir] [_E die Sache] angefangen haben, ... [_I er] versucht, [_E ein neues Leben] anzufangen. [_I Die Polizei] beendete [_E die Gewalttätigkeiten]. [_T Nach dem Abi] beginnt [_I Jens] [_L in Frankfurt] [_E seine Lehre] ...</p>
$n_I a_E [P]$	<p>+ anfangen, beenden, beginnen / \neg aufhören, enden</p> <p>Wenn [_E die Arbeiten] [_T vor dem Bescheid] angefangen werden ... Während [_X für Senna] [_E das Rennen] beendet war ... [_E Das Durcheinander, das es zu CDU-Zeiten gegeben habe,] sei beendet worden. ... ehe [_E eine militärische Aktion] begonnen wird ...</p>

Verb Class Frame Variants: Aspect Verbs (3)

Frame	Participating Verbs & Corpus Examples
$n_I i_E$	<p>+ anfangen, aufhören, beginnen / \neg beenden, enden</p> <p>[_I] Ich habe angefangen, [_E Hemden zu schneidern]. [_I] Die Bahn will [_T 1994] anfangen [_E zu bauen]. ... daß [_I der Alkoholiker] aufhört [_E zu trinken]. ... daß [_I die Säuglinge] einfach aufhören [_E zu atmen]. In dieser Stimmung begannen [_I Männer] [_E auf den Straßen den Tango zu tanzen] ... [_I Tausende von Pinguinen] beginnen [_E dort zu brüten].</p>
$n_I p_E:mit_{Dat}$	<p>+ anfangen, aufhören, beginnen / \neg beenden, enden</p> <p>Erst als [_I der versammelte Hofstaat] [_E mit Klatschen] anfing, Aber [_I wir] müssen endlich [_E damit] anfangen. [_I Der Athlet] ... kann ... [_E mit seinem Sport] aufhören. ... müßten noch [_I viel mehr Frauen] [_E mit ihrer Arbeit] aufhören ... Schließlich zog [_I er] einen Trennstrich, begann [_E mit dem Selbstentzug] ... [_I Man] beginne [_E mit eher katharsischen Werken].</p>
$n_I p_E:mit_{Dat} [P]$	<p>+anfangen, aufhören, beginnen / \neg beenden, enden</p> <p>Und [_E mit den Umbauarbeiten] könnte angefangen werden. [_E Mit diesem ungerechten Krieg] muß sofort aufgehört werden. [_T Vorher] dürfe [_E mit der Auflösung der Szene] nicht begonnen werden.</p>

Clustering Methodology

1. Statistical acquisition of lexical verb information
2. Automatic verb clustering by standard technique k-Means
3. Clustering evaluation against manual verb classification

Lexical Acquisition Framework

- Lexicalised probabilistic context-free grammar (Carroll/Rooth 1998)
- Unsupervised training by the *EM-Algorithm* (Baum 1972)
- Robust statistical parser **LoPar** (Schmid 2000)
- 35 million words of German newspaper corpora
- Lexicalised grammar rules and lexical choice parameters
- Corpus-based statistical lexical acquisition

Corpus-Based Statistical Lexical Acquisition

- D1** purely syntactic definition of subcategorisation
- D2** syntactico-semantic definition of subcategorisation
with prepositional preferences
- D3** syntactico-semantic definition of subcategorisation
with prepositional and selectional preferences

Subcategorisation Frame Elements

- n** noun phrase: NP_{Nom}
- a** noun phrase: NP_{Akk}
- d** noun phrase: NP_{Dat}
- r** reflexive pronoun
- p** prepositional phrase
- x** expletive es
- i** subordinated non-finite clause
- s-2** subordinated finite verb second clause
- s-dass** subordinated finite *dass*-clause
- s-ob** subordinated finite *ob*-clause
- s-w** indirect *wh*-questions
- k** copula constructions

Examples: **nad**, **np:auf_{Akk}**, **nai**

Lexical Verb Information (1): Subcategorisation Frame Definition

Frame	Freq	Prob
ns-dass	1,929	0.27945
ns-2	1,888	0.27358
np	687	0.09951
n	608	0.08811
na	555	0.08046
ni	346	0.05015
nd	234	0.03392
nad	160	0.02325
nds-2	70	0.01011

probability distribution for *glauben* ‘to think/believe’
(probability values >1%)

Lexical Verb Information (2): Subcategorisation Frame Definition + PPs

Refined Frame	Freq	Prob
np:über_{Akk}	480	0.11981
np:von_{Dat}	463	0.11568
np:mit_{Dat}	280	0.06983
np:in_{Dat}	81	0.02031

refined **np** probability distribution for *reden* ‘to talk’
with total joint probability $p(reden, np) = 0.35820$
(probability values >1%)

Selectional Preferences: Nominal Level

Noun		Freq
Ziel	'goal'	86.30
Strategie	'strategy'	27.27
Politik	'policy'	25.30
Interesse	'interest'	21.50
Konzept	'concept'	16.84
Entwicklung	'development'	15.70
Kurs	'direction'	13.96
Spiel	'game'	12.26
Plan	'plan'	10.99
Spur	'trace'	10.91
Programm	'program'	8.96
Weg	'way'	8.70

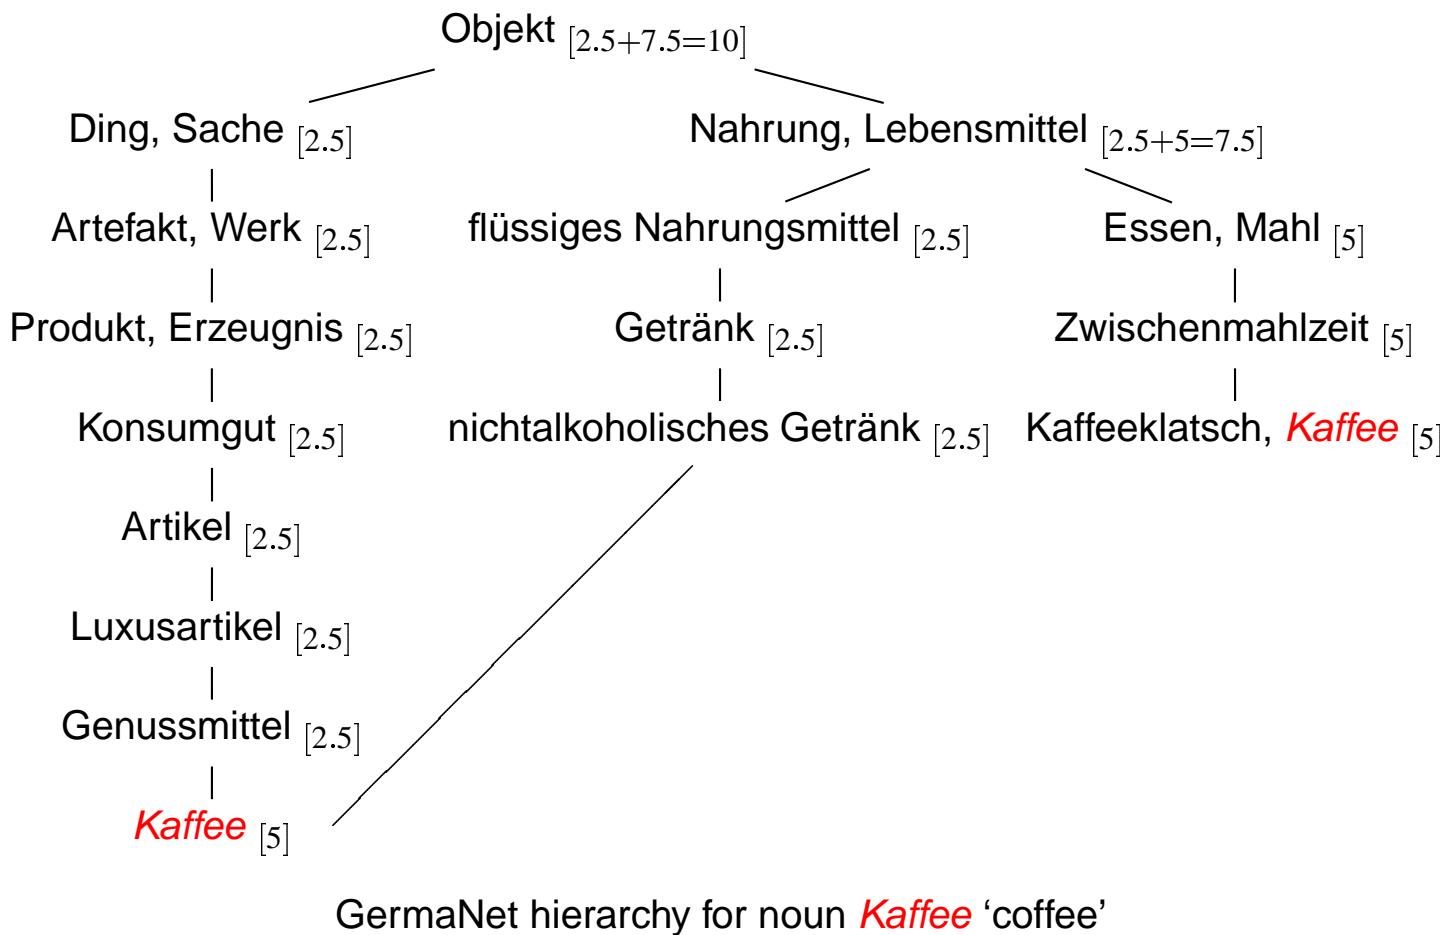
Nominal arguments for *verfolgen* 'to follow' in **na**

Selectional Preferences: Nominal Level

Noun		Freq
Uhr	'o'clock'	85.38
Prozeß	'process'	77.14
Kampf	'fight'	69.77
Verhandlung	'negotiation'	65.51
Krieg	'war'	64.39
Tag	'day'	52.12
Zeit	'time'	51.94
Arbeit	'work'	46.86
Geschichte	'history'	46.10
Karriere	'career'	42.49
Spiel	'game'	37.79
Diskussion	'discussion'	31.25

Nominal arguments for *beginnen* 'to begin' in n

Selectional Preferences: GermaNet Nodes (1)



Selectional Preferences: GermaNet Nodes (2)

Synset	Freq
Objekt	'object'
Nahrung, Lebensmittel, Esswaren, Speisen	'food'
festes Nahrungsmittel	'solid food'
Ding, Sache, Gegenstand, Gebilde	'thing'
Lebewesen, Kreatur, Wesen	'creature'
natürliches Lebewesen, Organismus	'organism'
Fleischware, Fleisch	'meat'
höheres Lebewesen	'higher creature'
Tier	'animal'
Backware	'pastry'
Gericht, Speise, Essen	'food'
Grünzeug	'vegetables' (coll.)

Selectional preferences for *essen* 'to eat' in na

GermaNet Top Level Nodes

Lebewesen	'creature'
Sache	'thing'
Besitz	'property'
Substanz	'substance'
Nahrung	'food'
Mittel	'means'
Situation	'situation'
Zustand	'state'
Struktur	'structure'
Physis	'body'
Zeit	'time'
Ort	'space'
Attribut	'attribute'
Kognitives Objekt	'cognitive object'
Kognitiver Prozess	'cognitive process'

Selectional Preferences: GermaNet Top Level Nodes

Synset	Freq	Prob
Situation	140.99	0.244
Kognitives Objekt	109.89	0.191
Zustand	81.35	0.141
Sache	61.30	0.106
Attribut	52.69	0.091
Lebewesen	46.56	0.081
Ort	45.96	0.080
Struktur	14.25	0.025
Kognitiver Prozess	11.77	0.020
Zeit	4.58	0.008
Besitz	2.86	0.005
Substanz	2.08	0.004
Nahrung	2.00	0.003
Physis	0.50	0.001

GermaNet arguments for *verfolgen* ‘to follow’ in na

Selectional Preferences: GermaNet Top Level Nodes

Synset	Freq	Prob
Situation	1,102.26	0.425
Zustand	301.82	0.116
Zeit	256.64	0.099
Sache	222.13	0.086
Kognitives Objekt	148.12	0.057
Kognitiver Prozess	139.55	0.054
Ort	107.68	0.041
Attribut	101.47	0.039
Struktur	87.08	0.034
Lebewesen	81.34	0.031
Besitz	36.77	0.014
Physis	4.18	0.002
Substanz	3.70	0.001
Nahrung	3.29	0.001

GermaNet arguments for *beginnen* ‘to begin’ in n

Verb Description

- D1** purely syntactic definition of subcategorisation
- D2** syntactico-semantic definition of subcategorisation
with prepositional preferences
- D3** syntactico-semantic definition of subcategorisation
with prepositional and selectional preferences

D1 → D2 → D3

<i>D1</i>		<i>D2</i>		<i>D3</i>	
np	0.43	n	0.28	<u>n</u> (Situation)	0.12
n	0.28	np:um _{Akk}	0.16	<u>np:um</u> _{Akk} (Situation)	0.09
ni	0.09	ni	0.09	<u>np:mit</u> _{Dat} (Situation)	0.04
na	0.07	np:mit _{Dat}	0.08	<u>ni</u> (Lebewesen)	0.03
nd	0.04	na	0.07	<u>n</u> (Zustand)	0.03
nap	0.03	np:an _{Dat}	0.06	<u>np:an</u> _{Dat} (Situation)	0.03
nad	0.03	np:in _{Dat}	0.06	<u>np:in</u> _{Dat} (Situation)	0.03
nir	0.01	nd	0.04	<u>n</u> (Zeit)	0.03
ns-2	0.01	nad	0.02	<u>n</u> (Sache)	0.02
xp	0.01	np:nach _{Dat}	0.01	<u>na</u> (Situation)	0.02

Example: *beginnen* ‘to begin’

D1 → D2 → D3

<i>D1</i>		<i>D2</i>		<i>D3</i>	
na	0.42	na	0.42	<u>na</u> (Lebewesen)	0.33
n	0.26	n	0.26	<u>na</u> (Nahrung)	0.17
nad	0.10	nad	0.10	<u>na</u> (Sache)	0.09
np	0.06	nd	0.05	<u>n</u> (Lebewesen)	0.08
nd	0.05	ns-2	0.02	<u>na</u> (Lebewesen)	0.07
nap	0.04	np:auf _{Dat}	0.02	<u>n</u> (Nahrung)	0.06
ns-2	0.02	ns-w	0.01	<u>n</u> (Sache)	0.04
ns-w	0.01	ni	0.01	<u>nd</u> (Lebewesen)	0.04
ni	0.01	np:mit _{Dat}	0.01	<u>nd</u> (Nahrung)	0.02
nas-2	0.01	np:in _{Dat}	0.01	<u>na</u> (Attribut)	0.02

Example: **essen** ‘to eat’

D1 → D2 → D3

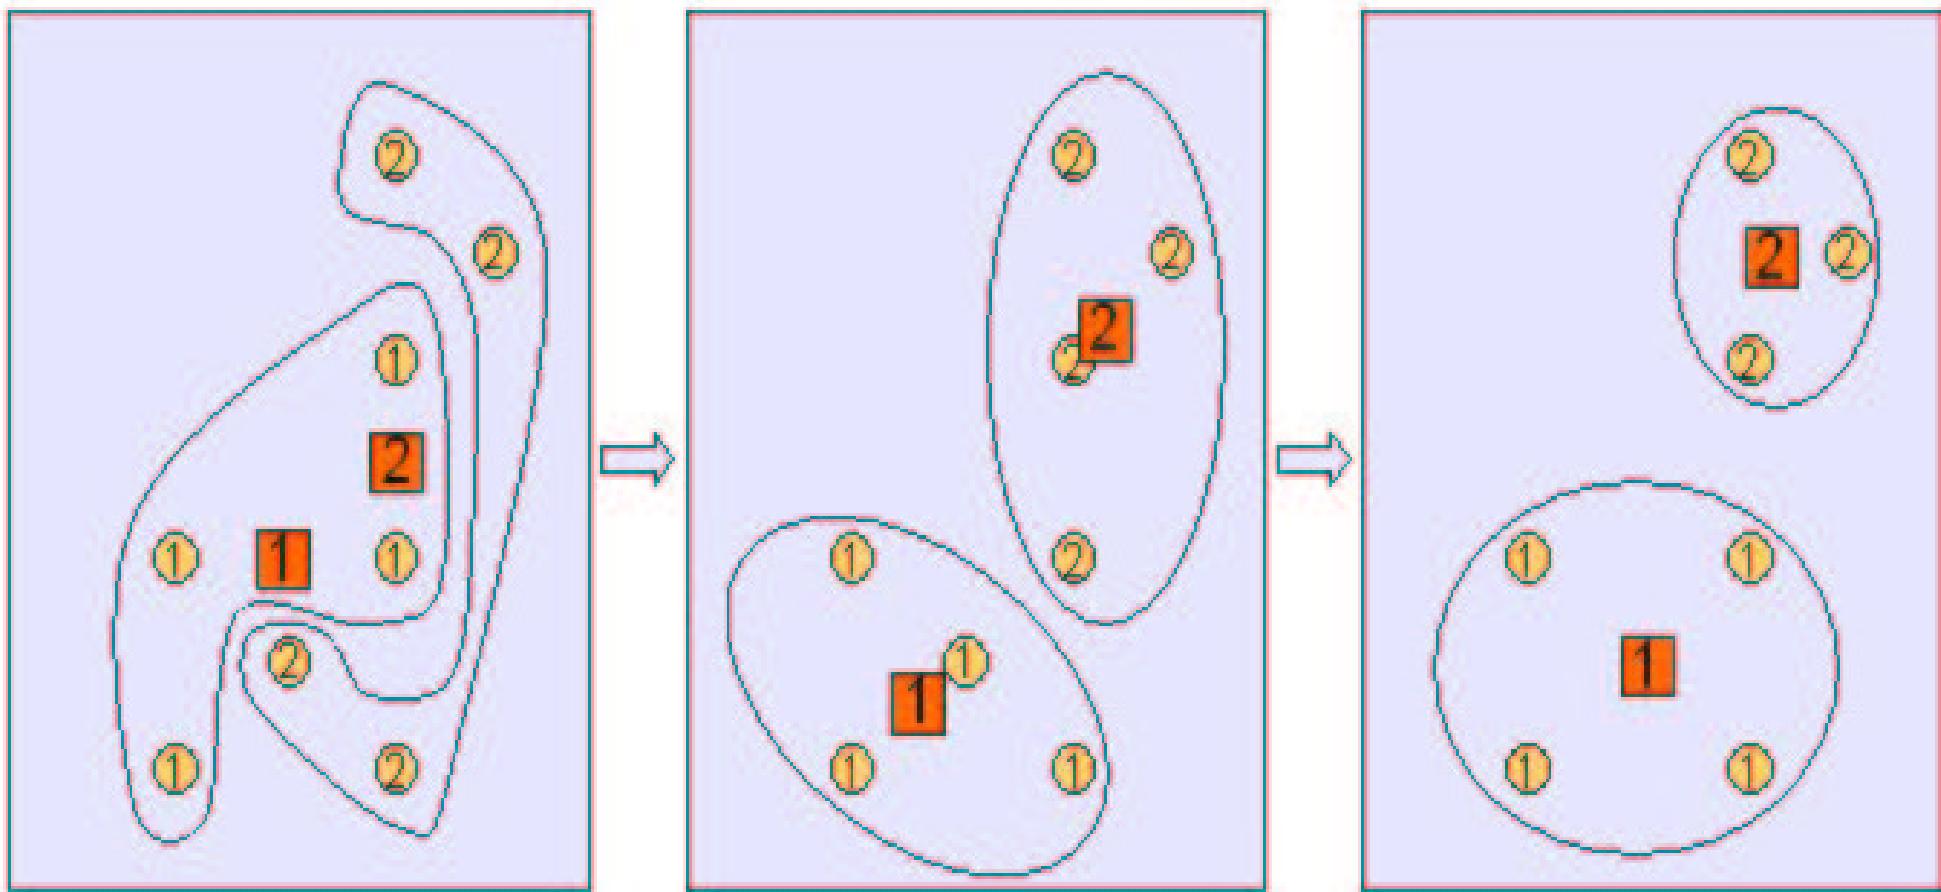
D1		D2		D3	
n	0.34	n	0.34	<u>n</u> (Sache)	0.12
np	0.29	na	0.19	<u>n</u> (Lebewesen)	0.10
na	0.19	np: <i>in</i> _{Akk}	0.05	<u>na</u> (Lebewesen)	0.08
nap	0.06	nad	0.04	<u>na</u> (Sache)	0.06
nad	0.04	np: <i>zu</i> _{Dat}	0.04	<u>n</u> (Ort)	0.06
nd	0.04	nd	0.04	<u>na</u> (Sache)	0.05
ni	0.01	np: <i>nach</i> _{Dat}	0.04	<u>np:</u> <i>in</i> _{Akk} (Sache)	0.02
ns-2	0.01	np: <i>mit</i> _{Dat}	0.03	<u>np:</u> <i>zu</i> _{Dat} (Sache)	0.02
ndp	0.01	np: <i>in</i> _{Dat}	0.03	<u>np:</u> <i>in</i> _{Akk} (Lebewesen)	0.02
ns-w	0.01	np: <i>auf</i> _{Dat}	0.02	<u>np:</u> <i>nach</i> _{Dat} (Sache)	0.02

Example: *fahren* ‘to drive’

k-Means Clustering

- k-Means algorithm (Forgy 1965)
- Unsupervised hard clustering: n objects $\rightarrow k$ clusters
- Iterative re-organisation of cluster membership:
 1. Initial cluster assignment: agglomerative hierarchical clusters
 2. Calculation of cluster centroids
 3. Determining closest cluster (centroid)
 4. Re-arrangement of cluster membership
- Similarity measure: skew divergence
$$d(v_1, v_2) = D(p \parallel w * q + (1 - w) * p) \quad \text{with weight } w \text{ set to 0.9}$$
- Number of clusters: 43 (= manual)

k-Means Clustering: Illustration



Clustering Evaluation

Gold standard : hand-constructed verb classes

- Evaluation = Similarity between two partitions on verb set
- Evaluation measure: adjusted Rand index (Hubert/Arabie 1985):
 - Agreement between verb pairs in the partitions
 - Correction for chance in comparison to random partition
 - Typical range: $0 \leq R_{adj} \leq 1$

$$R_{adj} = \frac{\sum_{i,j} \binom{t_{ij}}{2} - \frac{\sum_i \binom{t_{i\cdot}}{2} \sum_j \binom{t_{\cdot j}}{2}}{\binom{n}{2}}}{\frac{1}{2} (\sum_i \binom{t_{i\cdot}}{2} + \sum_j \binom{t_{\cdot j}}{2}) - \frac{\sum_i \binom{t_{i\cdot}}{2} \sum_j \binom{t_{\cdot j}}{2}}{\binom{n}{2}}} \quad (1)$$

Clustering Results on $D1$ and $D2$

Distribution	R_{adj}
$D1$	0.094
$D2$	pp_{arg}
	pp_{chosen}
	pp_{all}

Clustering Results on Varying $D3$

Single Slots	Slot Combinations
<u>n</u>	0.125
<u>na</u>	0.176
<u>na</u>	0.164
<u>nad</u>	0.144
<u>nad</u>	0.115
<u>nad</u>	0.161
<u>nd</u>	0.152
<u>nd</u>	0.143
<u>np</u>	0.133
<u>ni</u>	0.148
<u>nr</u>	0.136
<u>ns-2</u>	0.121
<u>ns-dass</u>	0.156
<u>na</u>	0.137
<u>n/na</u>	0.128
<u>nad</u>	0.088
<u>n/na/nad</u>	0.118
<u>nd</u>	0.150
<u>n/na/nd</u>	0.124
<u>n/na/nad/nd</u>	0.161
<u>n/na/nd/nad/ns-dass</u>	0.182
<u>np/ni/nr/ns-2/ns-dass</u>	0.131
all NP	0.158
all NPs+PPs	0.176

Cluster Analysis (D3) – Examples

- (a) beginnen₁ bestehen₃₇ enden₁ existieren₃₇ laufen₈ liegen₃₁ sitzen₃₁ stehen₃₁
- (b) eilen₁₀ gleiten₁₂ kriechen₈ rennen₈ starren₁₆
- (c) fahren₁₁ fliegen₁₁ fließen₁₂ klettern₈ segeln₁₁ wandern₈
- (d) bilden₃₂ erhöhen₃₅ festlegen₂₂ senken₃₅ steigern₃₅ vergrößern₃₅ verkleinern₃₅
- (e) töten₃₉ unterrichten₂₉
- (f) nieseln₄₃ regnen₄₃ schneien₄₃
- (g) dämmern₄₃

Large-Scale Cluster Analysis (D3) – Examples ↓ →

- (a) *anhören* ‘to listen’, *auswirken* ‘to affect’, *einigen* ‘to agree’, *lohnen* ‘to be worth’, *verhalten* ‘to behave’, *wandeln* ‘to promenade’
- (b) *beschleunigen* ‘to speed up’, ***bilden***, *darstellen* ‘to illustrate’, *decken* ‘to cover’, *erfüllen* ‘to fulfil’, ***erhöhen*** ‘to raise’, *erledigen* ‘to fulfil’, *finanzieren* ‘to finance’, *füllen* ‘to fill’, *lösen* ‘to solve’, *rechtfertigen* ‘to justify’, ***reduzieren*** ‘to reduce’, ***senken*** ‘to lower’, ***steigern*** ‘to increase’, ***verbessern*** ‘to improve’, ***vergrößern*** ‘to enlarge’, ***verkleinern*** ‘to make smaller’, ***verringern*** ‘to decrease’, ***verschieben*** ‘to shift’, ***verschärfen*** ‘to intensify’, ***verstärken*** ‘to intensify’, ***verändern*** ‘to change’

Large-Scale Cluster Analysis (D3) – Examples ↑

- (a) **ahnen** ‘to guess’, **bedauern** ‘to regret’, **befürchten** ‘to fear’, **bezweifeln** ‘to doubt’, **merken** ‘to notice’, **vermuten** ‘to assume’, **weißen** ‘to whiten’, **wissen** ‘to know’
- (b) **basieren** ‘to be based on’, **beruhen** ‘to be based on’, **resultieren** ‘to result from’, **stammen** ‘to stem from’
- (c) **befragen** ‘to interrogate’, **entlassen** ‘to release’, **ermorden** ‘to assassinate’, **erschießen** ‘to shoot’, **festnehmen** ‘to arrest’, **töten** ‘to kill’, **verhaften** ‘to arrest’
- (d) **beziffern** ‘to amount to’, **schätzen** ‘to estimate’, **veranschlagen** ‘to estimate’

Discussion

- Clustering methodology for automatic basis of large-scale verb classification
- Step-wise refinement of features improves clustering
- Linguistic intuition and clustering results do not necessarily align
- Difficulty of selecting and encoding verb features
(→ selectional preferences)
- Idiosyncratic properties of verbs
- Specific properties of desired verb classification

Verb Class Usage

- Redundancy reduction in verb descriptions by generalising over the common properties of verbs
 - Prediction of properties and refinement of vague properties
- Possible NLP applications: parsing, language modelling, machine translation, information extraction

Verb Classes for NLP Applications

- Machine translation (Dorr 1997)
- Document classification (Klavans and Kan 1998)
- Word sense disambiguation
(Dorr and Jones 1996, Prescher et al. 2000)
- Subcategorisation acquisition and filtering (Korhonen 2002)