

Aktuelle Architekturfragen in der Maschinellen
Übersetzung
semantischer Transfer und Integration statistischer
Information in *translate*

Kurt Eberle
Lingenio GmbH

26. Juni 2008

Überblick

- Das Übersetzungsproblem:
Mehrdeutigkeit, Translation mismatches
- Lösungsvorschläge: 1., 2., 3. Generation der MÜ
- Aktuelle Diskussion:
Hybride Systeme
- *translate*:
Hintergrund, Architekturen
- 'Hybridisierung' von *translate*:
Statistische Korpus-Information für Analyse, Transfer und Generierung

Mehrdeutigkeit

- lexikalisch
 - Kategoriale Ambiguität von Lexemen und Gramemen
 - *Time_{N/V} flies_{N/V} like_{V/P} an arrow - Zeitfliegen lieben einen Pfeil*
 - Semantische Ambiguität kategorial disambigierter Lexeme und Grameme
 - *Sie stellt_{PHYS/SOC} den Drucker ein_{PERSON/TOOL} - She hires/adjusts the printer.*
- strukturell
 - Funktionale Ambiguität (Label-/Etiketten-Ambiguität)
 - Ein Bild Albrecht Dürers. - A picture of/by Albrecht Dürer*
 - Attachment-Ambiguität
 - Bilder von der Kanzlerin hinter dem Tresen. - Pictures showing the chancellor behind the bar/ pictures behind the bar showing the chancellor*
 - Skopus-Ambiguität
 - Few women like many men - Wenige Frauen mögen viele Männer*
- referentiell, pragmatisch
 - *They saw the Alps as they flew over Zurich.*

Mehrdeutigkeit und Übersetzung

- Filter für die Disambiguierung
 - Syntaktische Constraints
*time flies like ... - *Zeit fliegt mag/mögen ...*
 - Semantische Selektionsbeschränkungen
**She hires the print device*
- Nicht alle Mehrdeutigkeiten müssen aufgelöst werden!
 - *printer - Drucker*
 - *few(x, woman, many(y, man, like(x, y))) / many(y, man, few(x, woman, like(x, y)))*
- Variable Analysetiefe - Übersetzung als *negociator*
(Kay Gawron Norvig1994)

Translation mismatches

(Kameyama Ochitani Peters 1991)

- Lexikalische Divergenz

un novillo - ein Jungbulle - a young bull

Rappe, Schimmel, ...

Boden - soil (Durrell 1988)

- Thematische Divergenz und Scrambling
(Dorr 1990, Hutchins Somers 1992)

Mir gefällt die Aufführung - I like the performance

Il remet le bouquet à la femme - er überreicht der Frau den Strauß / den Strauß der Frau

- Hinzufügen und Tilgen von Teilstrukturen

er durchschwimmt den Fluß - Il traverse la rivière en nageant

- Strukturumkehrung (Head switching)

Er raucht gerne - He likes to smoke

La plupart des gens aiment le foot - Die meisten Leute mögen Fußball

Translation mismatches und Repräsentationen

- Morphosyntaktische Repräsentation

Er schreibt an die Angestellten ↔ Il écrit aux employés

[Prep [DET_{def} N] NP]

- Funktional/Semantische Repräsentation

Peter würde den Wein nicht mögen. ↔ Peter n'aimerait pas le vin.

[PRED: "mögen⟨(↑SUBJ) (↑OBJ)⟩"
SUBJ: [PRED: "wein"]
OBJ: [PRED: "peter"]
NEG: +
TENSE: COND]

- Semantisch/Konzeptuelle Repräsentation

Peter raucht gerne ↔ Peter likes to swim

s
s : ATT(peter, { <POS_DISP, λx.rauchen(x) > })

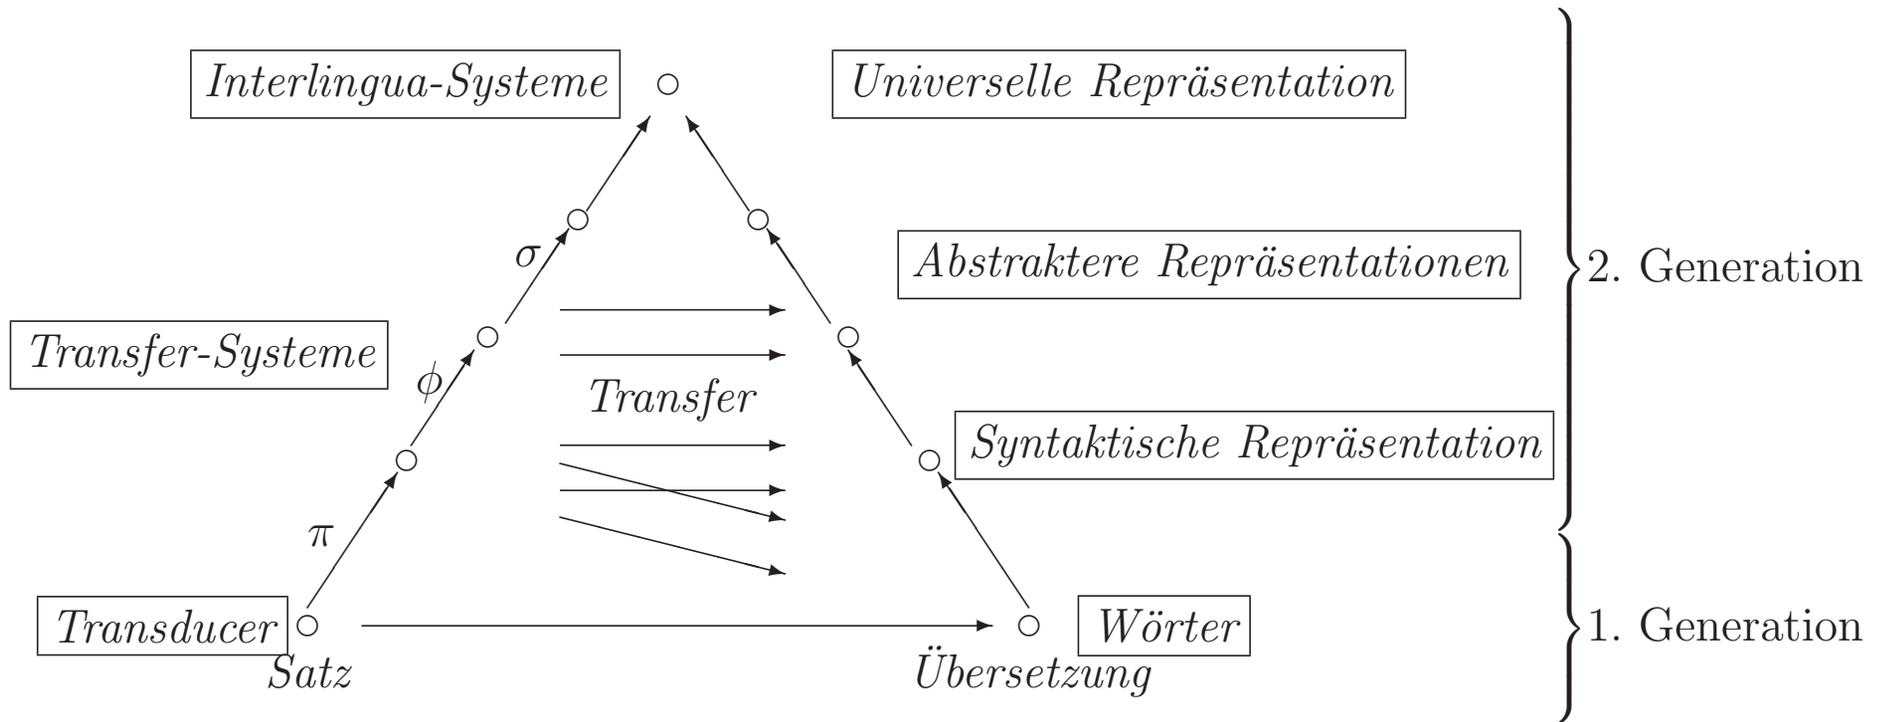
Mehrdeutigkeit, Mismatches und Analysen

- Analysen filtern
- je abstrakter die Analyse desto geringer der Source-Target-Unterschied
- je abstrakter die Analyse desto mehr Disambiguierungsaufwand

→ Optimierungsproblem

Lösungsversuche

(Vauquois 19975)



Regel-basierte Architekturen

Lösungsversuche - 3. Generation

- Statistik-basierte Systeme (SMT)
- Beispiel-basierte Systeme (EBMT)

Beispiel-basierte Systeme (EBMT)

(Sumita et al 1990, Maruyama Watanabe 1992)

Souvent le charpentier travaille le bois - Oft bearbeitet der Zimmermann das Holz

<i>{le charpentier travaille}</i>	–	<i>{der Zimmermann arbeitet}</i>
<i>{travaille le bois}</i>	–	<i>{bearbeitet das Holz}</i>
<i>{le charpentier}</i>	–	<i>{der Zimmermann}</i>

Finde (berechne) optimale Überdeckung:

{Souvent } ∪ {le charpentier } ∪ {travaille le bois}

Aktuell - Hybride Systeme

- Maximum-Entropie-Modell und linguistische Features (Och Ney 2002)

$$\hat{e}_1^I = \operatorname{argmax}_{e_1^I} \left\{ \sum_{m=1}^M \lambda_m h_m(e_1^I, f_1^J) \right\}$$

h_m : POS-Unterschiede, Differenz VP-Knoten, ...

- Linguistische Vor- und Nachbearbeitung: (Quirk Menezes Cherry 2005): Dependency treelet translation

Text \rightarrow *VB* \rightarrow *Suche* $\{ \leftarrow$ *Lexikon-*, *Alignment-*, *Sprach-Modell + Features* $\} \rightarrow$ *NB*

- Syntaktisch motivierte Beispiele, rekursive Beispielkomposition (Chiang 2006): HIERO

$\langle (1)_{NP1} \text{ 's } (2)_{NP2}, \text{DET } (2)_{NP2} \text{ de } (1)_{NP1} \rangle$

- Multisystem: Integriere Konkurrenzergbnisse

translate

Hintergrund

Lingenio

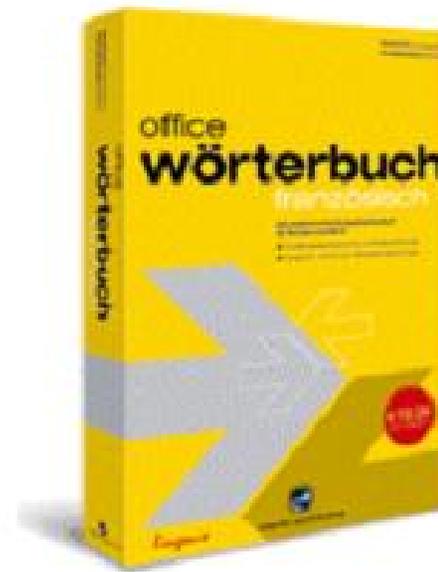
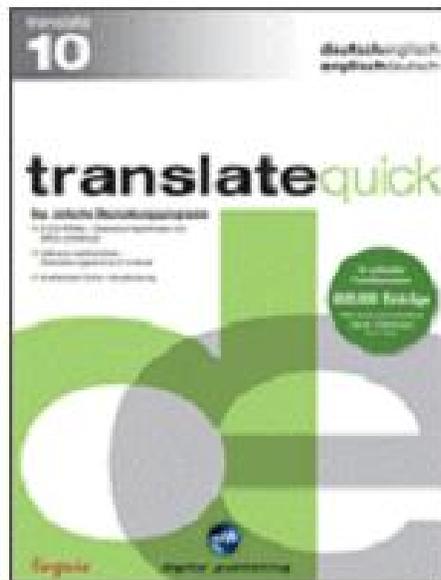
- Wissenschaftliches Zentrum der IBM
- 1999 Ausgründung unter dem Namen *linguatec* Entwicklung & Services
- Zusammenarbeit mit *linguatec* Sprachtechnologien
- seit 2004 unter dem Namen *lingenio*
- Zusammenarbeit mit *digital publishing*

translate

Produktentwicklung

- Kommerzielles Maschinelles Übersetzungssystem
- *Logic based Machine Translation (LMT)*
(McCord 1989), IBM
- 1996 *Personal Translator* (IBM, linguattec)
- 1999 *Personal Translator Französisch* (linguattec)
- 2004 *translate* (Lingenio)
- 2005 *office* Wörterbcher

Produkte



version 8

deutschenglisch | englischdeutsch
deutschfranzösisch | französischdeutsch



translate

Die neuen Übersetzer
für Ihre Texte, Internet
und E-Mails

t translate pro - Deutsch - Französisch

☰ Datei Bearbeiten Ansicht Format Wörterbuch Übersetzen Satzarchiv Sprachausgabe Hilfe

Deutsch - Französisch

Arial 10 A B K U

Unbekannte Wörter

Atomdrohungen (Kompositum)
h18
Opposition
Kuhn
Atomdrohung (Kompositum)
Kraftmeierei
Blumentopf (Kompositum)
Topthemen (Kompositum)

Status

Quelltext - (unbenannt)

Topthemen

Merkel soll Pariser Atomdrohungen missbilligen

23/01/2006 08h18

Die Opposition hat Bundeskanzlerin Angela Merkel aufgefordert, sich bei ihrem heftigen Gespräch mit dem französischen Präsidenten Jacques Chirac von den umstrittenen französischen Nukleardrohungen zu distanzieren. "Frau Merkel muss endlich klar sagen, dass die französische Atomdrohung in Deutschland nicht akzeptiert wird", fordert die Opposition.

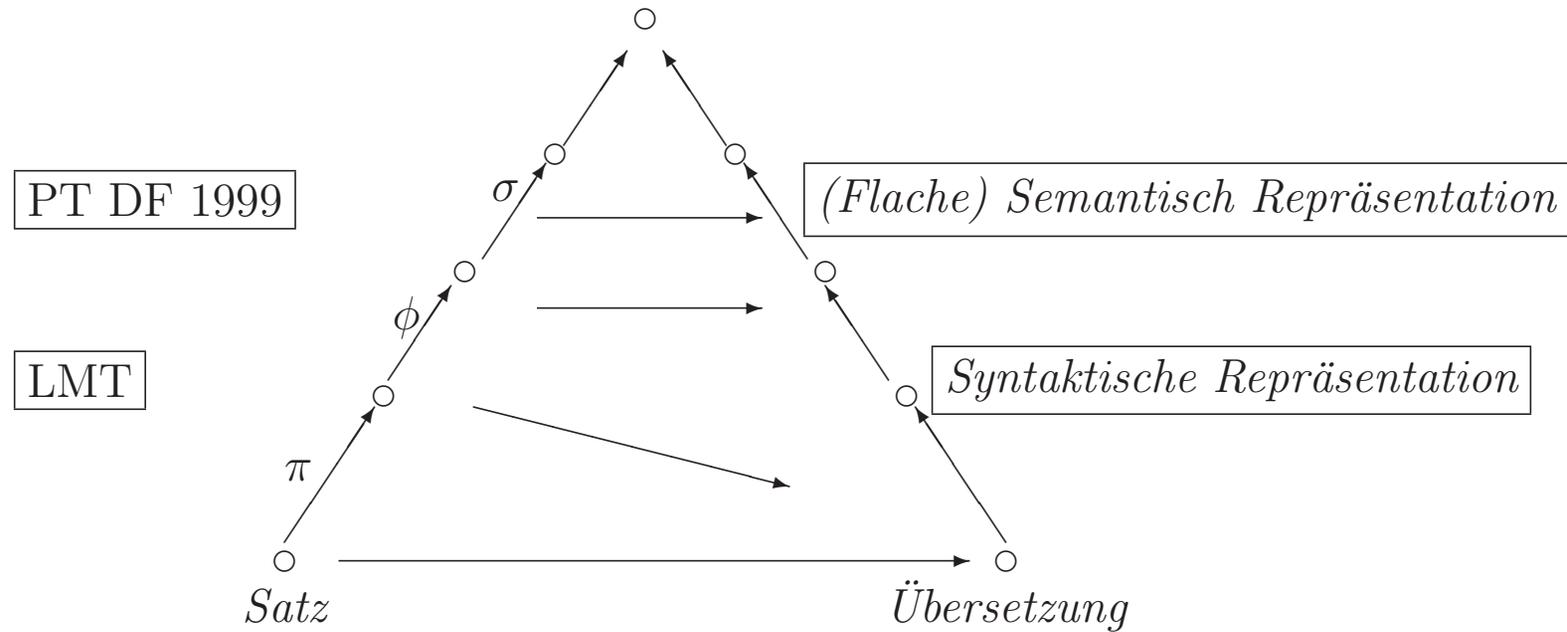
Zieltext - (unbenannt)

Des sujets de haut niveau

Merkel doit désapprouver des menaces d'atome parisiennes

23/01/2006 08 h18

translate-Architekturen



translate - **Flache Semantik**

Flat underspecified discourse representation theory (FUDRT) (Eberle 1997)
(Erweiterung/Modifikation der UDRT (Reyle 1993))

- Lexikon:
Semantische Repräsentationen sind **Funktionen**
(die bei Bedarf schrittweise durch den Kontext ausgewertet werden)
- Satzrepräsentationen:
Mengen von DRSen und **DRS-Modifikatoren ...**
und Aussagen zu Ordnung und **Art der Applikation**

Disambiguierung nach Bedarf!

translate - **Flache Semantik**

implementiert

- Abhängigkeits-Strukturen (Prädikat-(gram.) Argument-Strukturen)
- Semantische Abstraktionen bei Koordinationen und bestimmten Angaben
- Informationsstruktur (Fokus-Hintergrundbestimmung bei Fokus-Adverbien)
- Skopusauflösung bei Bedarf
- Akzessibilitätsinformation für die Pronomenauflösung
- Transfer auf FUDRSen
- (variable Analysetiefe)

”Auffaltung” koordinierter Strukturen (bei Bedarf)

☞ Eingabeaufforderung (2) - prolog

Eingabe:

! : Zum Schluss war er Alkohol-abhängig und sogar süchtig nach Heroin.

Dependence tree.

■ top	s(sei,2)	ntv(ind:dcl:nwh,tf(past,0,X1),a):[[lse,sei,v_adj]]
├─ vprep	s(zu,814900)	prep([zu dat],[nwh]):[[dirp,zu]]
│ └─ objprep(dat)	s(schluss,schluss)	noun(cn,dat,pers3-sg-n,[]):[[accompl,result0,schluss]]
│ │ └─ ndet	s(dem,d)	det(dat,pers3-sg-n,[def]):[[d,dem]]
│ └─ lconj	s(sei,2)	ntv(ind:dcl:nwh,tf(past,0,X2),a):[[lse,sei,v_adj]]
├─ subj(n)	s(er,206261)	noun(pron(pers3),nom,pers3-sg-n,[]):[[er,perspron]]
│ └─ pred(a)	s(abhängig,4350)	adj(p,X3,X4,[]):[[abhängig]]
├─ acompound	s(alkohol,20600)	noun(cn,[nom,dat,acc],pers3-sg-m,[]):[[alkohol,beverage,dr]]
│ └─ rconj	s(sei,2)	ntv(ind:dcl:nwh,tf(past,0,X5),a):[[lse,sei,v_adj]]
├─ vadv	s(sogar,644400)	adv(p,[]):[[dsa,focus_adv,ppadv,shade,sogar]]
│ └─ pred(a)	s(süchtig,856507)	adj(p,X6,X7,[]):[[noadv,süchtig]]
├─ acomp(p([nach dat]))	s(heroin,33220)	noun(cn,dat,pers3-sg-nt,[]):[[droge0,heroin,mass]]
└─ subj(n)	empty	coref(5)

À la fin il était dépendant de l'alcool et il s'adonnait à l'héroïne
même.

! :

4

Implementierung im Test

Funktionale Ambiguität, Attachment-Ambiguität

Zusammenarbeit mit IMS Stuttgart, SFB 732 Projekt B3

```
C:\ Eingabeaufforderung (2) - prolog
::
::
::
::
:: Peterson plante stundenweise Absperrungen mit verschiedensten Materialien.
Dependence tree.
-----
■—— top          s(plan,534364)      mtv(ind:dcl:nwh,tf(past,0,X1),a):[[cogv,creationv,nocmp,plan]]
├── subj(n)       s(Peterson,1876456) noun(prop,nom,pers3-sg-X2,[]):[[Peterson,human,lastname]]
├── xmod          s(stundenweise,683010) adv(p,[]):[[stundenweise]]
├── obj(n)        s(absperrung,1580731) noun(cn,acc,pers3-pl-f,[]):[[absperrung,nonliv,stat]]
├── xprep         s(mit,477132)      prep([mit|dat],[nwh]):[[mit]]
├── objprep(dat) s(material,461366) noun(cn,dat,pers3-pl-nt,[]):[[mat,material]]
└── nadj          s(verschieden,751701) adj(s,dat,pers3-pl-nt,[nwh]):[[verschieden]]
-----
::
```

Beispiele für die Verwendung von flachen Repräsentationen

Skopus-Ambiguität - Darstellung

In wenigstens fünf europäische Urlaubsgebiete flogen wenigstens drei Reiseveranstalter ihre Kunden in den letzten Jahren mehr als 20 Mal.

To at least five European tourist areas, at least three operators flew their clients more than 20 times within the last years.

Beispiele für die Verwendung von flachen Repräsentationen

Skopus-Ambiguität - Darstellung

In wenigstens fünf europäische Urlaubsgebiete flogen wenigstens drei Reiseveranstalter ihre Kunden in den letzten Jahren mehr als 20 Mal.

To at least five European tourist areas, at least three operators flew their clients more than 20 times within the last years.

Repräsentation:

e fliegen(e) subj(e,x) obj(e,γ)	{	subj: <u>w 3 Veranstalter(x)</u>	}
		obj: <u>ihre_kunden(γ)</u>	
		vprep: <u>in w 5 Gebiete</u>	
		⋮	

Default-Transferalgorithmus

$$\tau(\underline{\text{fliegen}} \left\{ \begin{array}{l} \text{subj: } \underline{\text{w 3 Veranstalter}}(x) \\ \text{obj: } \underline{\text{ihre_kunden}}(\gamma) \\ \text{vprep: } \underline{\text{in w 5 Gebiete}} \\ \vdots \end{array} \right\}) := \tau_n(\underline{\text{fliegen}} \left\{ \begin{array}{l} \tau_s(\text{subj}): \tau(\underline{\text{w 3 Veranstalter}})(x) \\ \tau_s(\text{obj}): \tau(\underline{\text{ihre_kunden}})(\gamma) \\ \tau_s(\text{vprep}): \tau(\underline{\text{in w 5 Gebiete}}) \\ \vdots \end{array} \right\})$$

e
fly(e)
subj(e,x)
obj(e,γ)

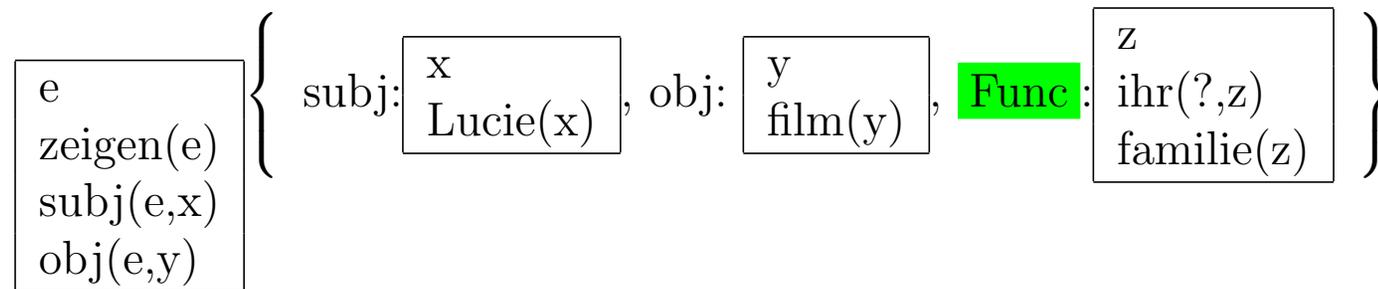
$$\left\{ \begin{array}{l} \text{subj: } \underline{\text{al 3 operators}}(x) \\ \text{obj: } \underline{\text{their clients}}(\gamma) \\ \text{vprep: } \underline{\text{to al 5 areas}} \\ \vdots \end{array} \right\}$$

Partielle Disambiguierung

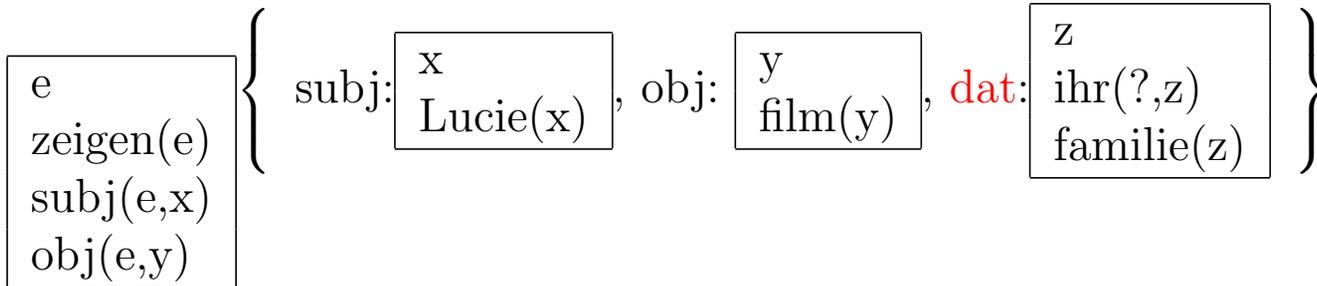
Funktionale Ambiguität

Lucie zeigte den Film ihrer Familie.

Ausgangssituation



a) Interpretiere **Func** als Dativ-Rolle der Verbrepräsentation

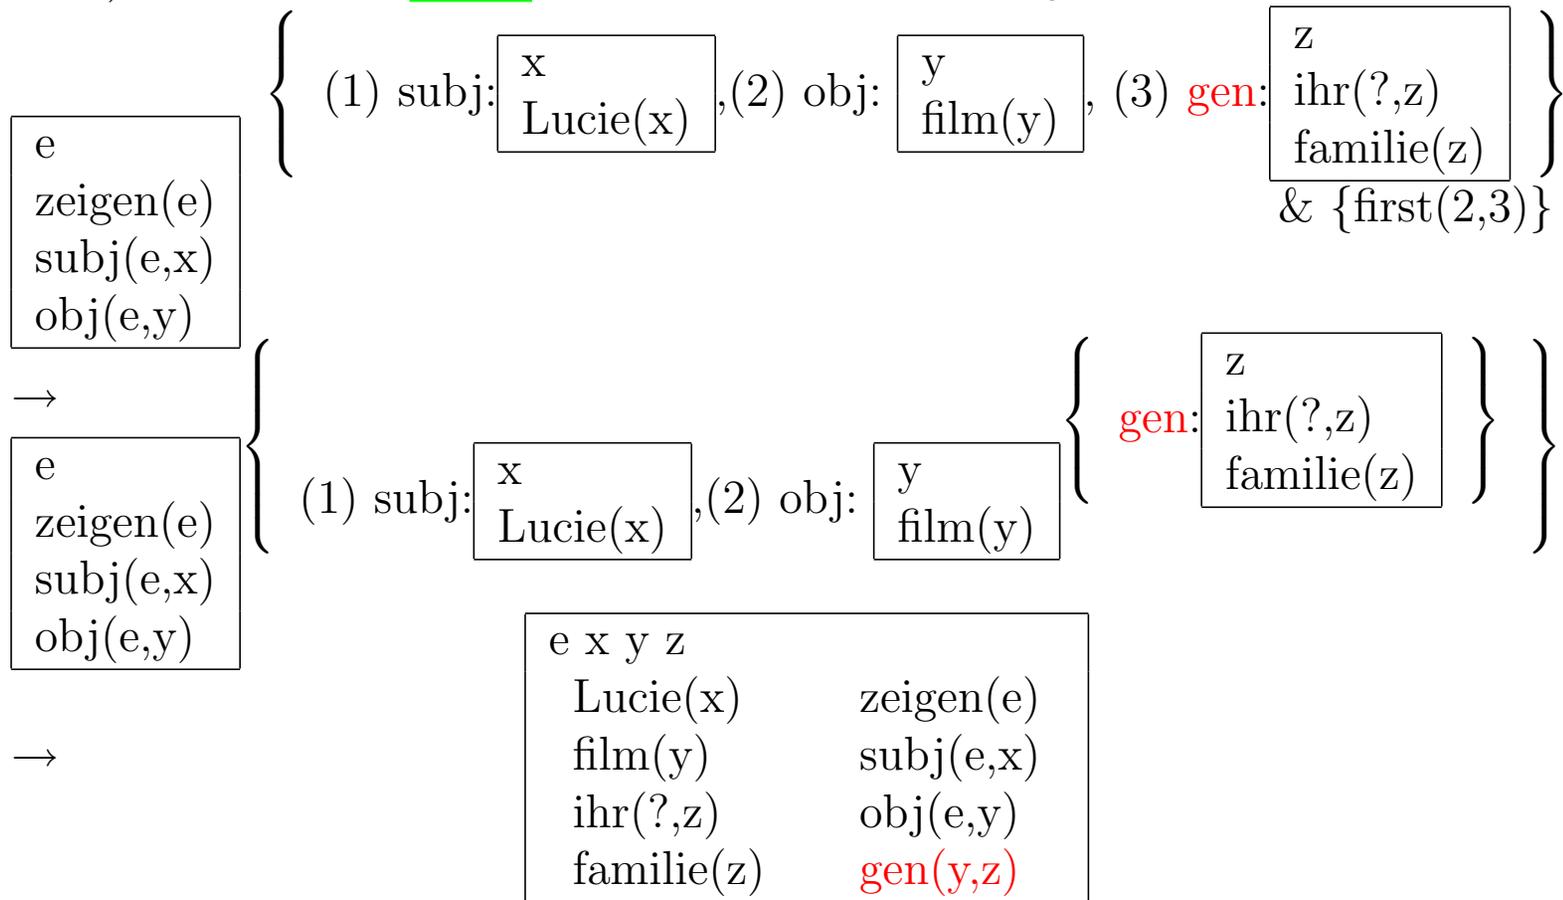


→

e	x	y	z
Lucie(x)		zeigen(e)	
film(y)		subj(e,x)	
ihr(?,z)		obj(e,y)	
familie(z)		dat(e,z)	

*Lucie **présente** le film **à** sa famille.*

b) Interpretiere **Func** als Genitiv-Rolle der Objektrepräsentation



*Lucie **pas**se le film **de** sa famille.*

Partielle Disambiguierung

Funktionale Ambiguität

Wodurch werden tiefere Auswertungen ausgelöst?

- Durch den Transfer
- nach Maßgabe im entsprechenden Eintrag im Lexikon

zeigen(e): Cond: $C \vdash_D \text{filled}(\text{obj}, \text{FILM}), \text{empty}(\text{dat})$ τ : passer

Interaktionen

Pronomen - Nomenambiguität

Pronomen haben nicht immer dieselbe Übersetzung:

elle	→	sie:	elle est intelligente	←	la femme
	→	er:	elle est visible	←	la lune
	→	es:	elle est bien élevée	←	la jeune fille

Der Bezug entscheidet!

Koreferenz-Entscheidungen haben komplexe Konsequenzen:

Enfin il trouva la balle. Elle était dégonflée.

elle	→	la balle	→	die Kugel	→	sie
				der Ball	→	er

Pronomenauflösung und Antezedent-Übersetzung interagieren!

... la *balle_u*... *Elle_x* était *dégonflée*.

s s: dégonflé(x)	\vdash_D	hohlkörper(x) norm_mit_gas_gefüllt(x)
---------------------	------------	--

u balle_kugel(u)	$\vdash x=u :$	Widerspruch!
---------------------	----------------	--------------

versus

u balle_ball(u)	$\vdash x=u :$	kein Widerspruch!
--------------------	----------------	-------------------

Schlussfolgerungen

Enfin il trouva la balle. Elle était dégonflée.

- a) Der Bezug *balle* - *elle* ist möglich.
- b) Wenn der Bezug gewählt wird, muss *balle* im Sinne von *Ball* verstanden werden!
- c) Dann ist *elle* mit *er* zu übersetzen.

und ...

Die Koreferenz-Information kann weitere Effekte in immer größeren Kontexten zeitigen!

Il tire la balle. Puis, tout d'un coup, elle se dégonfle.

- Achte auf sinnvolle Abfolge von Übersetzungs- und Auswertungsschritten

Interaktionen

Pronomen - Strukturambiguität

Pronomenbezug und Teilrepräsentationen interagieren!

*Der Polizist zeigte jedes der sichergestellten Videos einer Verdächtigen.
Er versuchte, sie dadurch in Widersprüche zu verwickeln.*

- Die Videos zeigen alle dieselbe Verdächtige (N gen)

sie = diese eine Verdächtige \rightarrow_{τ} elle

*– Il **passait** chacune des vidéos **d'**une suspecte. ... elle*

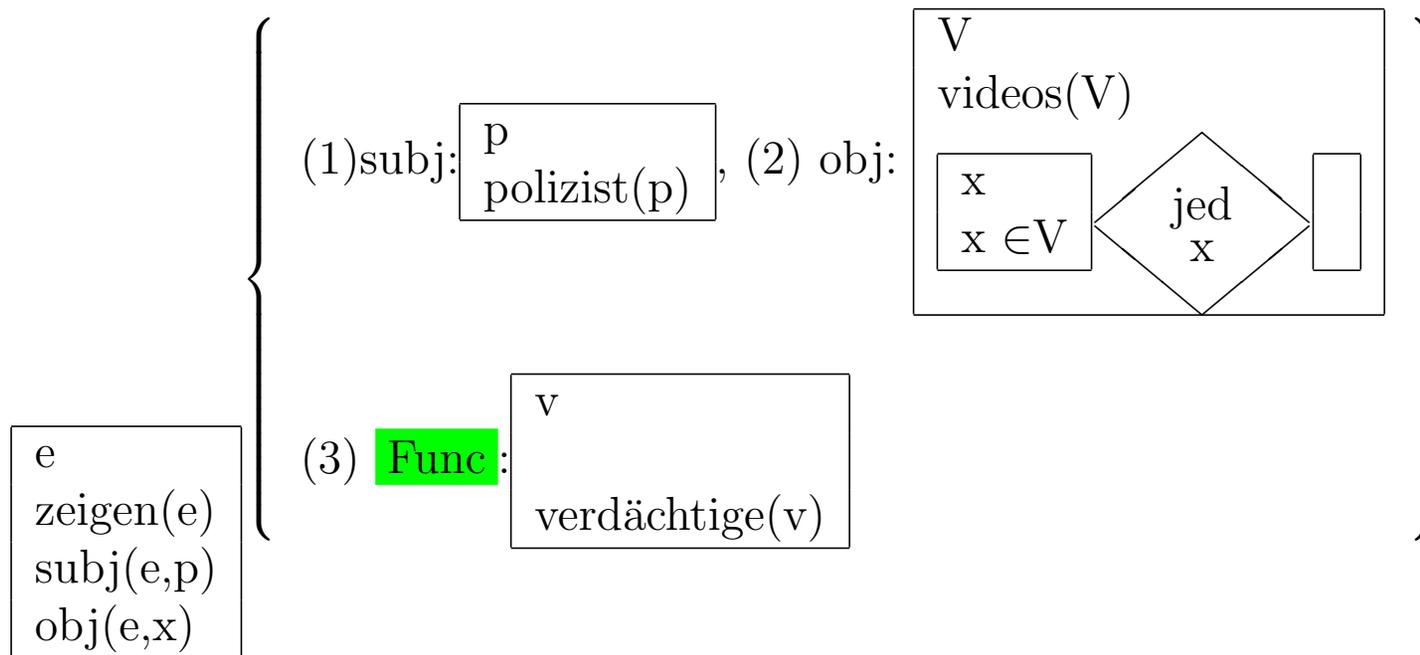
- Er zeigte jedes Video einer anderen Verdächtigen (V dat nach acc)

sie = diese vielen Verdächtigen

*– Il **présentait** chacune des vidéos **à** une suspecte (différente). ... elles*

- ...

Interdependenz der Übersetzungen und der Bezüge der Pronomen und der Teilrepräsentationen!



Zusammenhänge

$sie = \text{Pl_Pro} \rightarrow_{\tau} elles \Rightarrow (2) > (3) \wedge \text{Func}=\text{dat}$
 $zeigen \rightarrow_{\tau} présenter \grave{a}$

$sie = \text{Sg_Pro} \rightarrow_{\tau} elle \Rightarrow ((3) > (2) \wedge \text{Func}=\text{dat}) \vee (\text{first}(2,3) \wedge \text{Func}=\text{gen})$
 $présenter \grave{a} \qquad \qquad \qquad passer$

Pronomenresolution in *translate*:

- morpho-syntaktischer Filter (Lappin McCord 90)
- semantische Bedingungen des gegebenen Kontexts
- pragmatische Bewertungen (Lappin Leass 94)
- Entscheidung !
- neue semantische Bedingungen
- abschnittsweise Übersetzung (aktuelle Entwicklung)

Schwierige Mismatches

Head switching

(Sadler Thompson 1991, Butt 1994)

Peter schwimmt gerne.

Peter likes to swim.

Strukturelle Umkehrung:

gerne (Adjunkt) → like (syntaktischer Kopf)

schwimmen (Kopf) → swim (Komplement)

$$\tau((1) \text{ schwimmen } \left\{ \begin{array}{l} \text{subj: } (2) \text{ Peter} \\ \text{vadv: } (3) \text{ gerne} \end{array} \right\}) = \text{like} \left\{ \begin{array}{l} \text{subj: } \tau(2) \\ \text{comp: } \tau(1') \end{array} \right\} ?$$


Lösung

- vermeide Zirkularität
- durch partielle Skopusfestlegung
- Anweisung im Lexikon!

gerne

> *adv* []

> τ :

(u-cat(verb) \rightarrow aimer [item(subj(X'), τ (u-d(subj(X))))],item(obj(bin_f), τ (u ^{\cancel{id}})))]

...stößt eventuell weitere Disambiguierungen an...

Worauf bezieht sich *gerne* ?

Wie Franzi würde Peter gerne schwimmen.

a) *gerne* [*wie Franzi schwimmen*] (können)

← *wie Franzi* befindet sich im Skopus von *gerne*

Pierre aimerait (savoir) nager comme (/de la façon de) Franzi.

b) *wie Franzi gerne* [*schwimmen*] (gehen)

← *wie Franzi* befindet sich nicht im Skopus von *gerne*

Comme Franzi, Pierre aimerait (aller) nager.

- ein semantisches Skopusphänomen!
- andere Lösungsvorschläge:
Restriktionsoperator (Kaplan Wedekind 1993) , nicht ko-deskriptiv (Verbmobil)

Partielle Skopusfestlegung

Wie Franzi würde Peter gerne schwimmen.

$$\boxed{\begin{array}{l} e \\ \text{schwimmen}(e) \\ \text{subj}(e,x) \end{array}} \left\{ \text{subj: } \boxed{\begin{array}{l} x \\ \text{Peter}(x) \end{array}}, \text{adv:gerne, pp: wiePetra} \right\}$$

(A)

$$\left((1) \left(\boxed{\begin{array}{l} e \\ \text{schwimmen}(e) \\ \text{subj}(e,x) \end{array}} \left\{ \text{pp: (4)wieFranzi} \right\} \right) \left\{ \text{adv:(3)gerne} \right\} \right) \left\{ (2) \text{subj: } \boxed{\begin{array}{l} x \\ \text{Peter}(x) \end{array}} \right\}$$

gerne [schwimmen wie Franzi] \rightarrow_{τ} aimer savoir nager comme Franzi

(B)

$$\left(\left(\left(\begin{array}{l} e \\ (1) \text{schwimmen}(e) \\ \text{subj}(e,x) \end{array} \right) \left\{ \text{adv: (3)gerne} \right\} \right) \left\{ \text{pp: (4)wieFranzi} \right\} \right) \left\{ \text{subj:(2)} \begin{array}{l} x \\ \text{Peter}(x) \end{array} \right\}$$

wie Franzi gerne [schwimmen] \rightarrow_{τ} comme Franzi, aimer aller nager

Repräsentationen, Formalismen - Fazit

- ökonomische Repräsentation (flach)
- Auswertung nach Bedarf
- mächtiger Lexikonformalismus
- keine Transfergrammatik
- modulares Design

'Hybridisierung' von *translate*

Statistische Korpus-Information für Analyse, Transfer und Generierung

Analyse

- Lexem-Disambiguierung

Little John was looking for his toy box. Finally, he found it.

The box was in the pen. John was very happy.

(Bar-Hillel 1959)

Weltwissen → (pen = playpen/Laufstall)

oder → *Word sense disambiguation* (WSD)

pen(x) → <u>pen</u> (x) _C	C ⊢ _d sit _x ∈ BABY_FRAME	→ Laufstall(x)
	C ⊢ _D sit _x ∈ WRITING_FRAME	→ Stift(x)

- Funktional-/Attachment-Ambiguität

Beispiel: V NP Prep NP (Hindle/Rooth)

→ Bootstrapping: flache Analyse, Evaluation

'Hybridisierung' von *translate*

Transfer

- *translate 11*:

Bootstrapping: Analyse und bilinguales Lexikonwissen

→ Kontextbewertungen für Übersetzungsalternativen:

Er stellt das ein - He adjusts {adjust 0.35, end 0.3, suspend 0.15} it.

- Lernen von (analytischen) Übersetzungsbeziehungen
Bootstrapping: Lexikonwissen, Source-Targetanalysen

'Hybridisierung' von *translate*

Generierung

- Wortstellung

Poirot remet la lettre à la femme → *den Brief der Frau / der Frau den Brief*

→ Frequenzanalysen

Flache Analysen zu Korpusätzen mit Typinformationen für NPs

(Zusammenarbeit SFB 732, Projekt D2, Prof. Rohrer)

Zusammenfassung

- Aktuell: 'Hybridisierung'
- Gängig: Integration linguistischen Wissens in SMT
- *translate*: Integration von SMT- und EBMT-Methoden in RBMT
 - Flache Repräsentationen
 - variable Analysetiefe, Auswertungstrigger
 - Modularisierung:
Harte Regeln (deklarative Grammatiken) - *Weiche* Entscheidungskriterien (Disambiguierung)
 - bei Analyse, Transfer, Generierung
- Signifikante Qualitätsverbesserung
- ökonomisch, effizient