

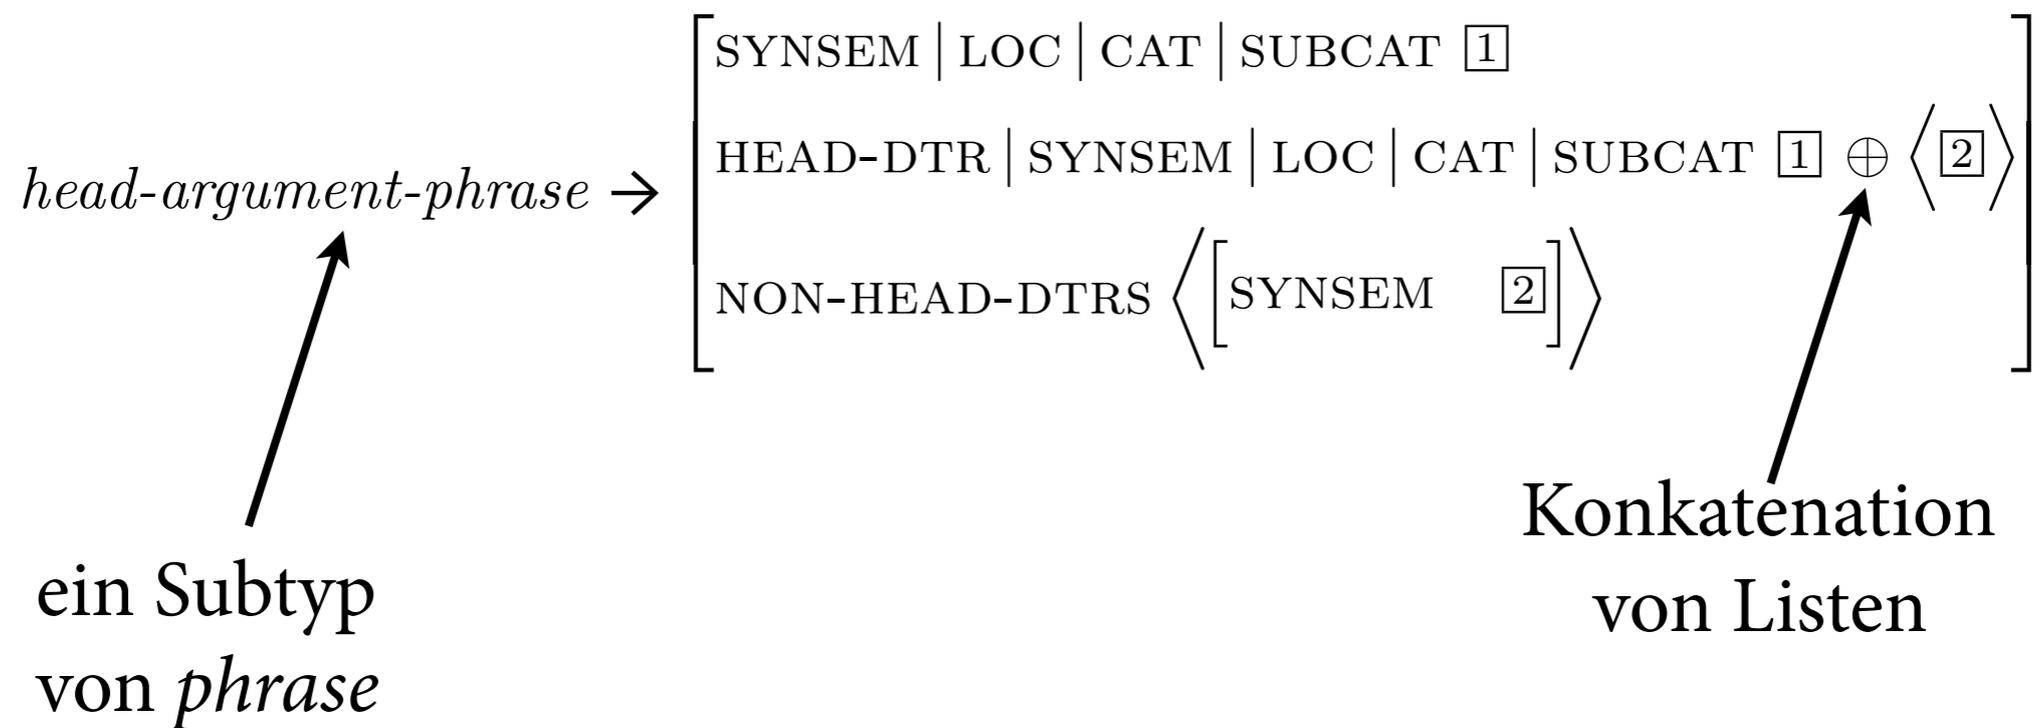
Parsing von unifikationsbasierten Grammatikformalismen

Vorlesung “Grammatikformalismen”
Alexander Koller

18. Juli 2017

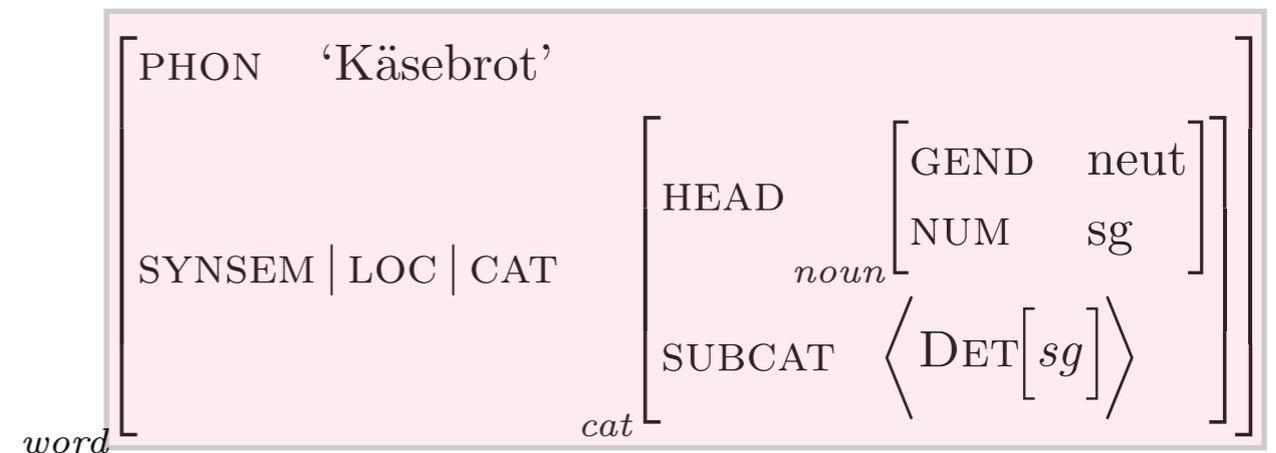
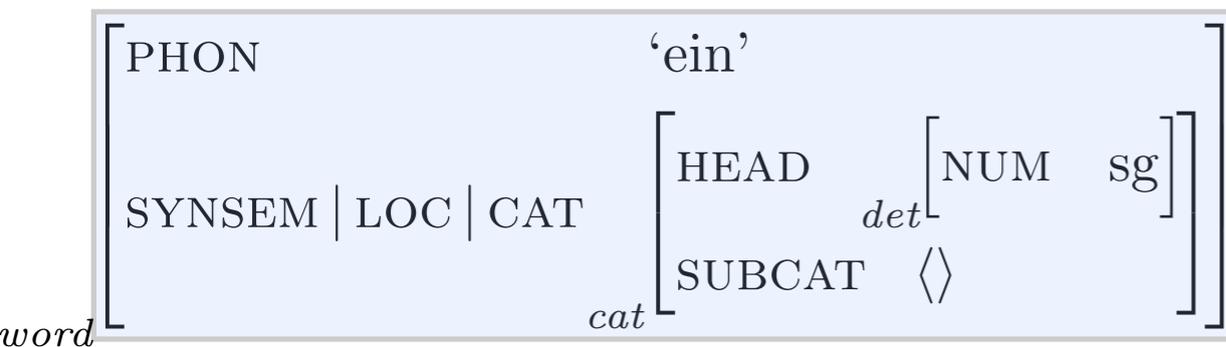
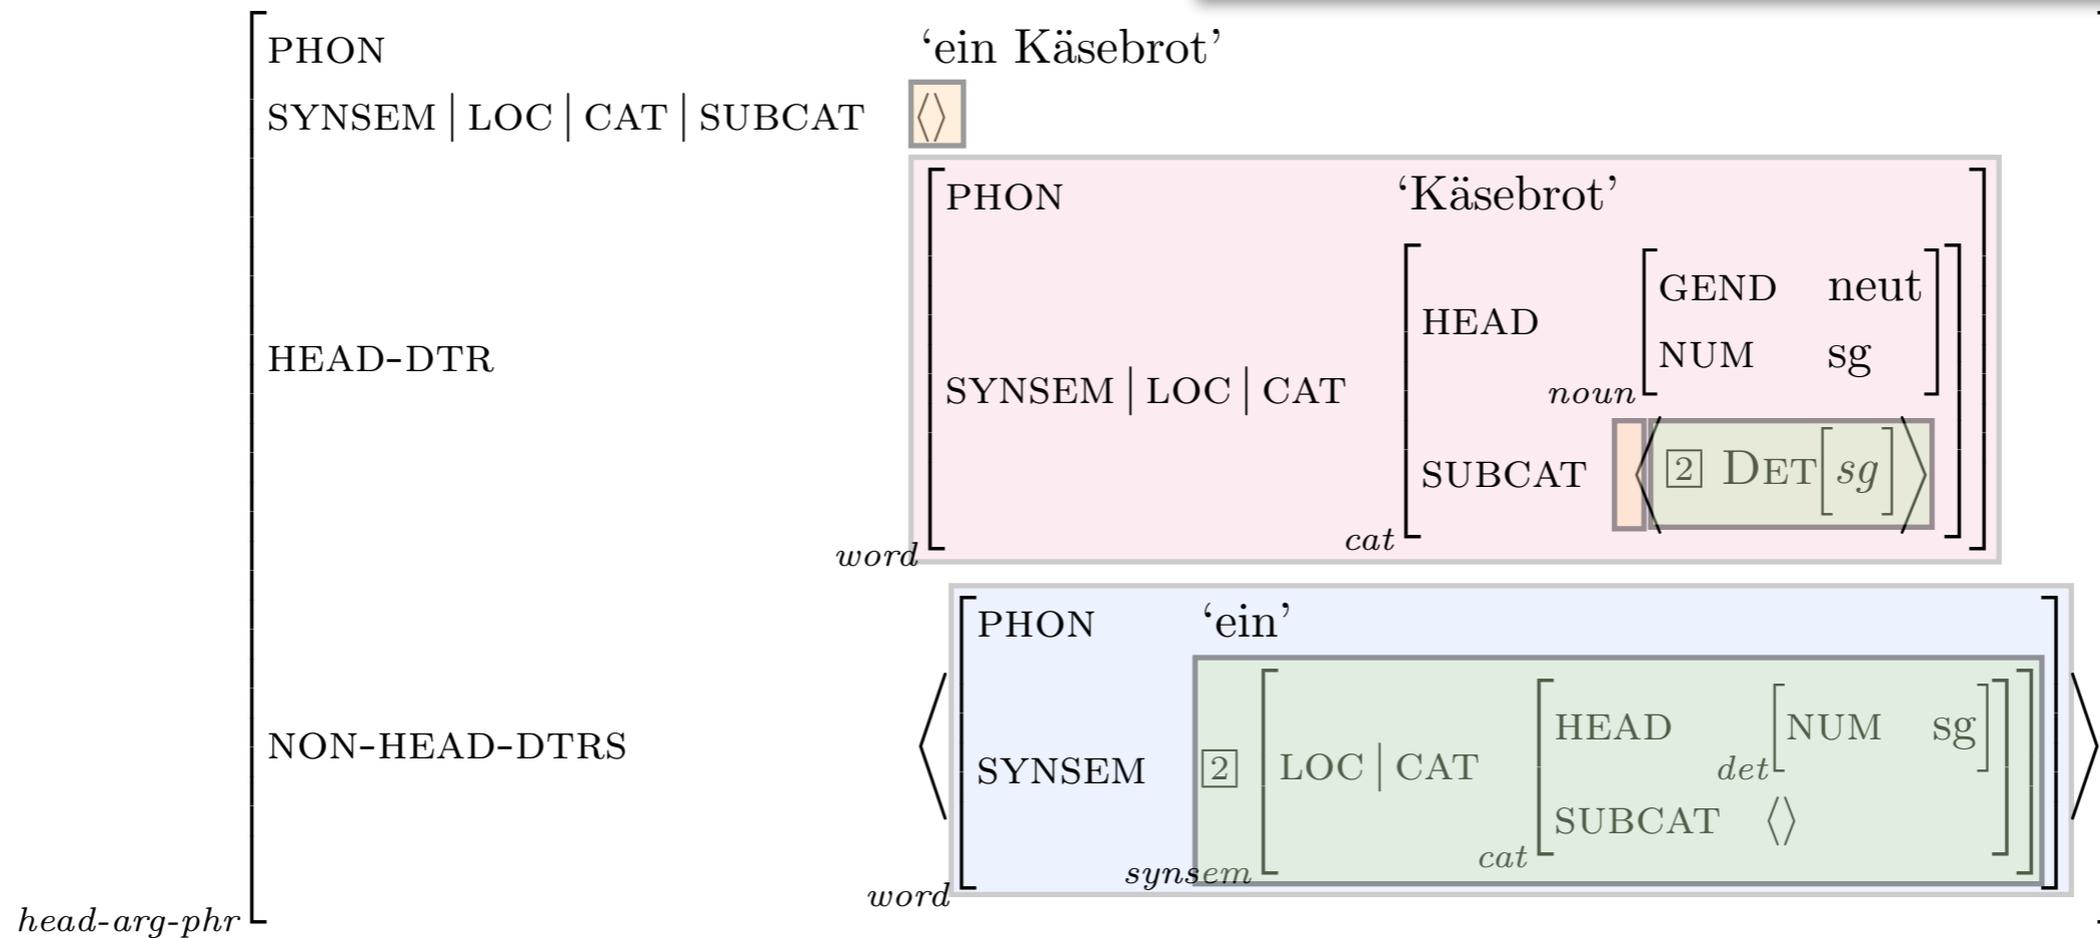
Das Kopf-Argument-Schema

- Wichtigstes Schema: Kombination von Kopf mit Argument mit dem *Kopf-Argument-Schema*.



Kopf + Argument

$$head-arg-phr \rightarrow \left[\begin{array}{l} SYNSEM | LOC | CAT | SUBCAT \boxed{1} \\ HEAD-DTR | SYNSEM | LOC | CAT | SUBCAT \boxed{1} \oplus \langle \boxed{2} \rangle \\ NON-HEAD-DTRS \langle [SYNSEM \boxed{2}] \rangle \end{array} \right]$$



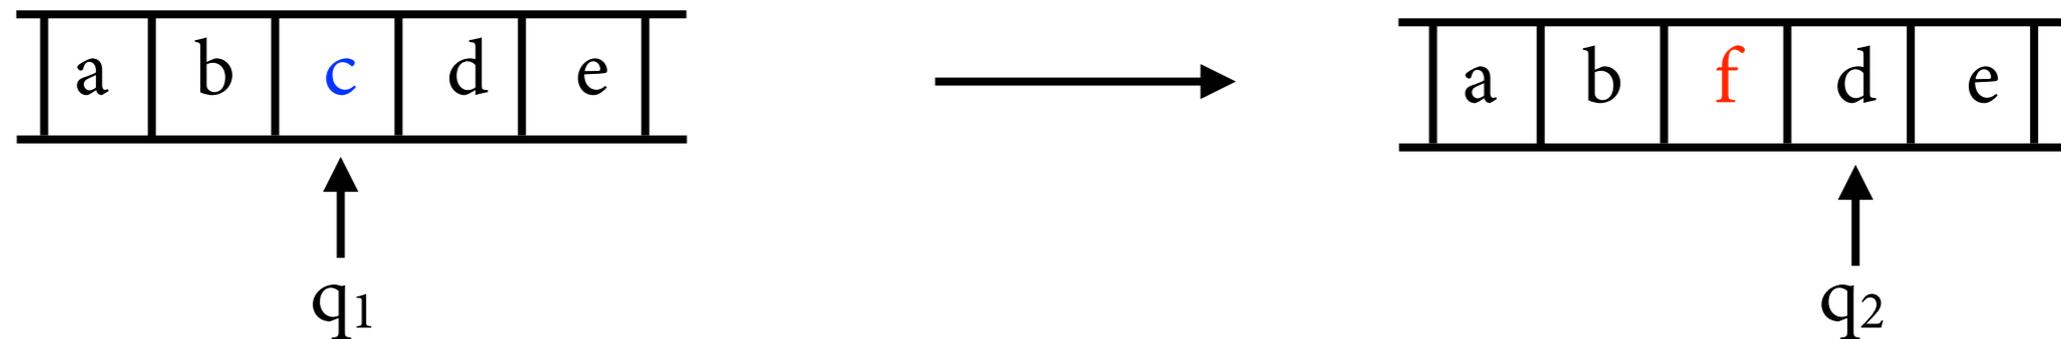
Expressivität

- Wir haben uns überzeugt, dass HPSG linguistische Phänomene sehr elegant beschreiben kann.
- Welchen Preis in formaler Expressivität bezahlen wir dafür?

Chomsky-Hierarchie

Typ	Grammatiken	Automaten
0	Typ-0-Grammatiken	Turingmaschinen
1	kontextsensitive	linear platzbeschränkte Turingmaschinen
2	kontextfreie	Kellerautomaten
3	reguläre	endliche Automaten

Codierung von Turing-Maschinen


$$\begin{bmatrix} \text{LEFT} & \langle b, a \rangle \\ \text{RIGHT} & \langle c, d, e \rangle \\ \text{STATE} & q_1 \end{bmatrix}$$

$$\begin{bmatrix} \text{LEFT} & \langle f, b, a \rangle \\ \text{RIGHT} & \langle d, e \rangle \\ \text{STATE} & q_2 \end{bmatrix}$$

Codierung von Turing-Maschinen

$$\begin{bmatrix} \text{LEFT} & \langle b, a \rangle \\ \text{RIGHT} & \langle c, d, e \rangle \\ \text{STATE} & q_1 \end{bmatrix}$$


$$\begin{bmatrix} \text{LEFT} & \langle f, b, a \rangle \\ \text{RIGHT} & \langle d, e \rangle \\ \text{STATE} & q_2 \end{bmatrix}$$

Regelschema
(vereinfacht):

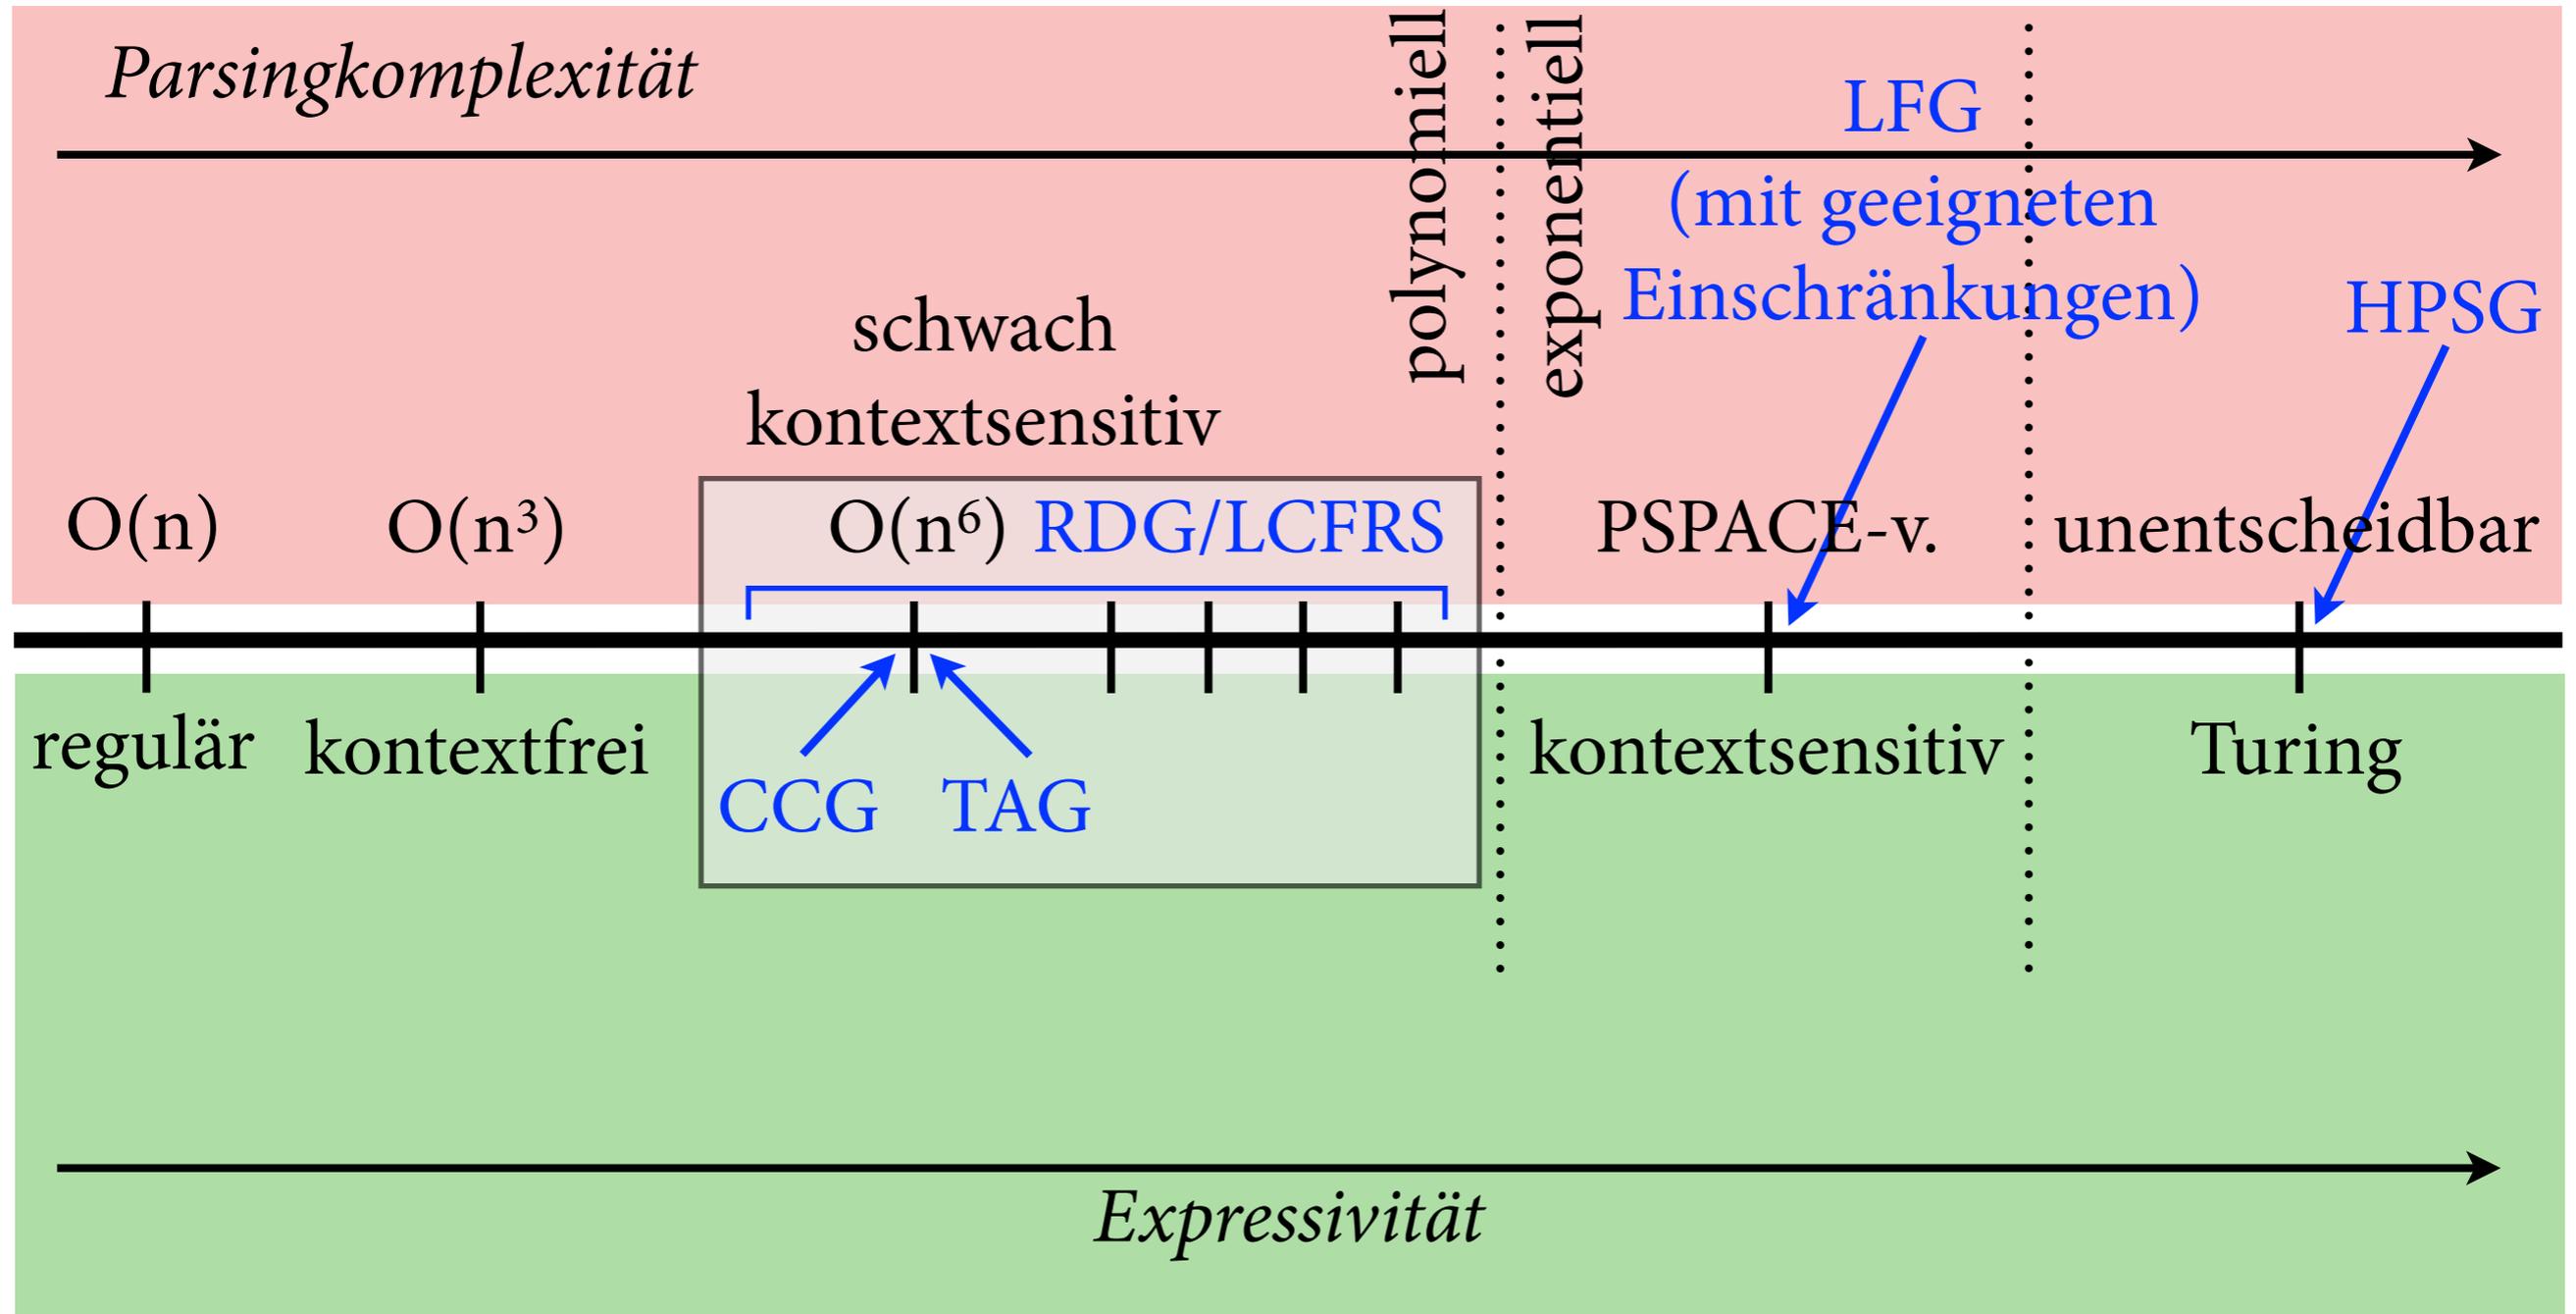
rstep →

$$\begin{bmatrix} \text{LEFT} & \begin{bmatrix} \text{FIRST} & f \\ \text{REST} & \boxed{1} \end{bmatrix} \\ \text{RIGHT} & \boxed{2} \\ \text{STATE} & q_2 \\ \text{DTR} & \begin{bmatrix} \text{LEFT} & \boxed{1} \\ \text{RIGHT} & \begin{bmatrix} \text{FIRST} & c \\ \text{REST} & \boxed{2} \end{bmatrix} \\ \text{STATE} & q_1 \end{bmatrix} \end{bmatrix}$$

Codierung: Grundidee

- Kann Berechnung einer Turingmaschine mit zwei Stacks simulieren.
- In HPSG-Featurestrukturen kann man zwei Stacks mit zwei listenwertigen Features darstellen.
 - ▶ geht in TAG, CCG nicht:
dort endliche Wertebereiche für Features
- Daher ist Wortproblem von HPSG unentscheidbar.

Fazit



Parsing mit Featurestrukturen

- Grammatikalität von HPSG-Analysen bisher über Constraints definiert:
 - ▶ FS mit Subtyp von *sign* und korrektem Wert von PHON
 - ▶ alle Knoten sort-resolved und wohlgeformt (d.h. jeder Knoten durch Lexikoneintrag oder spezifischen Typ von Phrase motiviert)
- Heute: CKY-artiger Parser für HPSG.
- Grundideen übertragen sich auf andere unifikationsbasierte Formalismen, z.B. LFG.

Grundidee

- Parsingschema für Bottom-Up-Parser:

$$\frac{[i,j, F_1] \quad [j,k, F_2]}{[i,k, C(\tau) \sqcup [\text{hdtr } F_1] \sqcup [\text{nhdtr } F_2]]} \tau$$

- Einbettende Features `hdtr` und `nhdtr` hängen von Phrasentyp τ ab.
- FS $C(\tau)$ kommt aus Typconstraint für τ . Unifikation kann fehlschlagen; dann Regel nicht anwendbar.

Grundidee

- Parsingschema für Bottom-Up-Parser:

$$\frac{[i,j, F_1] \quad [j,k, F_2]}{[i,k, C(\tau) \sqcup [\text{hdtr } F_1] \sqcup [\text{nhdtr } F_2]]} \tau$$

FS F_2 ist Analyse von Substring j - k

- Einbettende Features hdtr und nhdtr hängen von Phrasentyp τ ab.
- FS $C(\tau)$ kommt aus Typconstraint für τ . Unifikation kann fehlschlagen; dann Regel nicht anwendbar.

Grundidee

- Parsingschema für Bottom-Up-Parser:

$$\frac{[i,j, F_1] \quad [j,k, F_2]}{[i,k, C(\tau) \sqcup [\text{hdtr } F_1] \sqcup [\text{nhdtr } F_2]]} \tau$$

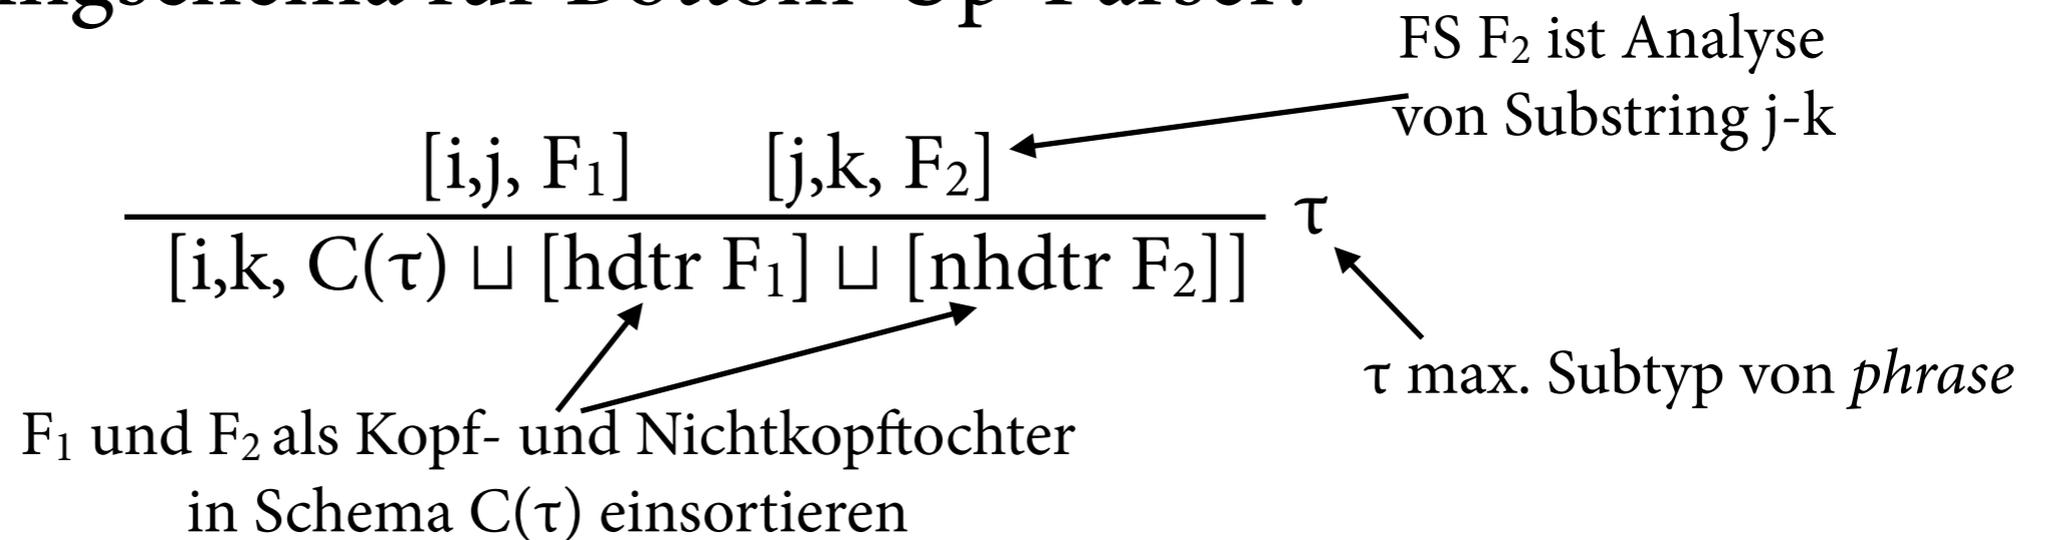
FS F_2 ist Analyse von Substring j - k

τ max. Subtyp von *phrase*

- Einbettende Features hdtr und nhdtr hängen von Phrasentyp τ ab.
- FS $C(\tau)$ kommt aus Typconstraint für τ . Unifikation kann fehlschlagen; dann Regel nicht anwendbar.

Grundidee

- Parsingschema für Bottom-Up-Parser:



- Einbettende Features hdtr und nhdtr hängen von Phrasentyp τ ab.
- FS $C(\tau)$ kommt aus Typconstraint für τ . Unifikation kann fehlschlagen; dann Regel nicht anwendbar.

Beispiel

ein Käsebrot

isst

isst

ein Käsebrot

Beispiel

ein Käsebrot

isst

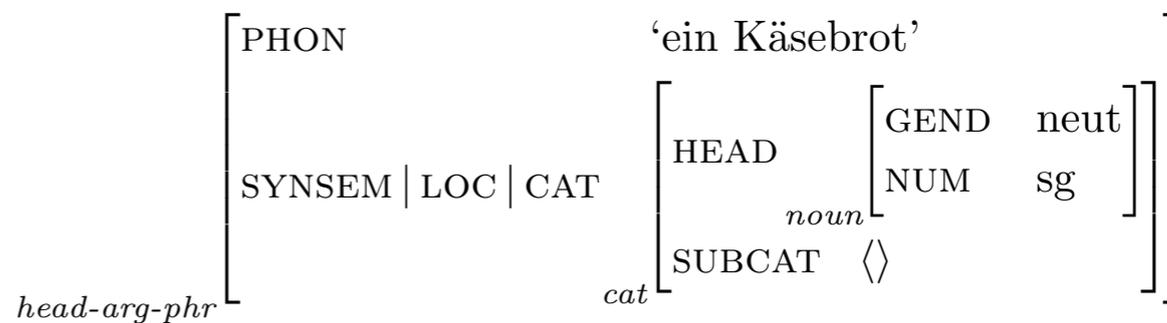
<p><i>word</i> [PHON 'isst' SYNSEM LOC CAT <i>cat</i> [HEAD <i>verb</i> [NUM sg] SUBCAT < NP[<i>nom</i>], NP[<i>acc</i>] >]]</p>	

isst

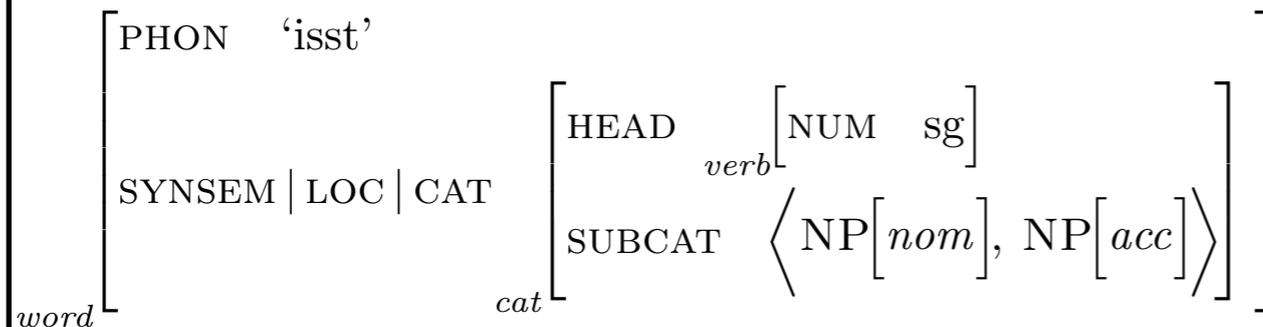
ein Käsebrot

Beispiel

ein Käsebro



isst



isst

ein Käsebro

Algorithmische Fragen

- *Gleichheit testen*: Wenn ich $[i,k,F]$ und $[i,k,G]$ ableiten kann, muss ich effizient überprüfen, ob F und G die gleiche Featurestruktur sind.
 - ▶ Wenn nein, muss neues Item auf Agenda eingetragen werden.
- *Unifikation*: Muss $C(\tau) \sqcup [\text{hdtr } F_1] \sqcup [\text{nhdtr } F_2]$ effizient ausrechnen.
- Mindestens 90% der Laufzeit eines unifikationsbasierten Parsers gehen in diese zwei Funktionen.

Subsumption von TFS

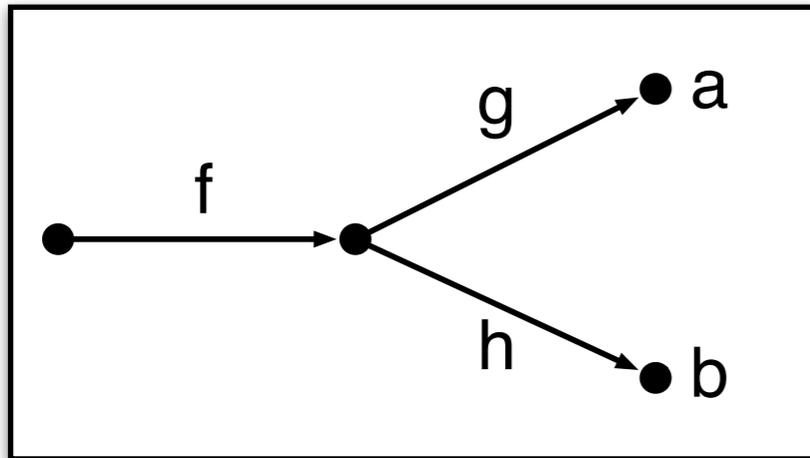
- TFS F *subsumiert* TFS G ($F \sqsubseteq G$), wenn alle Informationen in F auch in G vorhanden sind:
 - ▶ Pfade: $F(\pi)$ definiert $\Rightarrow G(\pi)$ definiert
 - ▶ Reentrancy: $F(\pi) = F(\pi') \Rightarrow G(\pi) = G(\pi')$
 - ▶ Subtypen: $\theta_F(F(\pi)) \sqsubseteq \theta_G(G(\pi))$
- *Unifikation*: $F = F_1 \sqcup F_2$ ist FS (falls existiert), so dass
 - ▶ subsumiert beide: $F_1 \sqsubseteq F, F_2 \sqsubseteq F$
 - ▶ erfindet nichts dazu: für alle F' mit $F_1 \sqsubseteq F', F_2 \sqsubseteq F'$ gilt $F \sqsubseteq F'$.

Subsumption testen

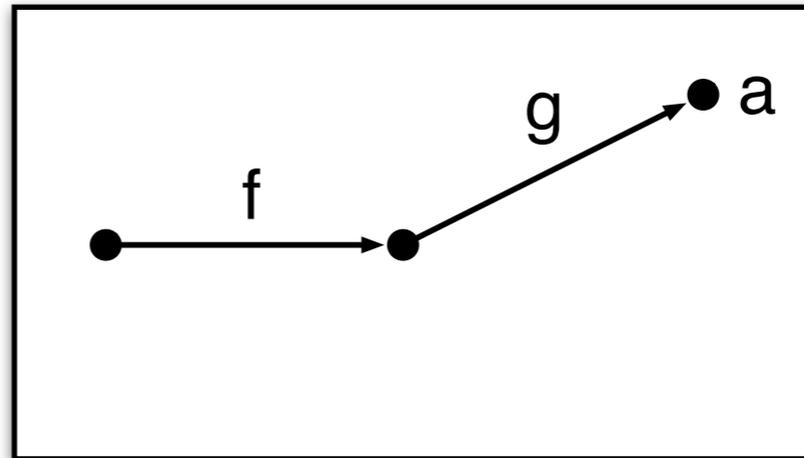
- Algorithmus von Malouf et al. 2000: Gegeben F und G , teste gleichzeitig, ob $F \sqsubseteq G$ und ob $G \sqsubseteq F$.
 - ▶ Spezialfall: $F = G$ gdw. $F \sqsubseteq G$ und $G \sqsubseteq F$.
- Traversiere beide FS rekursiv.
 - ▶ Speichere für jeden Knoten u in F einen *Pointer* zu einem Knoten v in G , und umgekehrt.
 - ▶ Erkenne $F \not\sqsubseteq G$, falls: u mehr Features hat als v ; Typen von u , v nicht zusammenpassen; u beim zweiten Besuch schon einen Pointer zu einem Knoten $\neq v$ hatte (und umgekehrt).

Beispiel

F_1



F_2

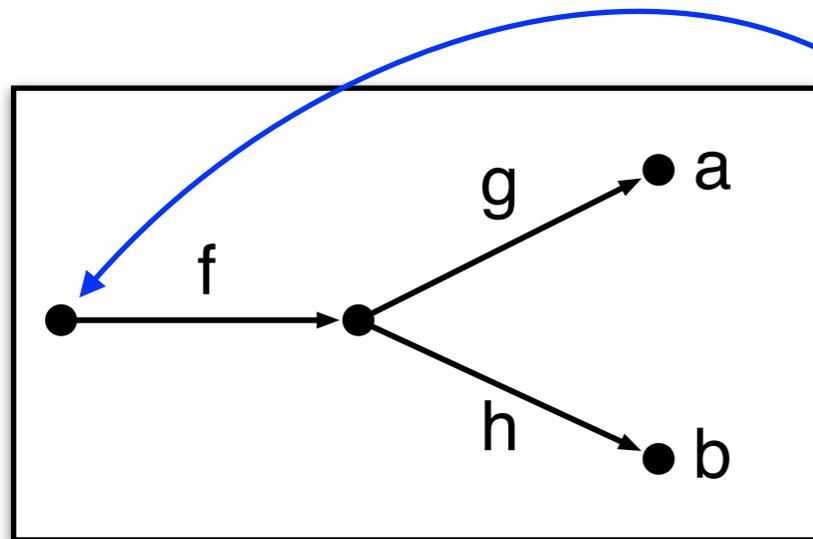


$F_1 \sqsubseteq F_2 ?$

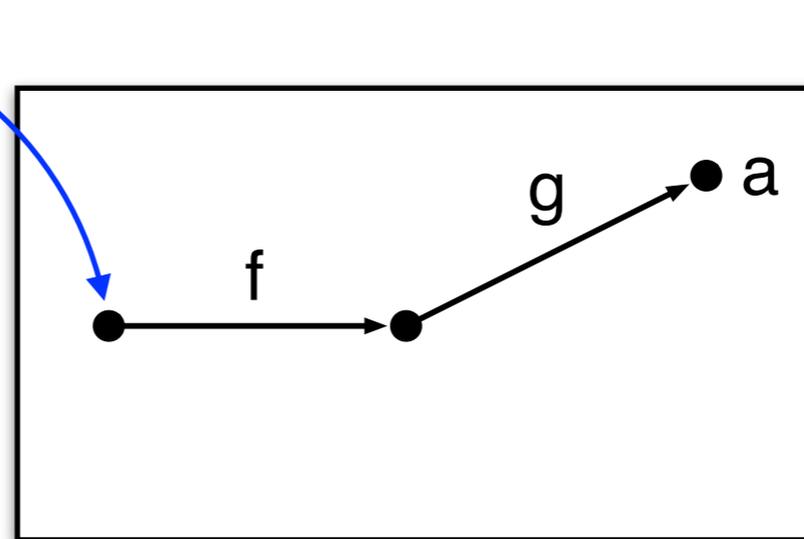
$F_2 \sqsubseteq F_1 ?$

Beispiel

F_1



F_2

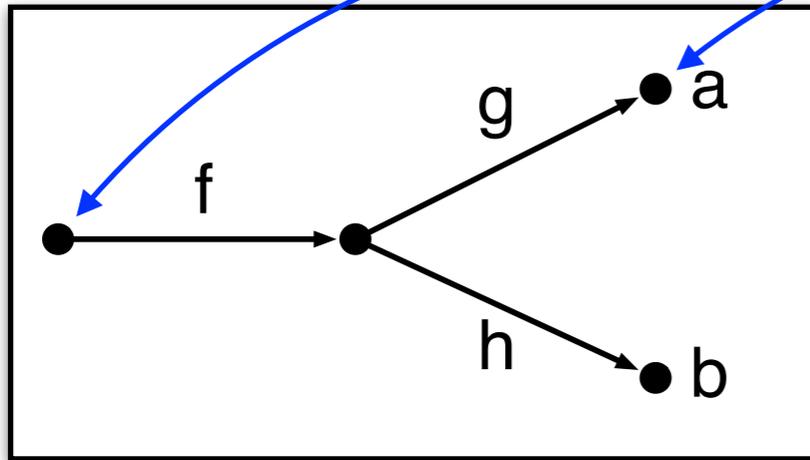


$F_1 \sqsubseteq F_2?$

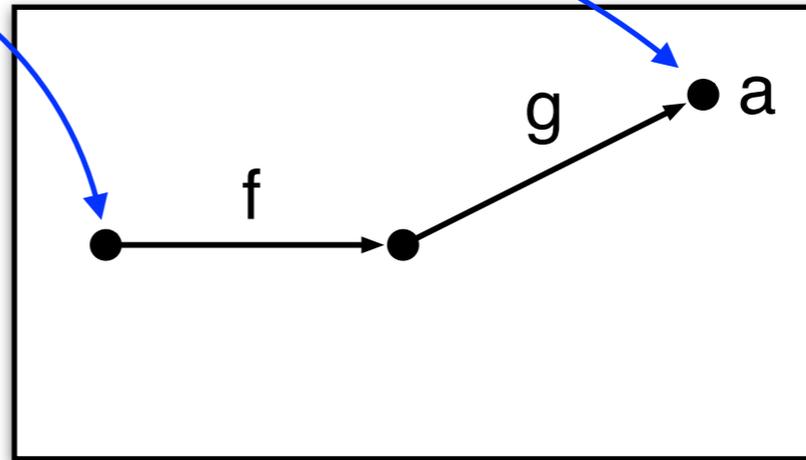
$F_2 \sqsubseteq F_1?$

Beispiel

F_1



F_2



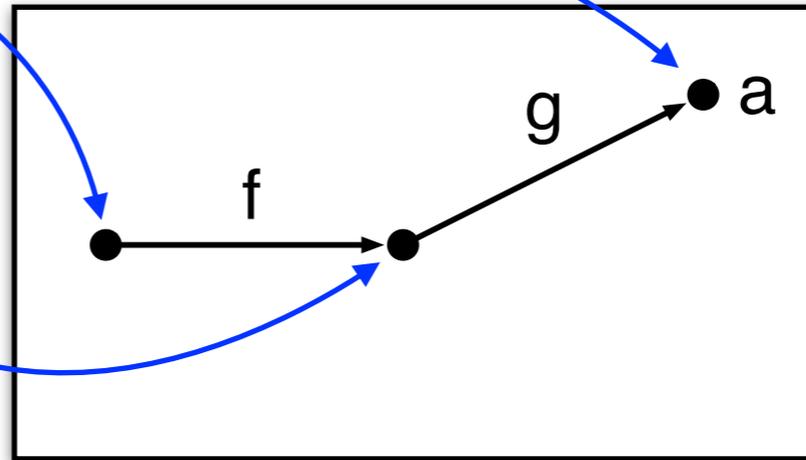
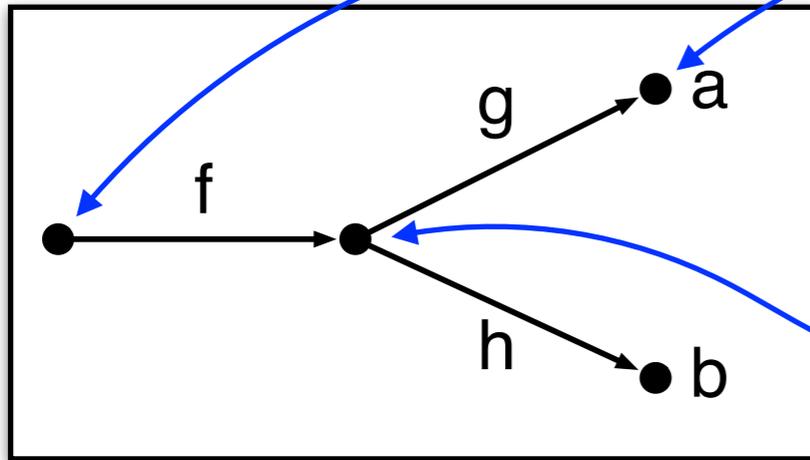
$F_1 \sqsubseteq F_2?$

$F_2 \sqsubseteq F_1?$

Beispiel

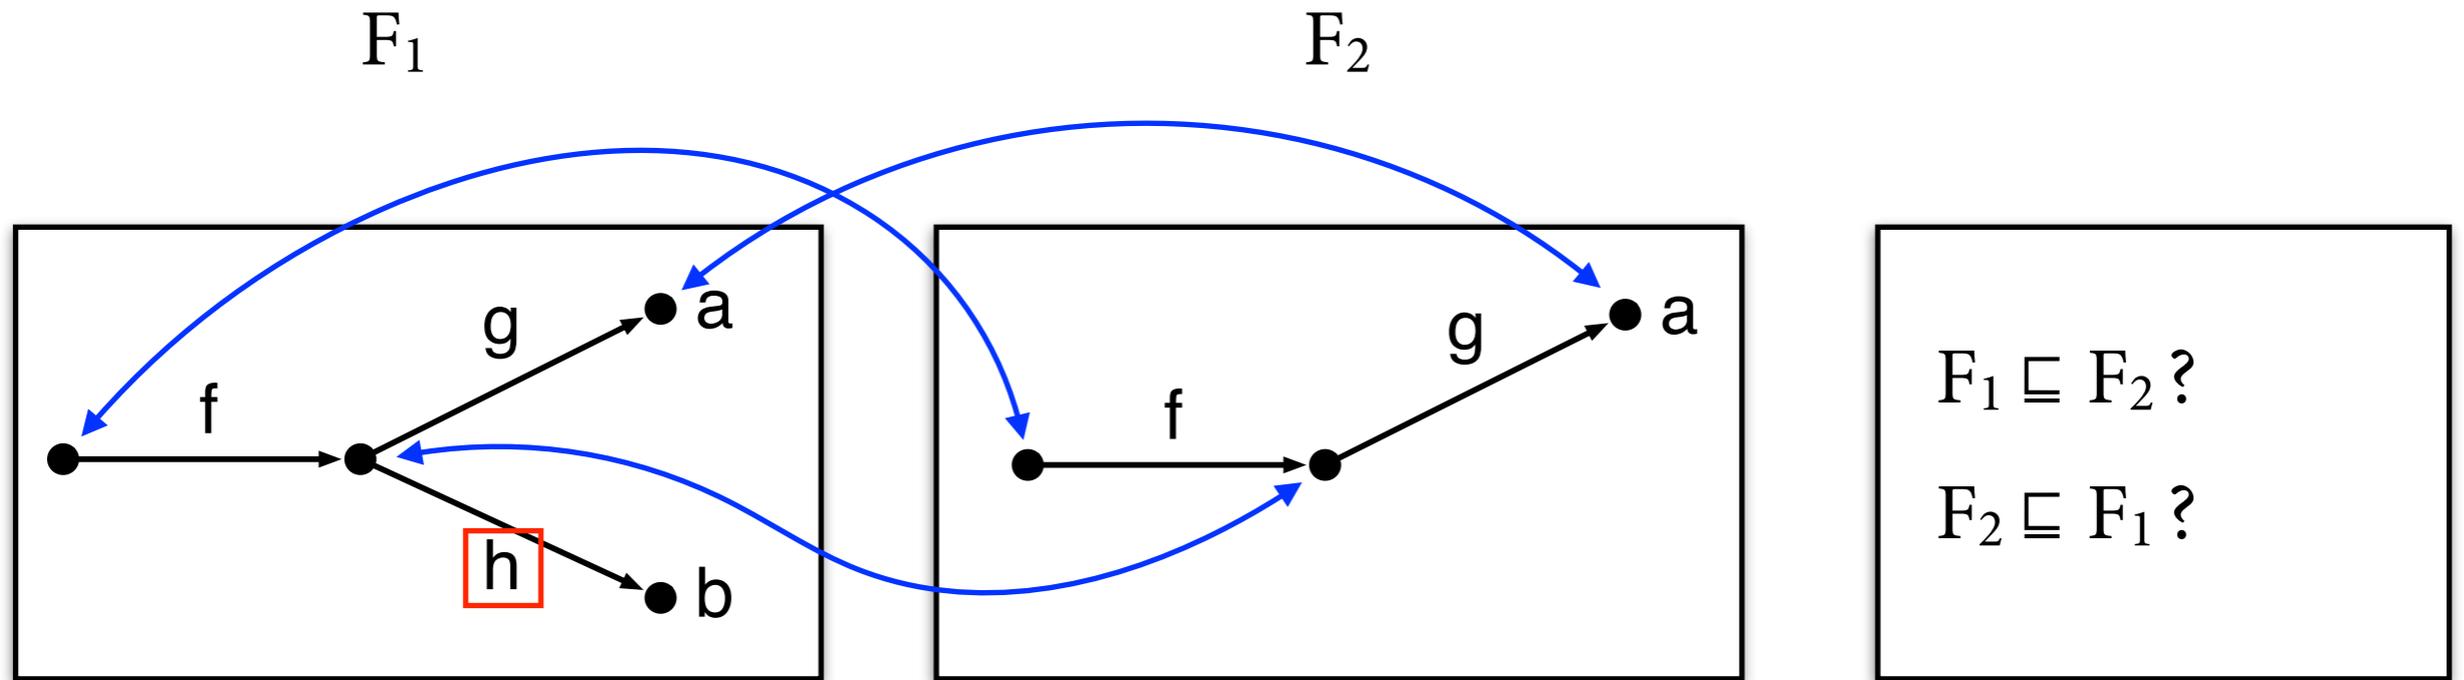
F_1

F_2

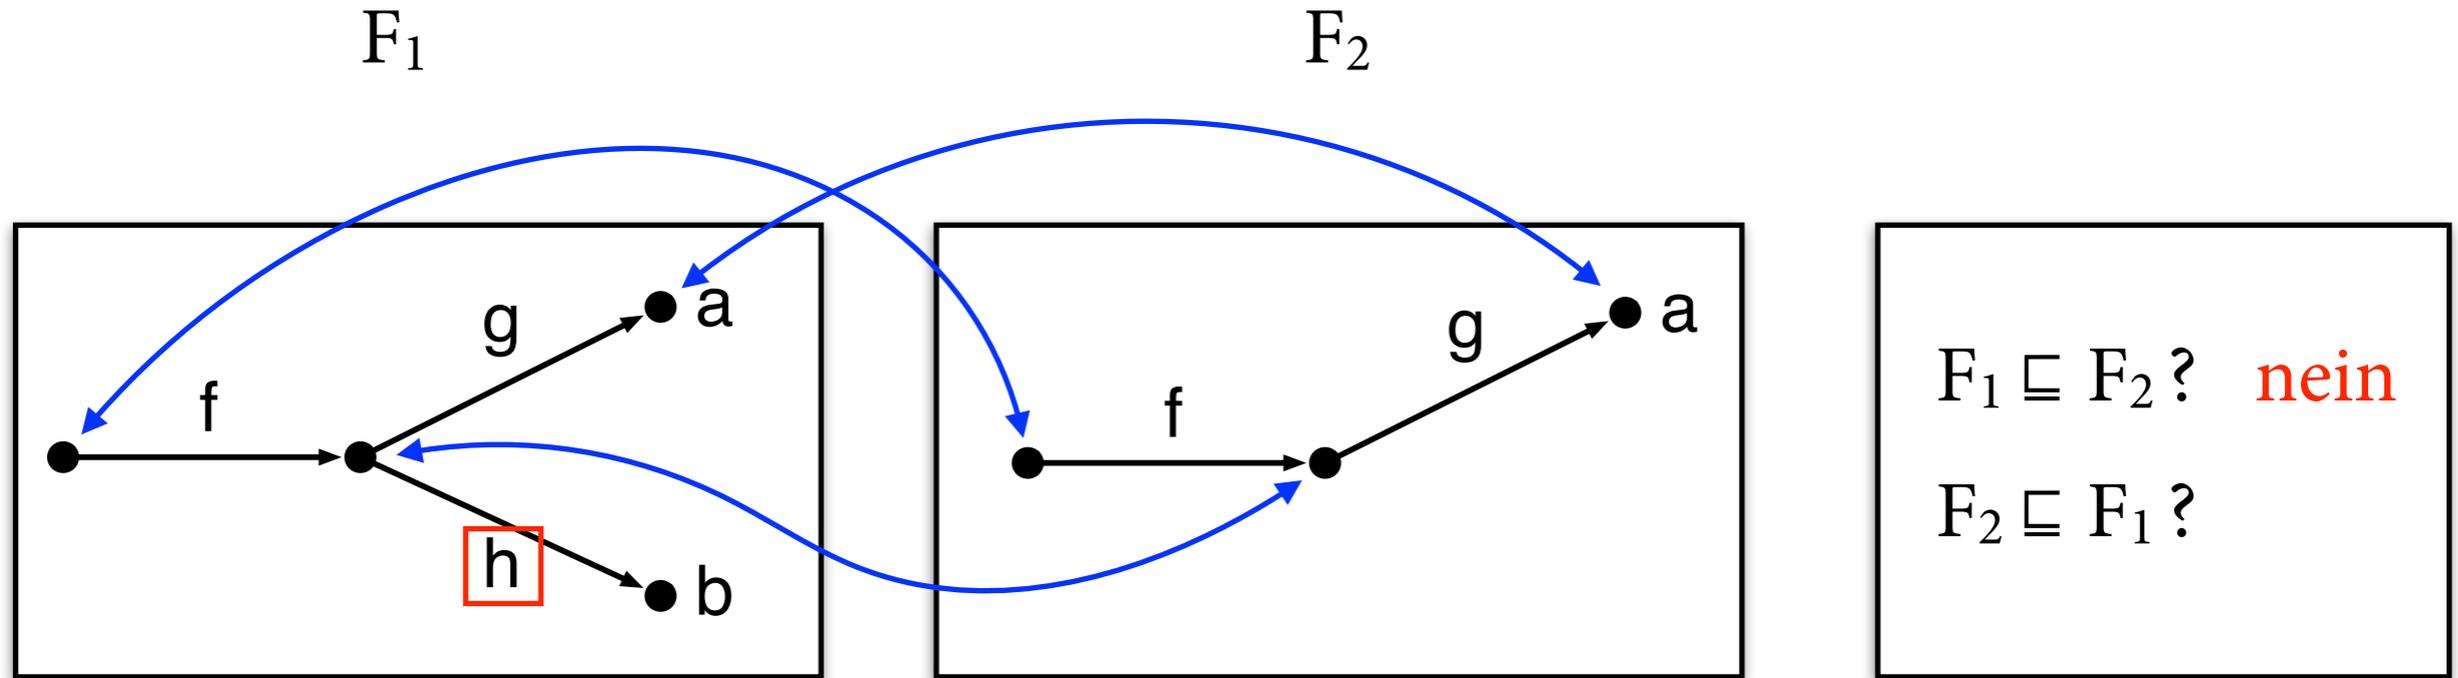


$F_1 \sqsubseteq F_2?$
 $F_2 \sqsubseteq F_1?$

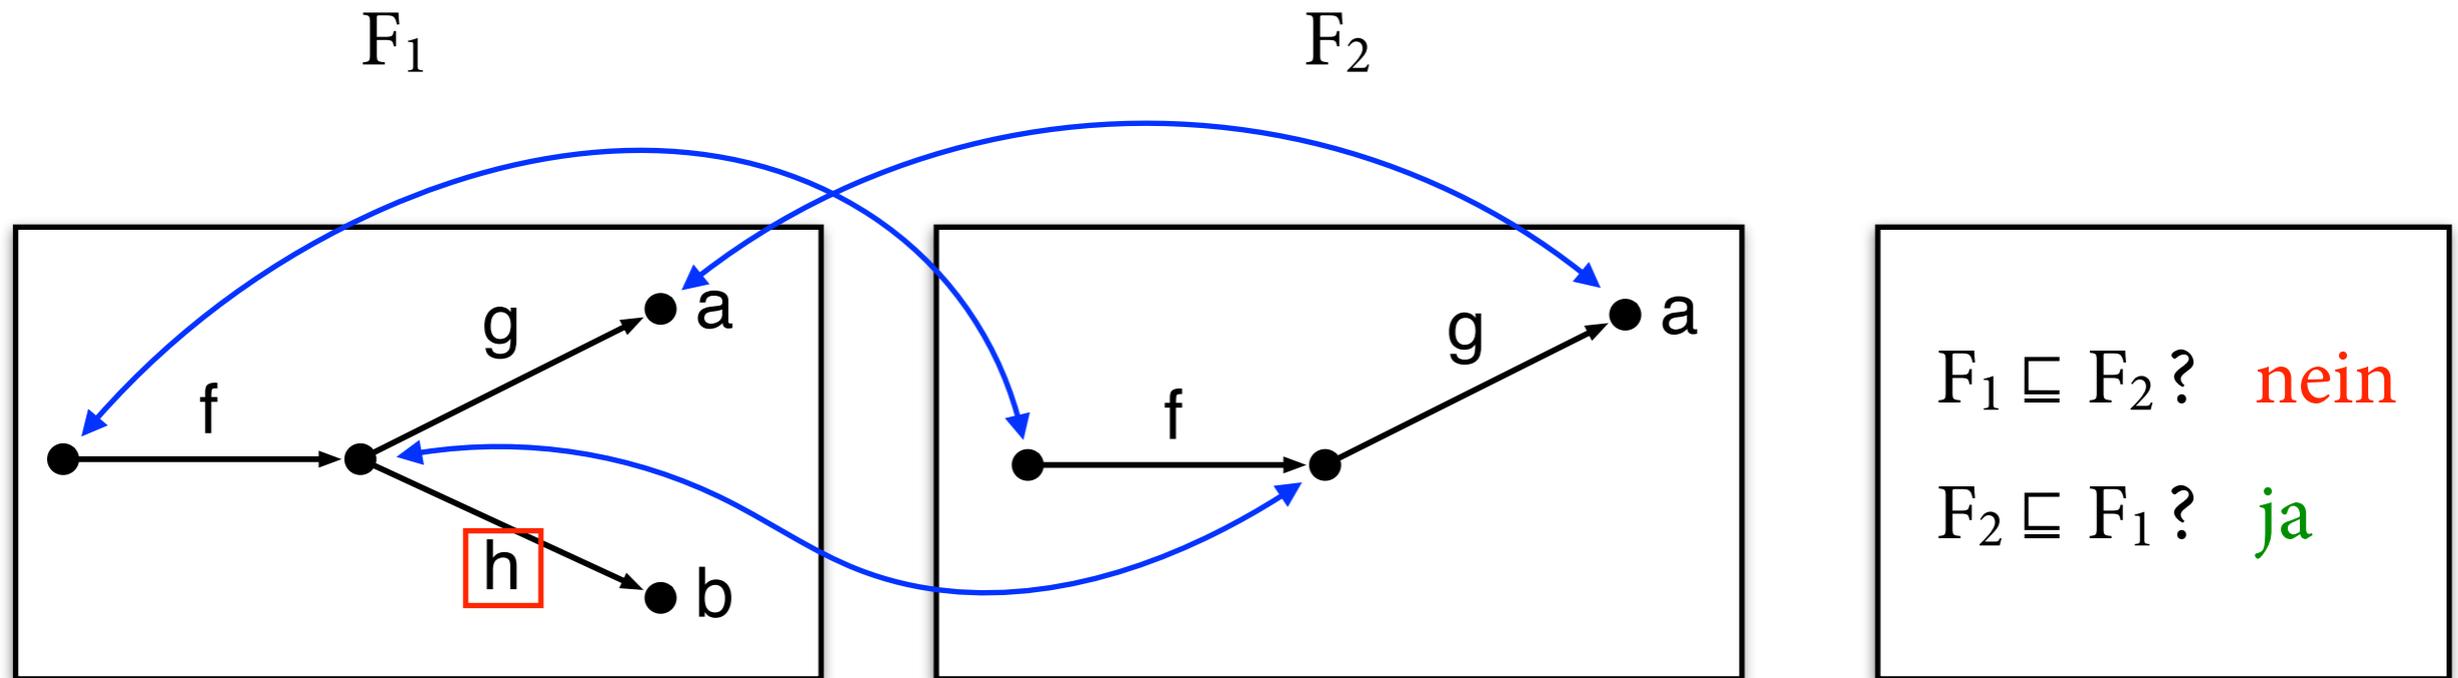
Beispiel



Beispiel



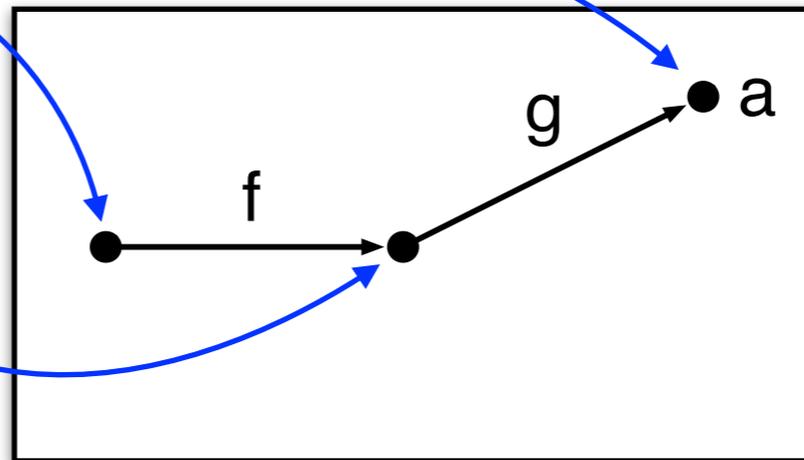
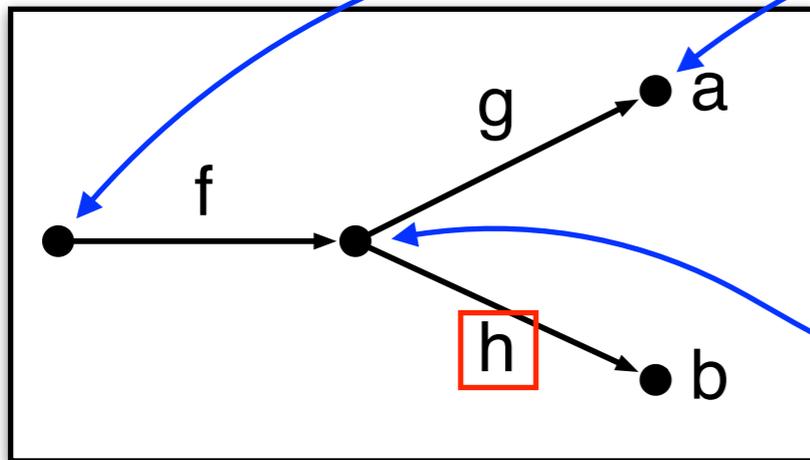
Beispiel



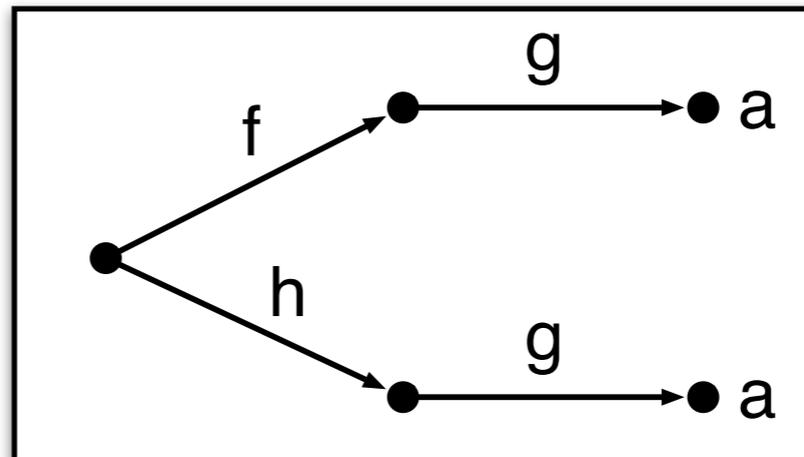
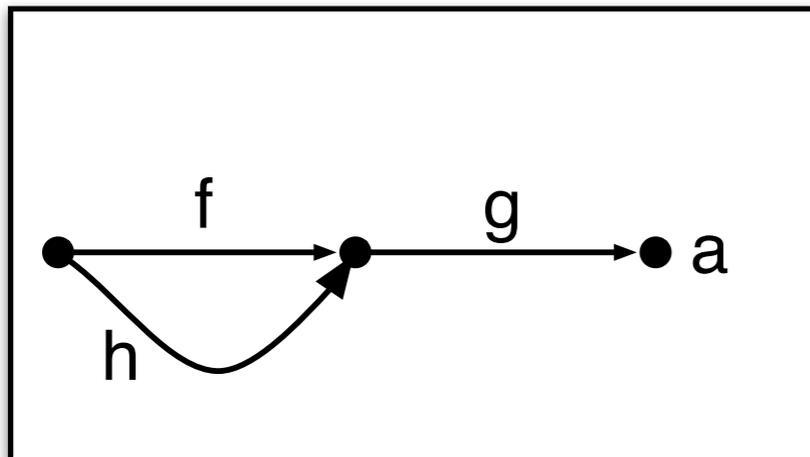
Beispiel

F_1

F_2



$F_1 \sqsubseteq F_2$? **nein**
 $F_2 \sqsubseteq F_1$? **ja**

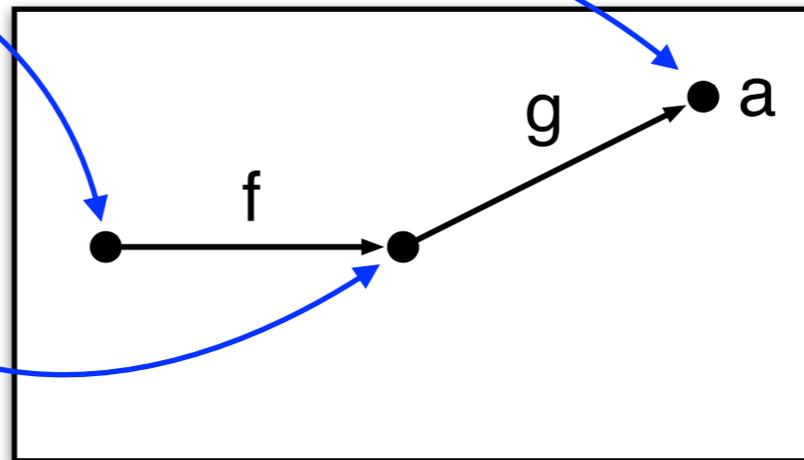
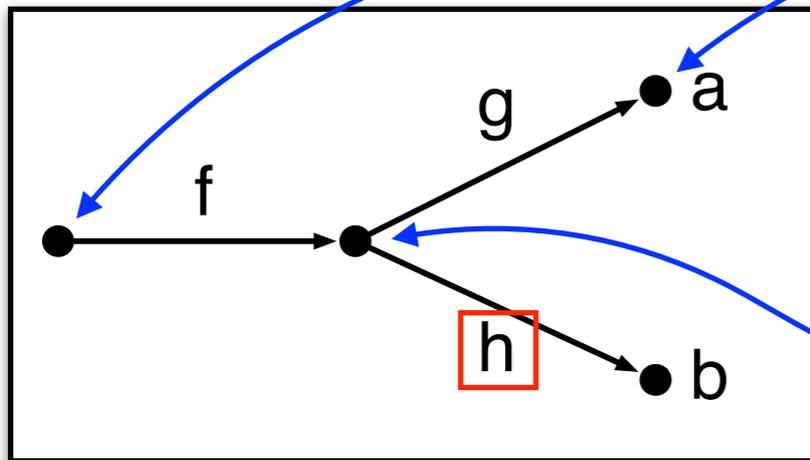


$F_1 \sqsubseteq F_2$?
 $F_2 \sqsubseteq F_1$?

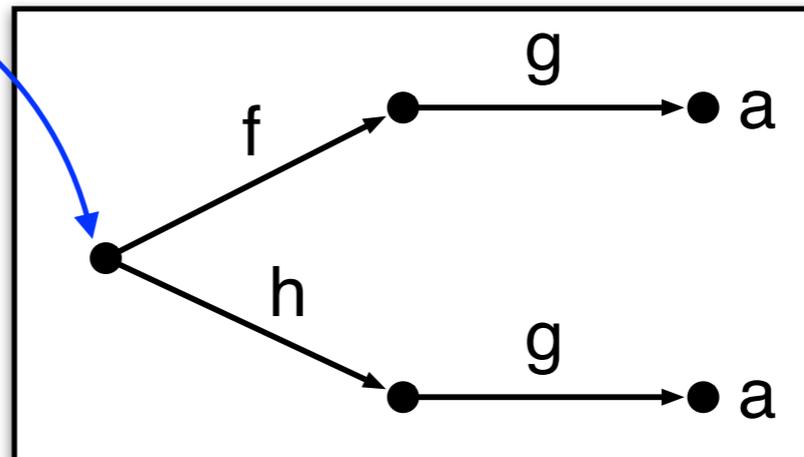
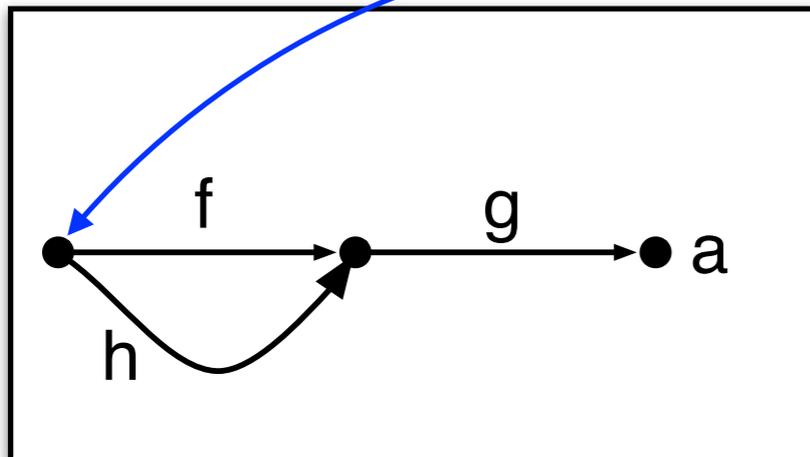
Beispiel

F_1

F_2



$F_1 \sqsubseteq F_2$? **nein**
 $F_2 \sqsubseteq F_1$? **ja**

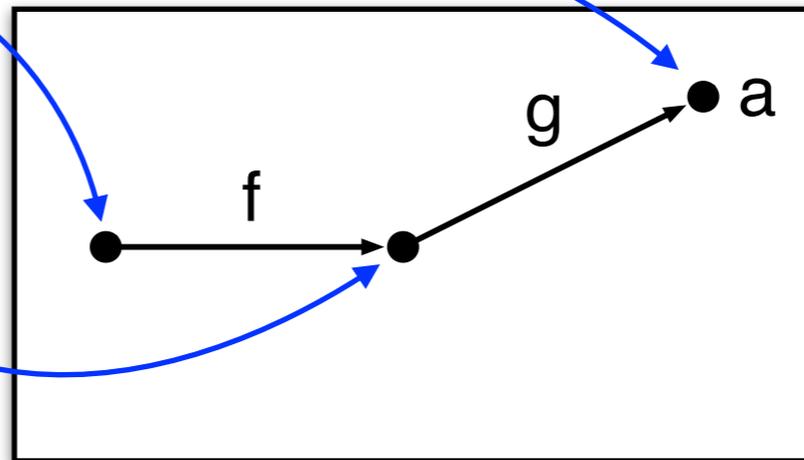
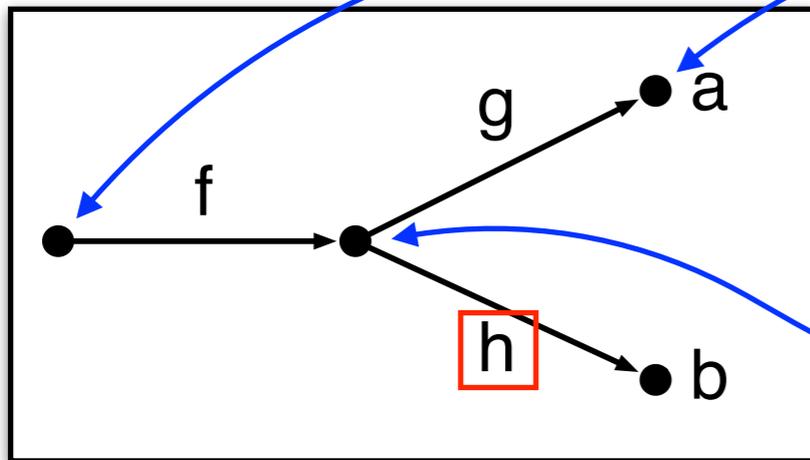


$F_1 \sqsubseteq F_2$?
 $F_2 \sqsubseteq F_1$?

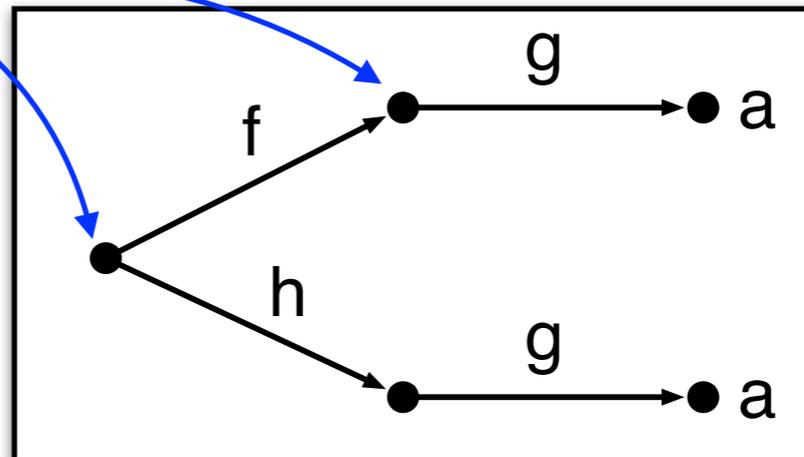
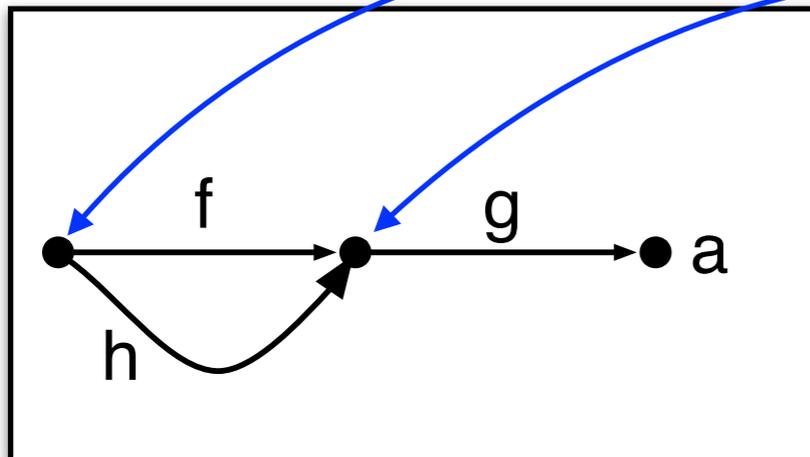
Beispiel

F_1

F_2



$F_1 \sqsubseteq F_2$? **nein**
 $F_2 \sqsubseteq F_1$? **ja**

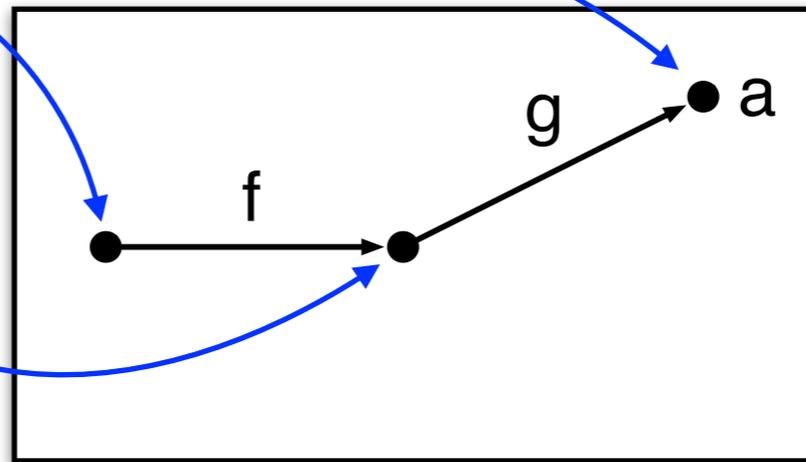
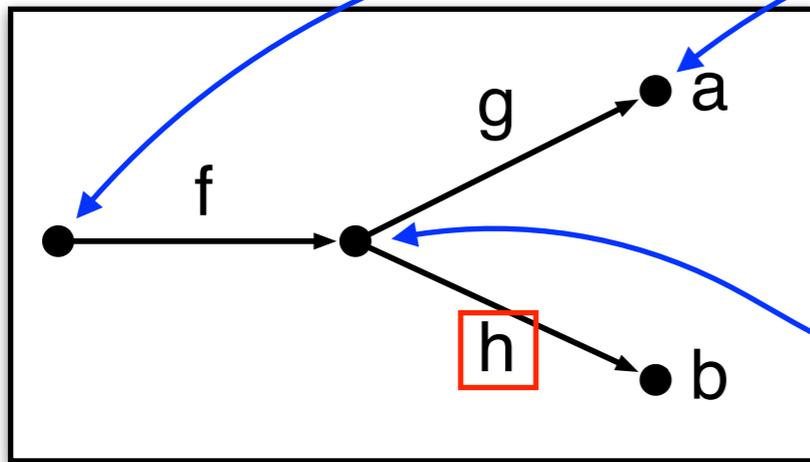


$F_1 \sqsubseteq F_2$?
 $F_2 \sqsubseteq F_1$?

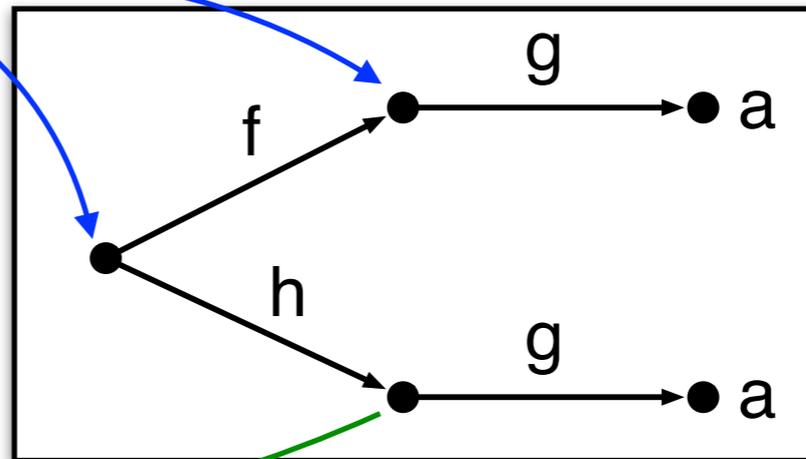
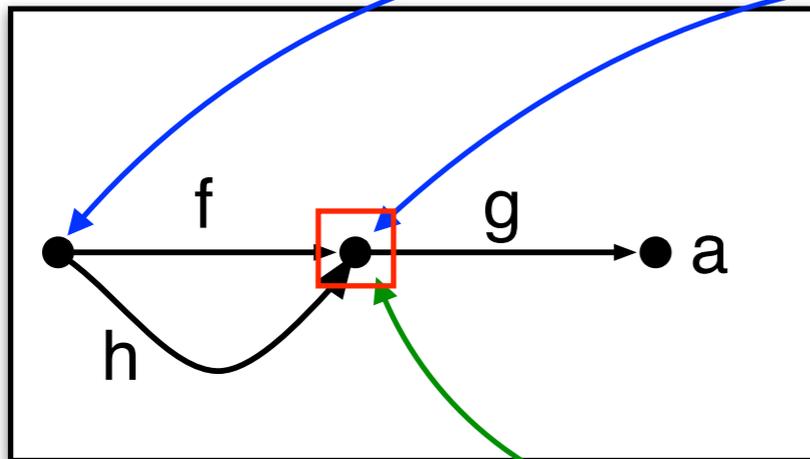
Beispiel

F_1

F_2



$F_1 \sqsubseteq F_2$? **nein**
 $F_2 \sqsubseteq F_1$? **ja**

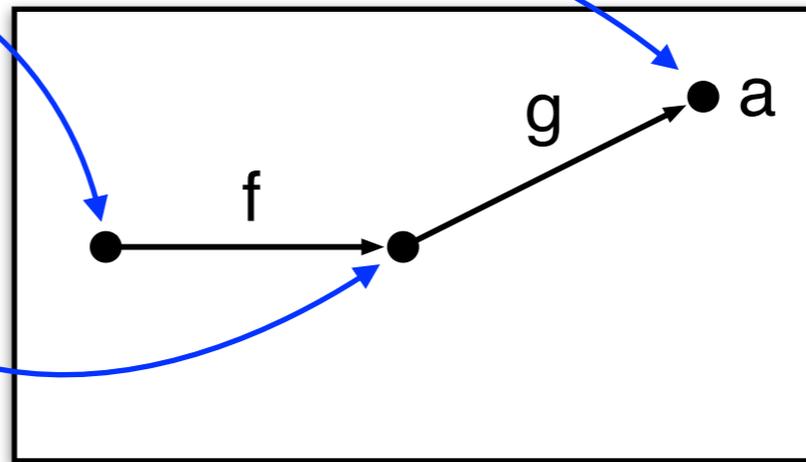
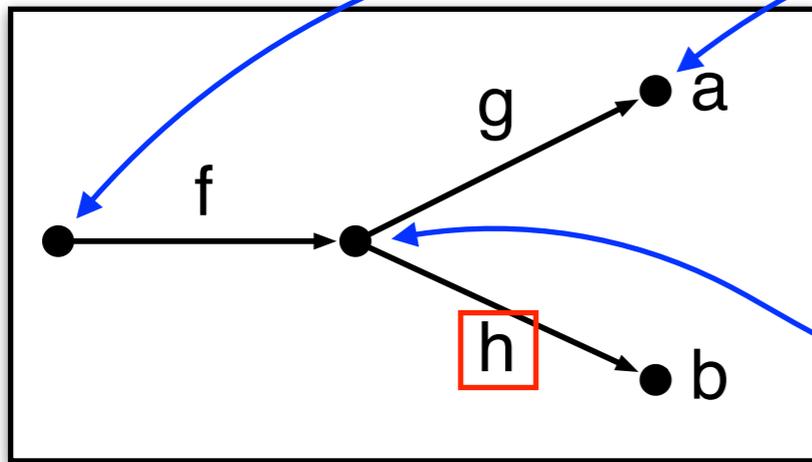


$F_1 \sqsubseteq F_2$? **nein**
 $F_2 \sqsubseteq F_1$?

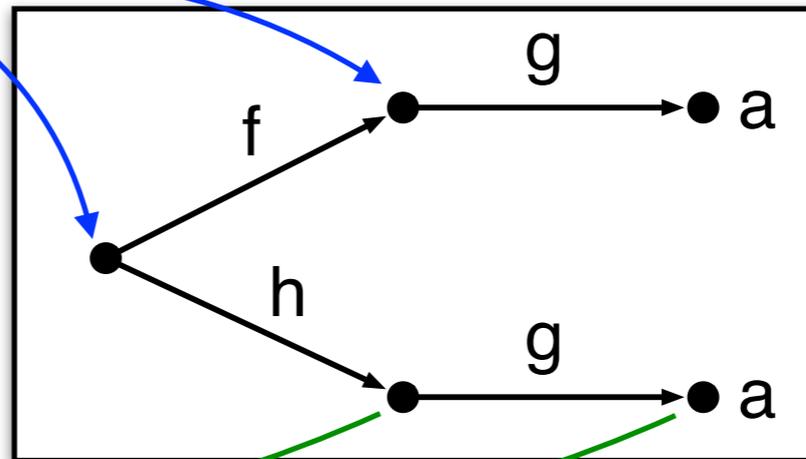
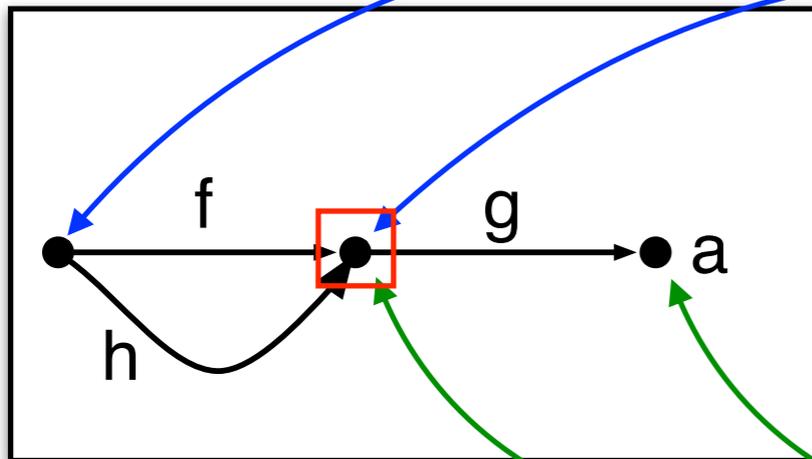
Beispiel

F_1

F_2



$F_1 \sqsubseteq F_2$? **nein**
 $F_2 \sqsubseteq F_1$? **ja**

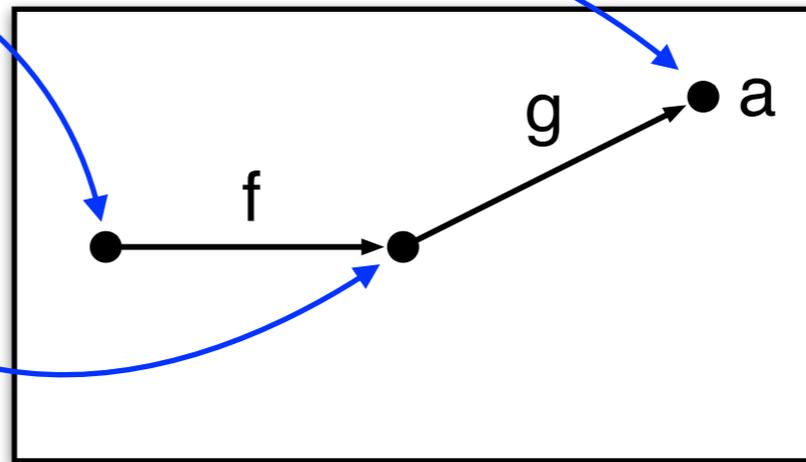
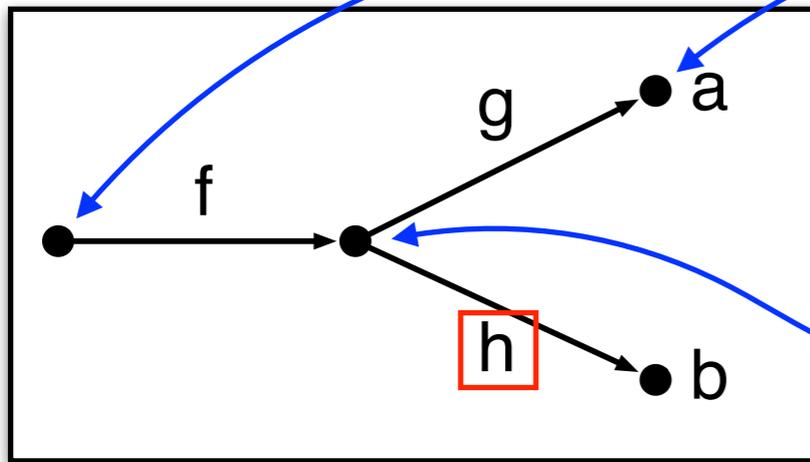


$F_1 \sqsubseteq F_2$? **nein**
 $F_2 \sqsubseteq F_1$?

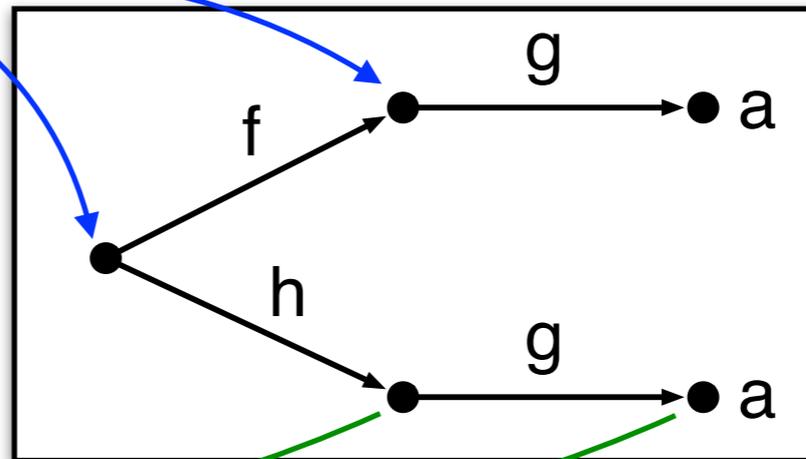
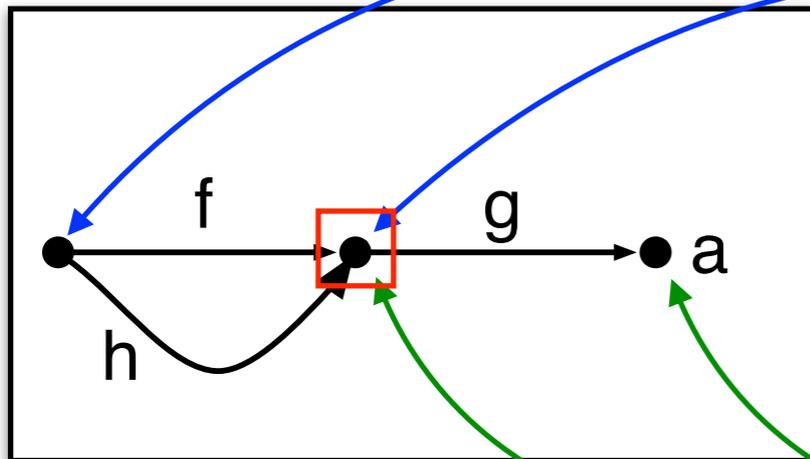
Beispiel

F_1

F_2



$F_1 \sqsubseteq F_2$? **nein**
 $F_2 \sqsubseteq F_1$? **ja**



$F_1 \sqsubseteq F_2$? **nein**
 $F_2 \sqsubseteq F_1$? **ja**

Unifikation

- Grundidee: Rekursiv durch Featurestrukturen gehen und Pointer auf korrespondierende Knoten setzen.
 - ▶ Dabei wird Inhalt von F_2 nach F_1 kopiert.
 - ▶ In ähnlicher Weise wie bei Subsumption auf Konsistenz der Information testen.
- Rolle des Kopierens:
 - ▶ Im worst case kopiert Algorithmus fast die ganze FS F_2 , bevor er erkennt, dass die FS nicht unifiziert werden können.
 - ▶ Schnellere Algorithmen verzögern und vermeiden Kopieren so gut wie möglich, z.B. Tomabechi (1991).

Unifikationsalgorithmus

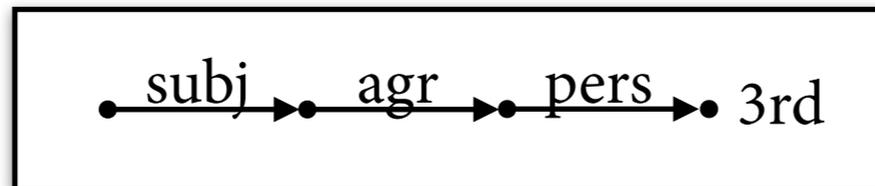
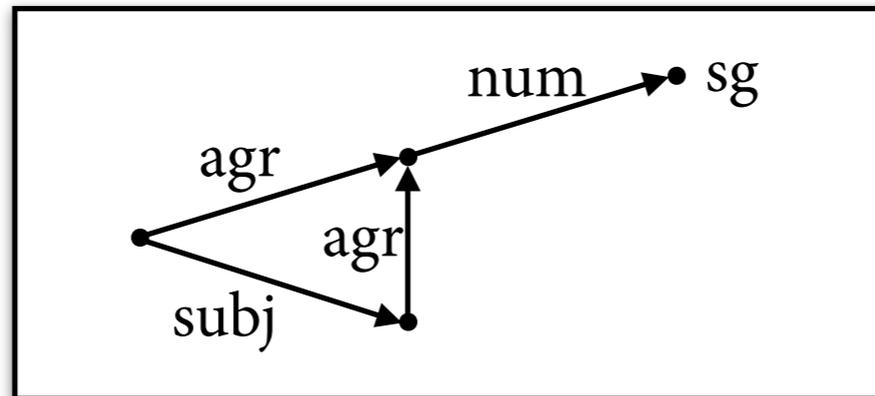
```
function UNIFY(f1, f2) returns fstructure or failure

f1-real ← Real contents of f1
f2-real ← Real contents of f2

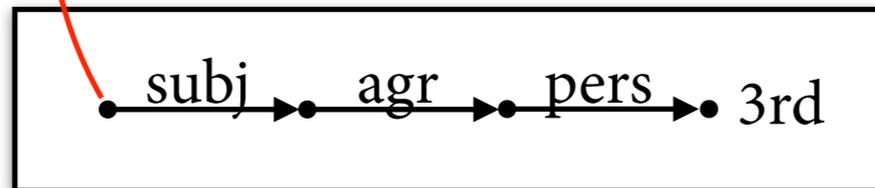
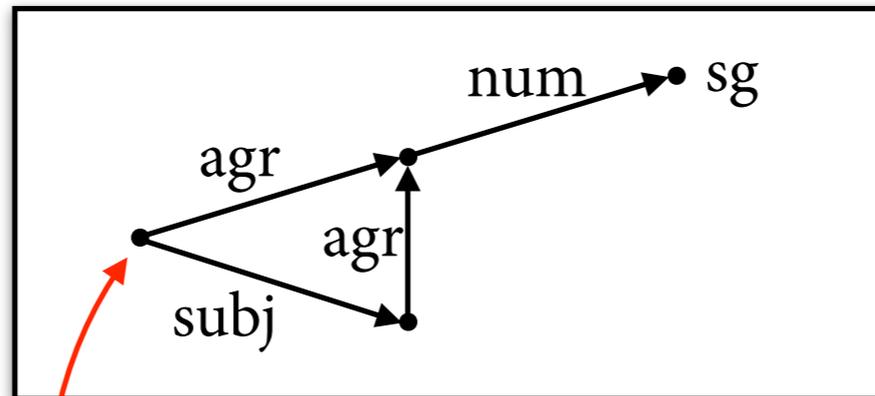
if f1-real is null then
  f1.pointer ← f2
  return f2
else if f2-real is null then
  f2.pointer ← f1
  return f1
else if f1-real and f2-real are identical then
  f1.pointer ← f2
  return f2
else if both f1-real and f2-real are complex feature structures then
  f2.pointer ← f1
  for each feature in f2-real do
    other-feature ← Find or create
                        a feature corresponding to feature in f1-real
    if UNIFY(feature.value, other-feature.value) returns failure then
      return failure
  return f1
else return failure
```

(aus, aber nicht von, Jurafsky & Martin)

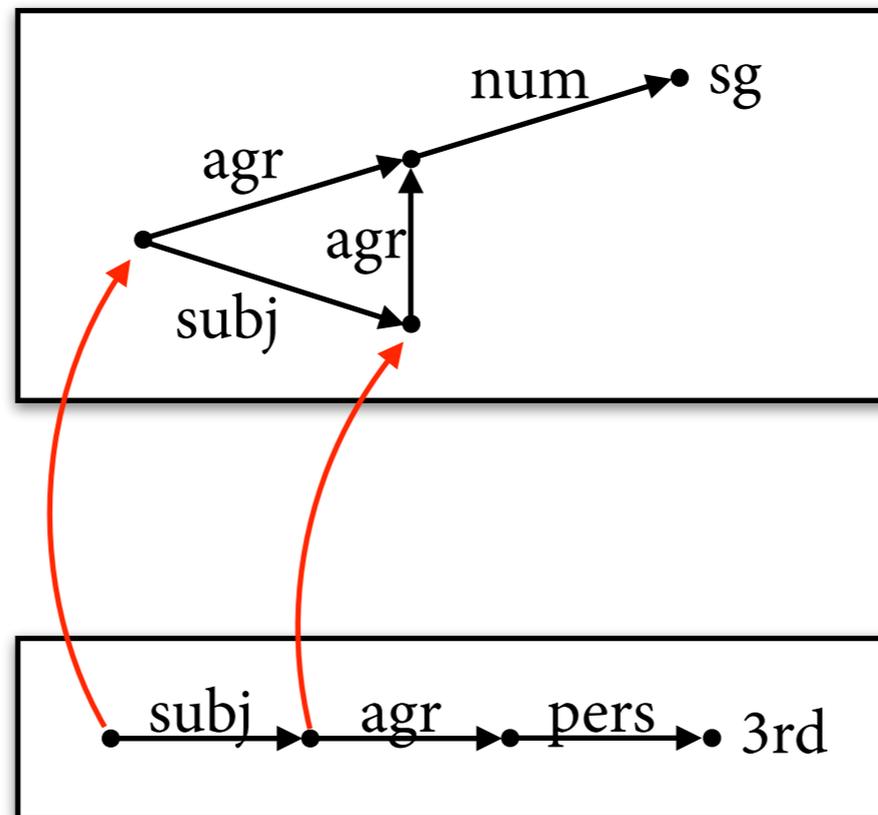
Beispiel



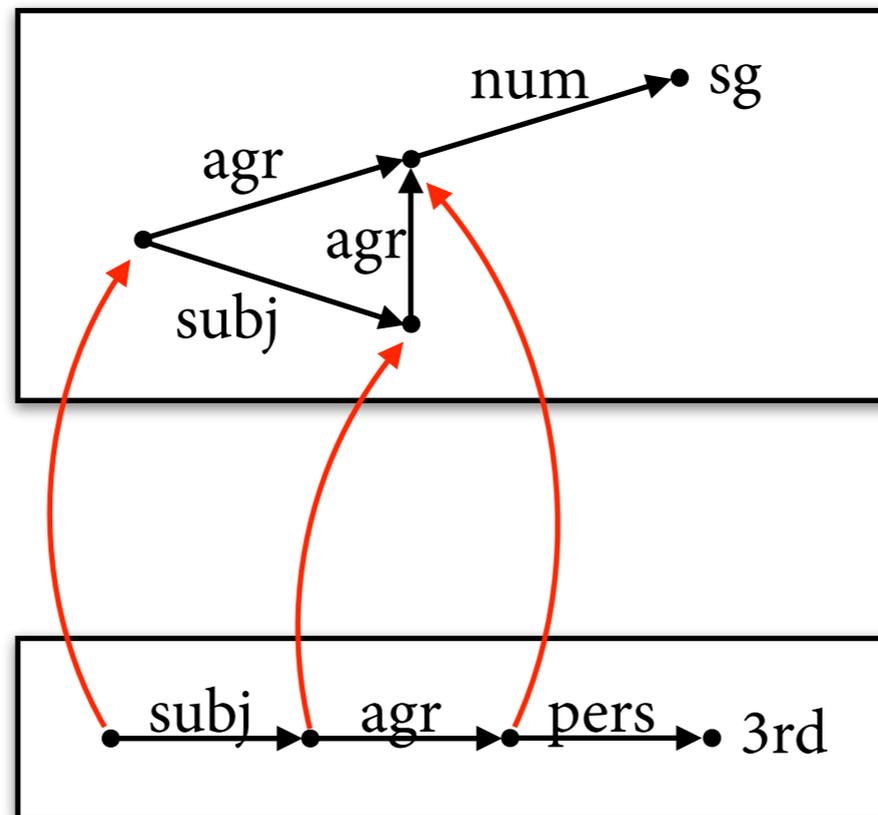
Beispiel



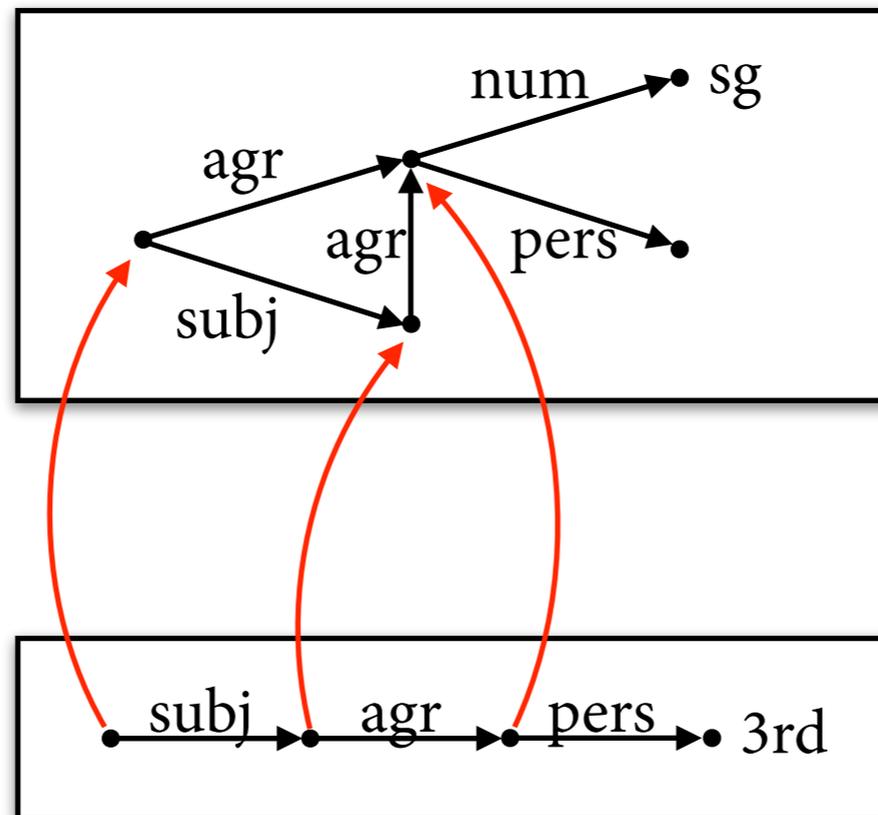
Beispiel



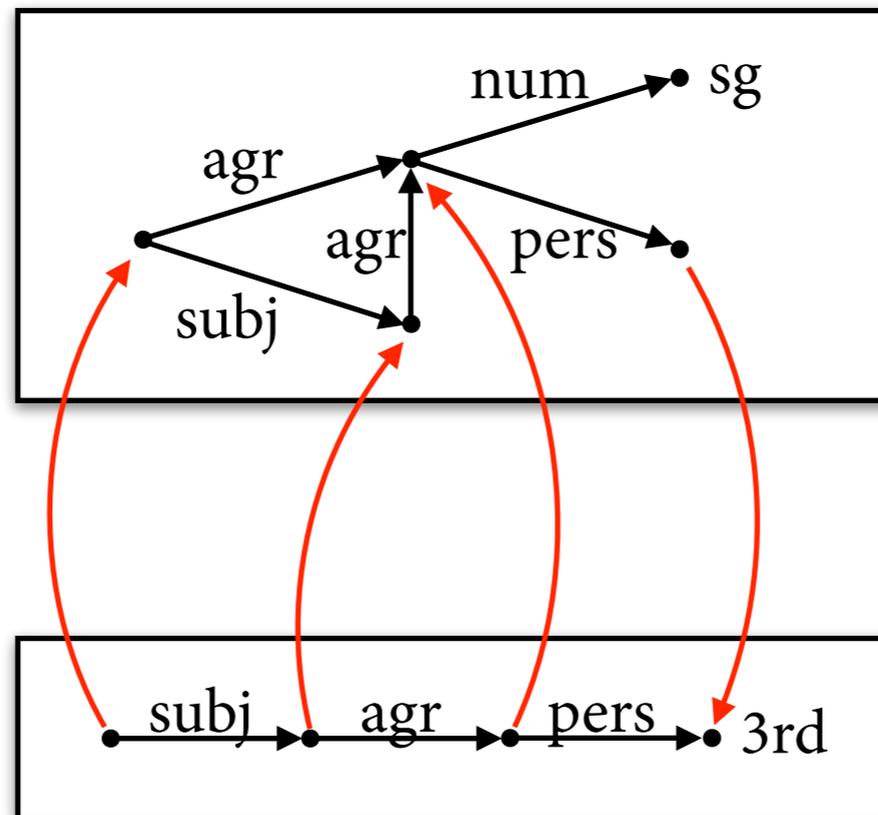
Beispiel



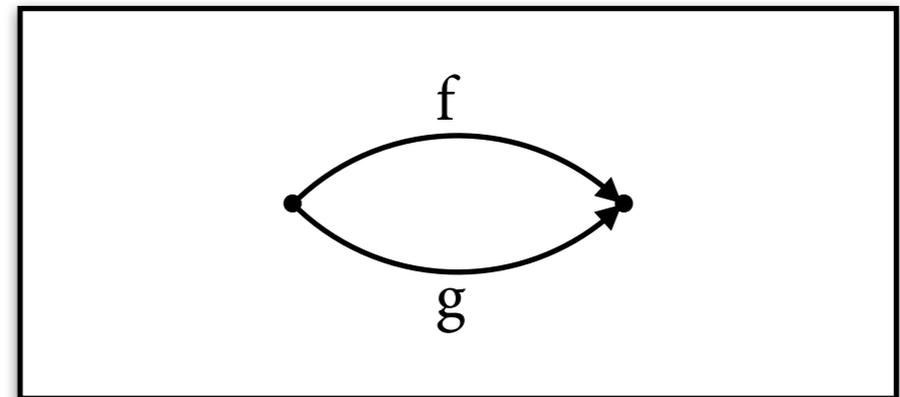
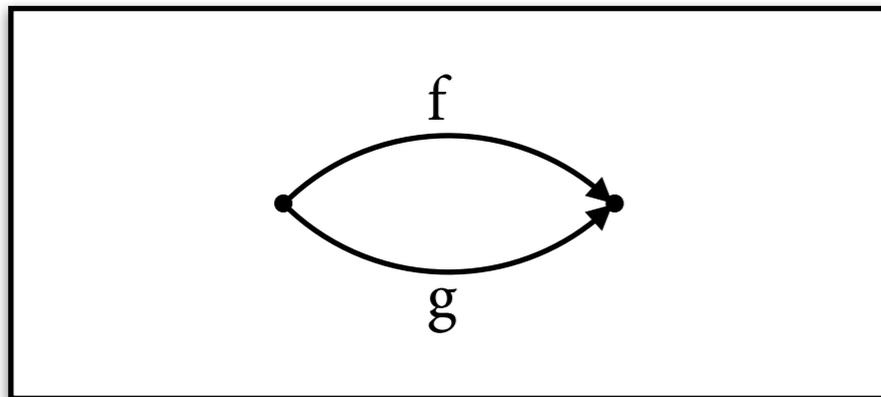
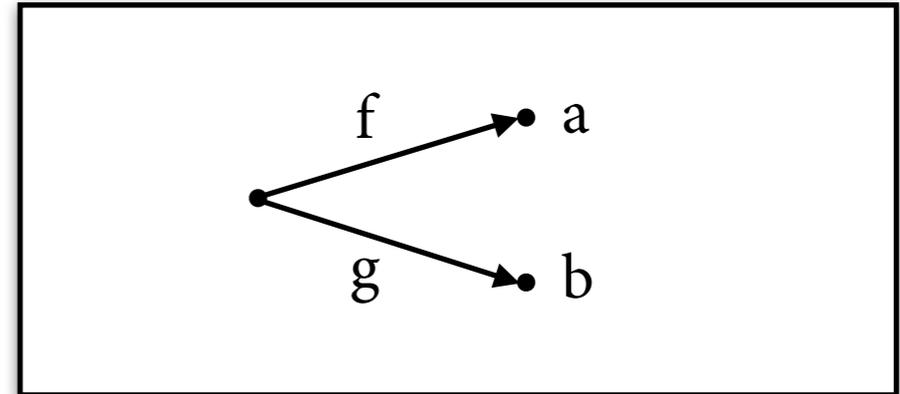
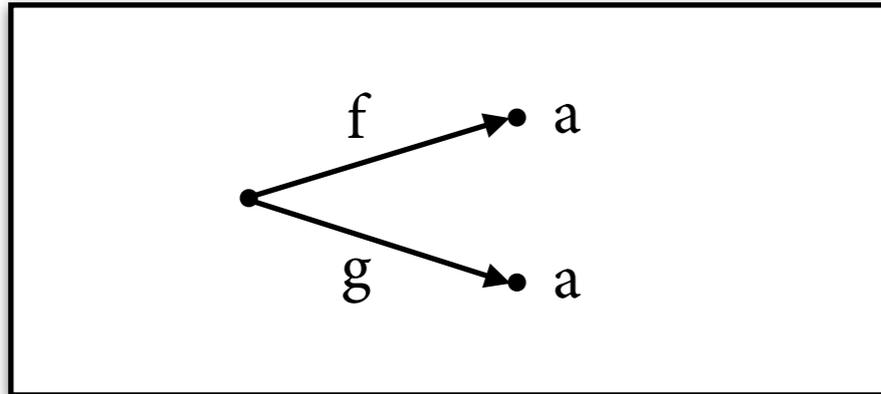
Beispiel



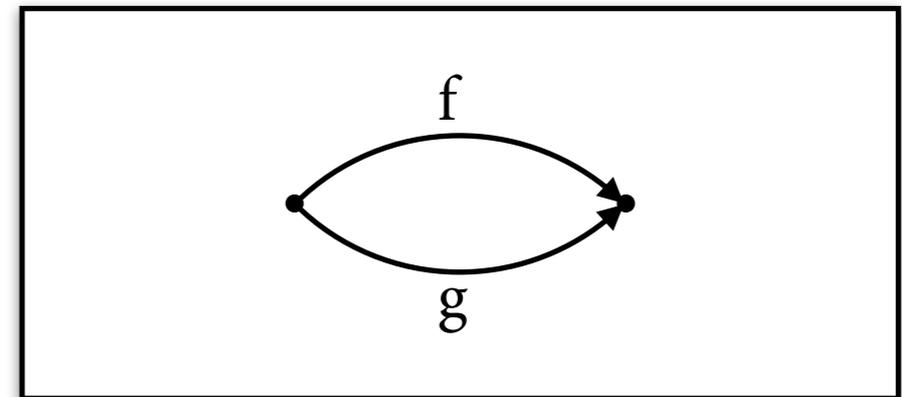
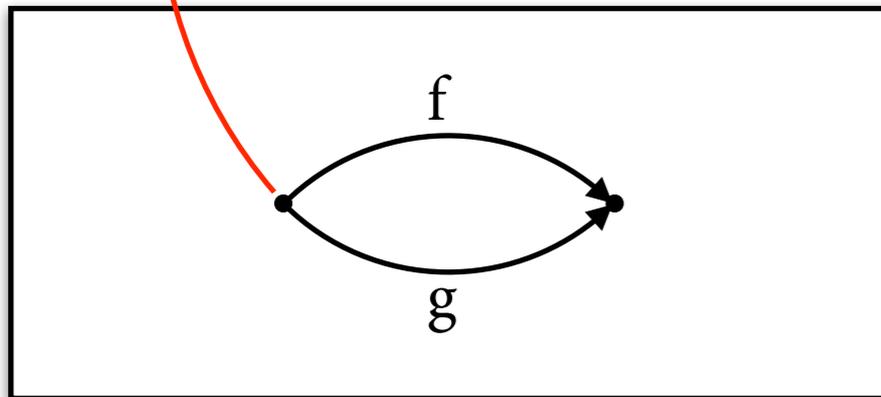
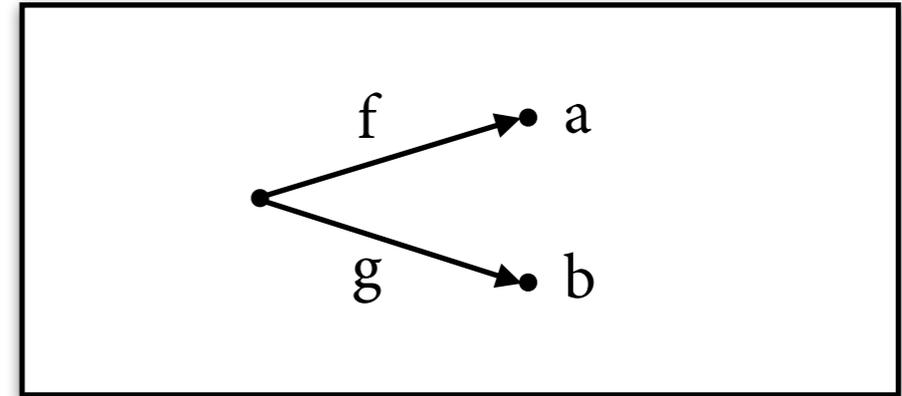
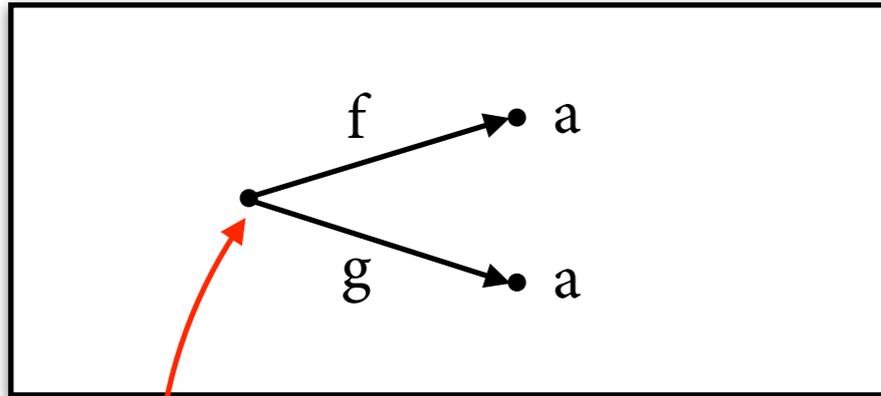
Beispiel



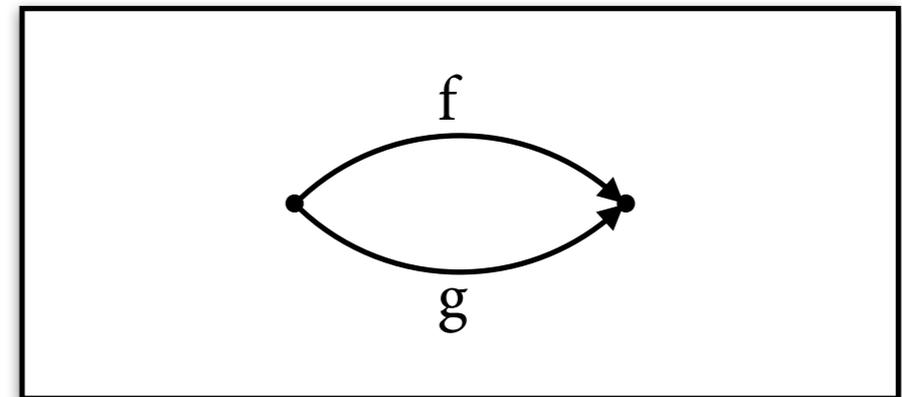
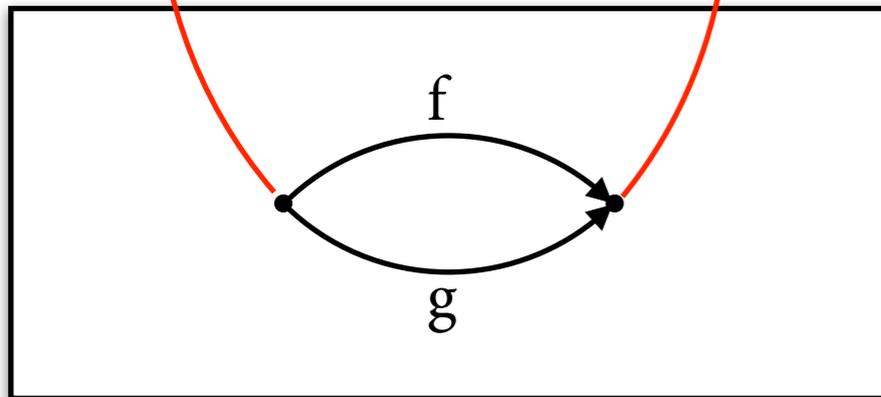
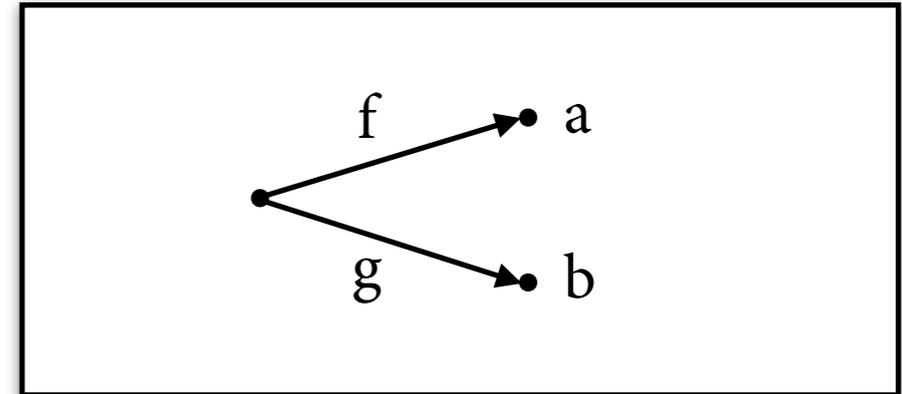
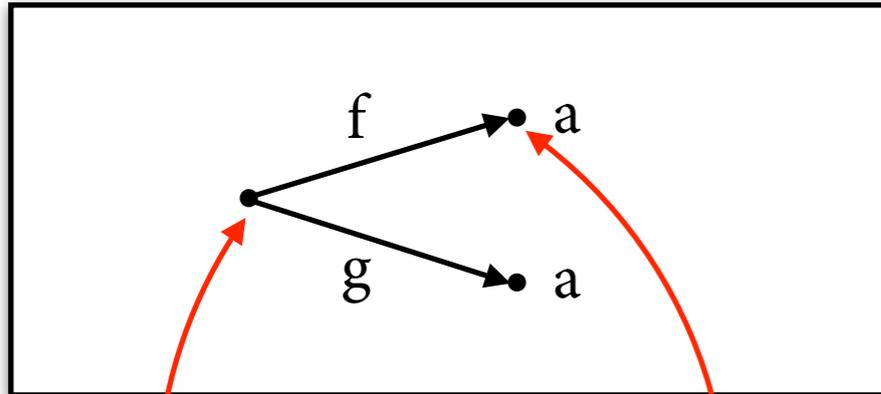
Beispiel



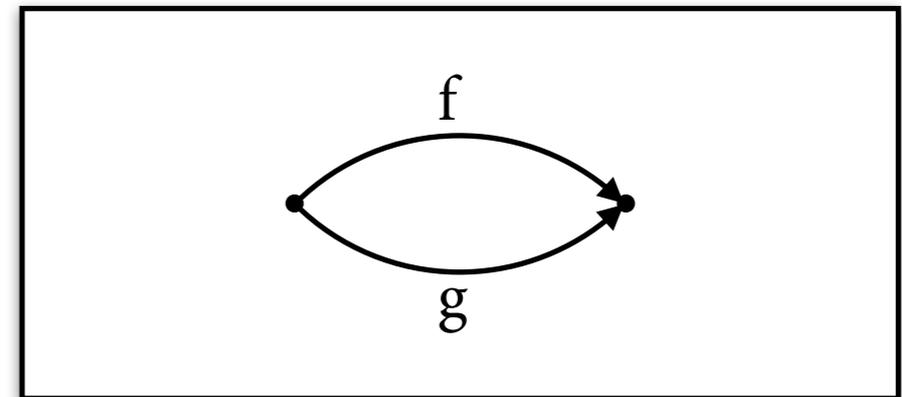
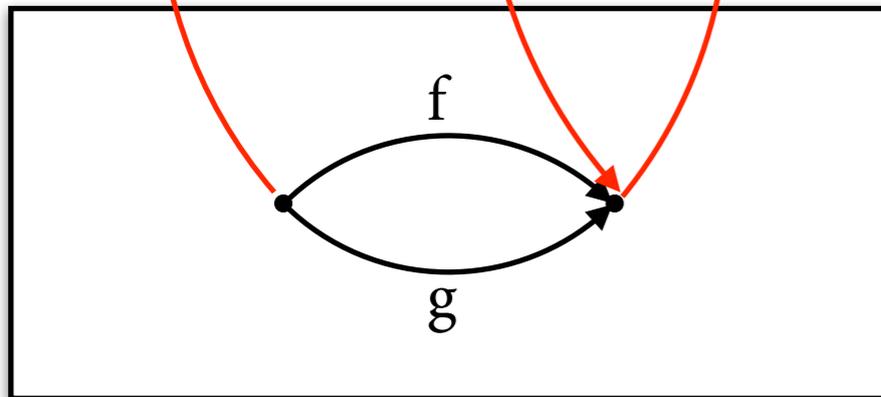
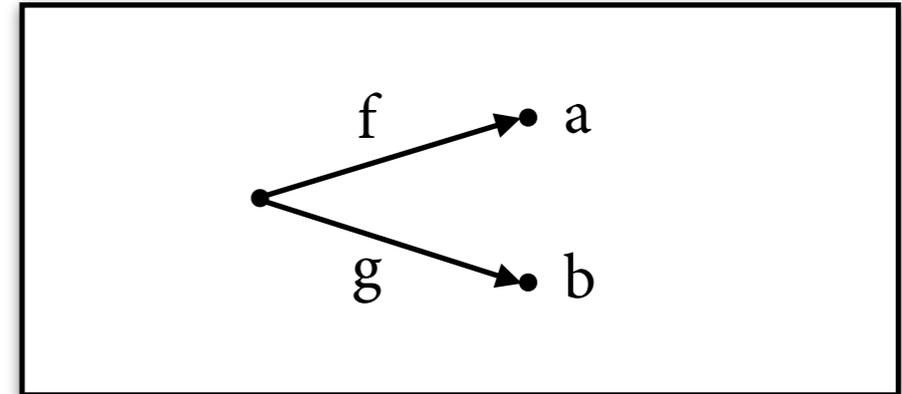
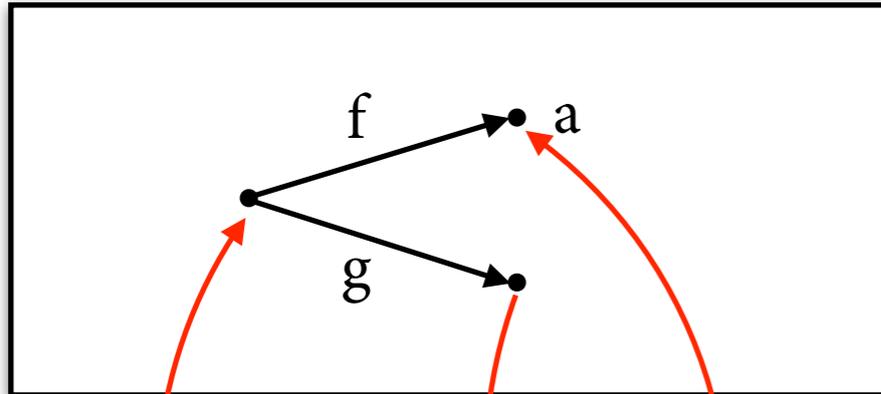
Beispiel



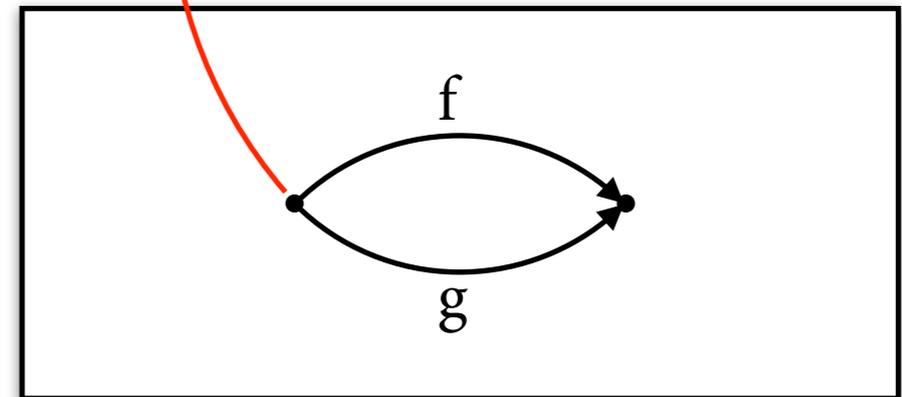
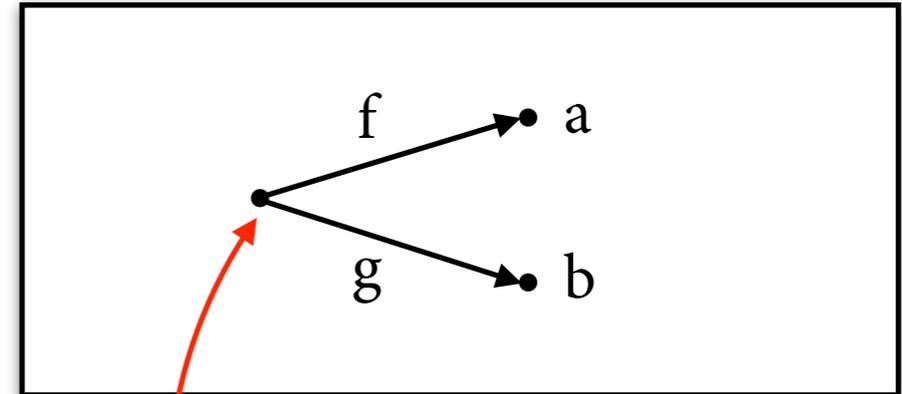
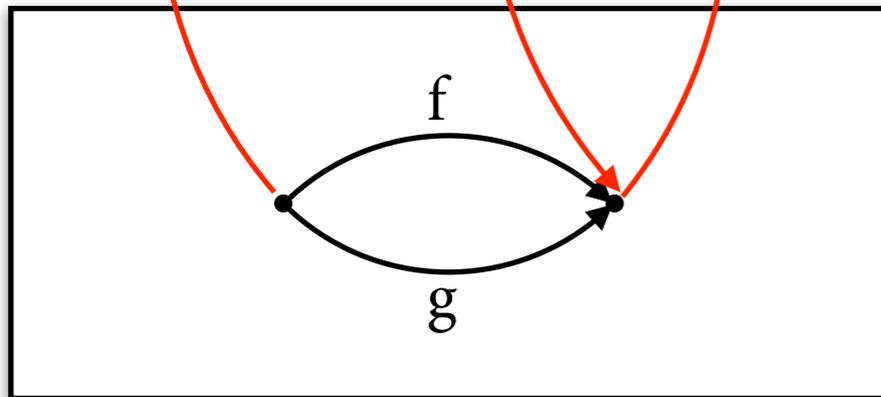
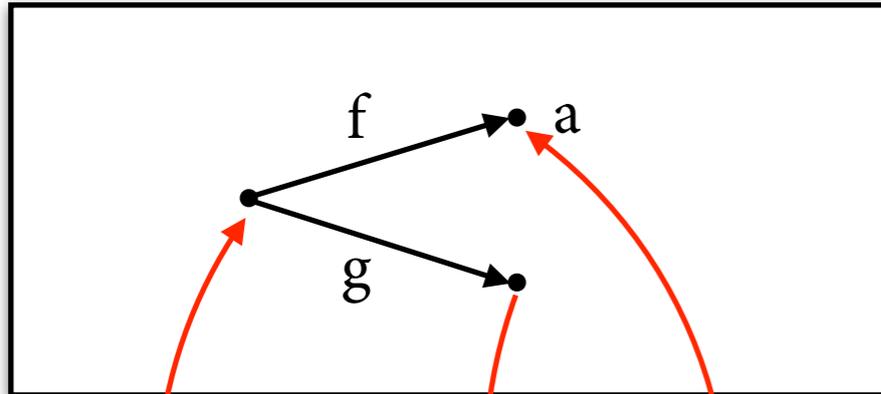
Beispiel



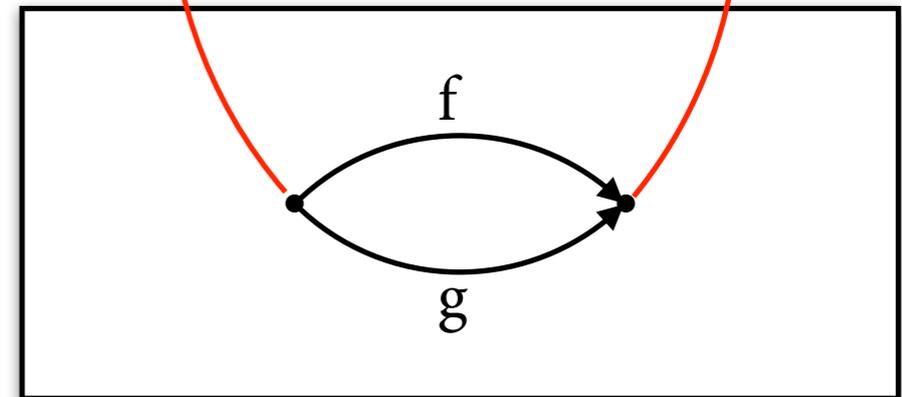
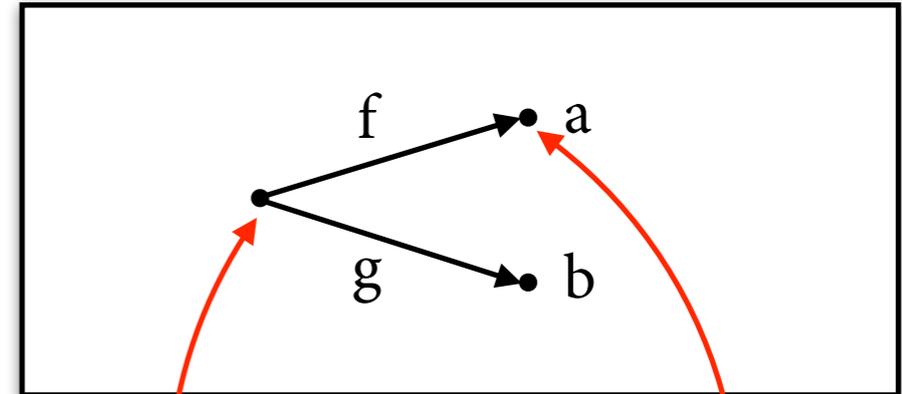
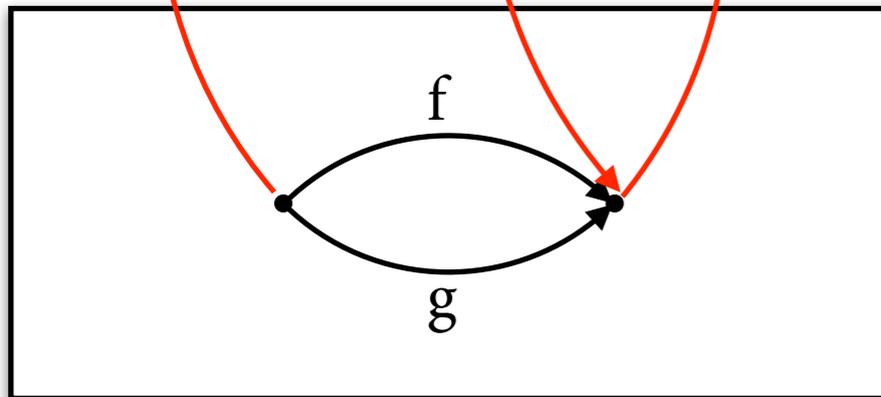
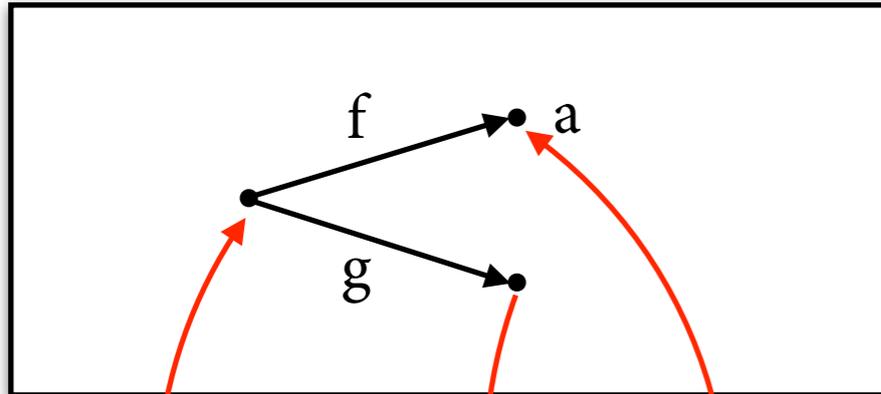
Beispiel



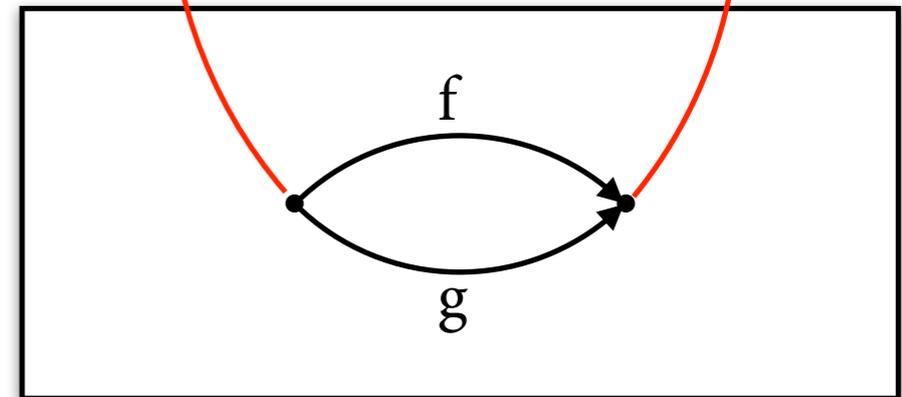
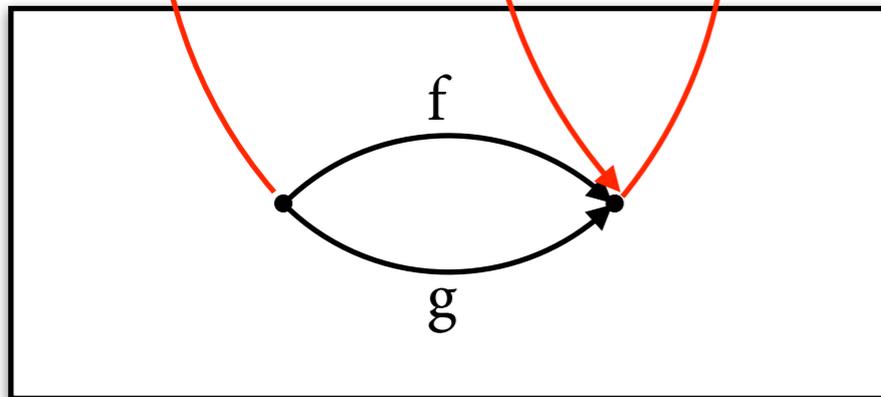
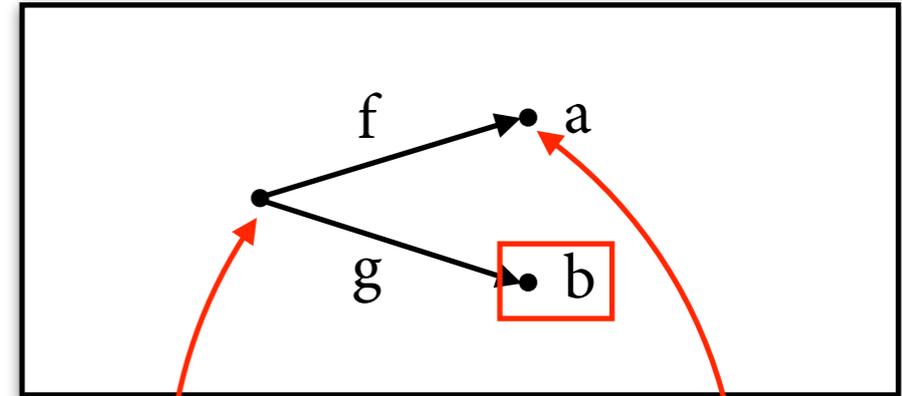
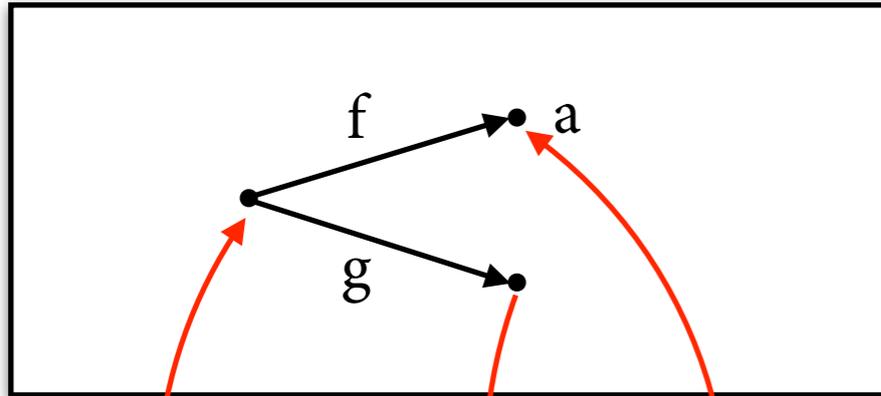
Beispiel



Beispiel



Beispiel



Evaluation

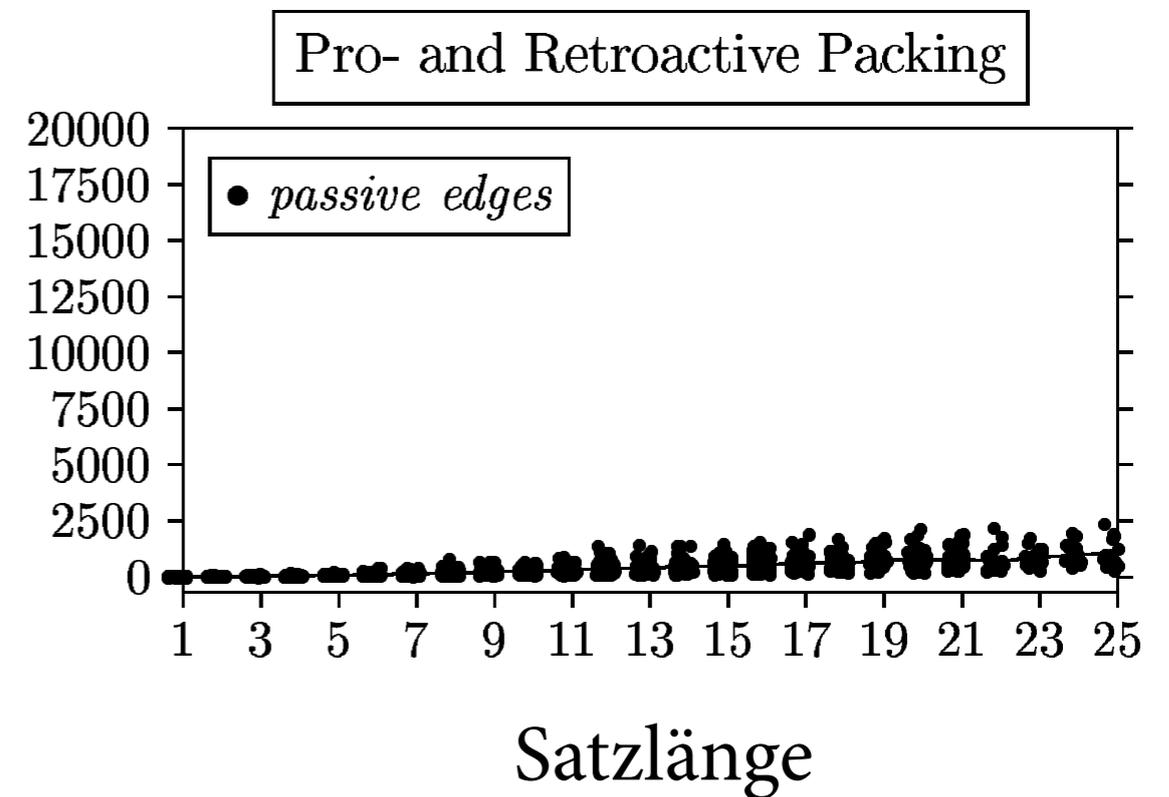
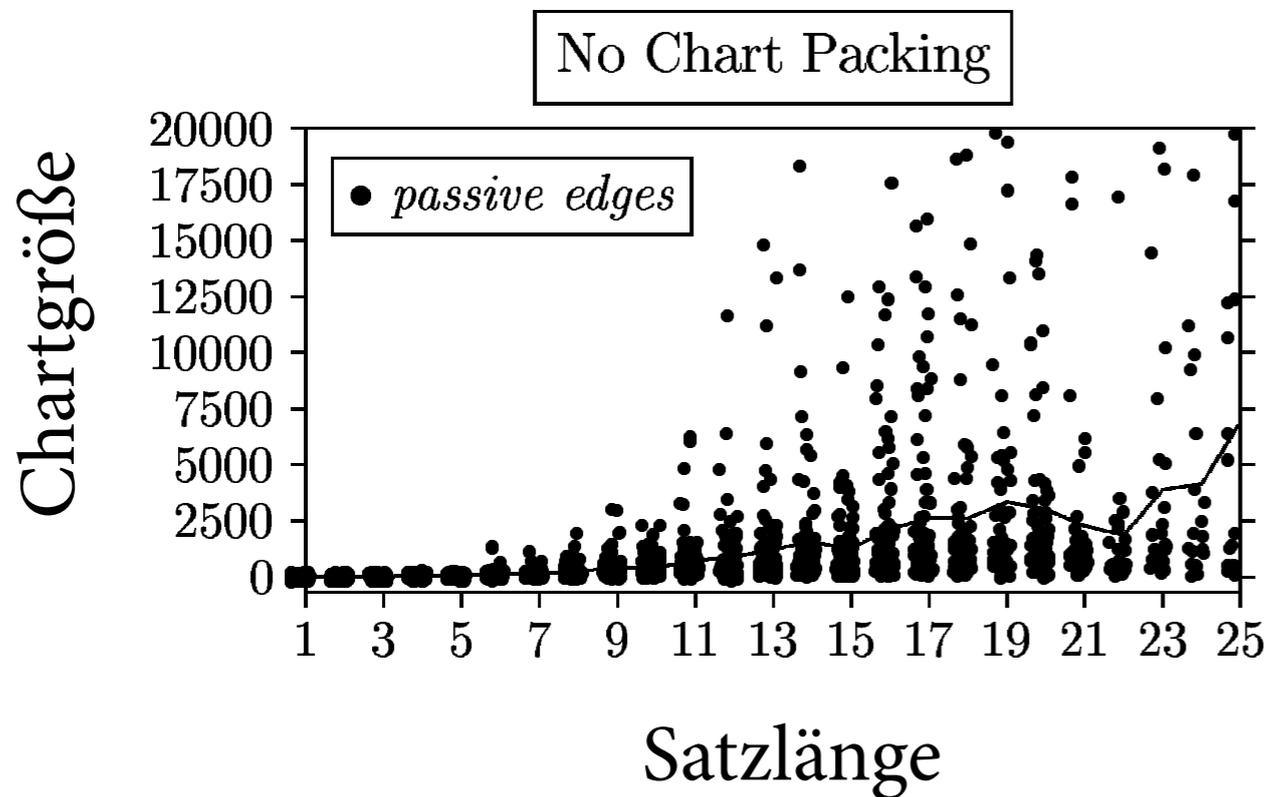
Unifier	tcpu		space (kb)	over (nodes)	copying		redundant (nodes)
	(s)	(s)			early (nodes)	(nodes)	
<i>quick check</i>	<i>on</i>	<i>off</i>	<i>on</i>	<i>on/off</i>	<i>on</i>	<i>off</i>	<i>on/off</i>
<i>unify1</i>	0.281	1.151	6,672	39.5	226.9	208.2	156.0
<i>unify2</i>	0.205	0.407	5,614	4.2	78.3	52.6	120.6
<i>unify3</i>	0.232	0.406	5,702	9.7	161.0	137.4	126.2
<i>tomabechi</i>	0.170	0.267	5,214	–	–	–	83.6
<i>tom-smart</i>	0.167	0.258	2,174	–	–	–	–

(Callmeier 2000; englisches Verbmobil-Testset mit LinGO-Grammatik; gemessen auf 500 MHz Pentium III)

Ambiguitäten packen

- Unter bestimmten Umständen kann man zwei FSen als äquivalent gelten lassen.
 - ▶ wenn Parser (i,k,σ) kannte und (i,k,τ) findet und $\tau \sqsubseteq \sigma$ (d.h. ist allgemeiner), dann darf er (i,k,σ) löschen.
 - ▶ Chart bleibt kleiner \Rightarrow Parsing wird schneller.
- Löschen von Einträgen, die aus (i,k,σ) abgeleitet wurden, ist nicht trivial.

Evaluation

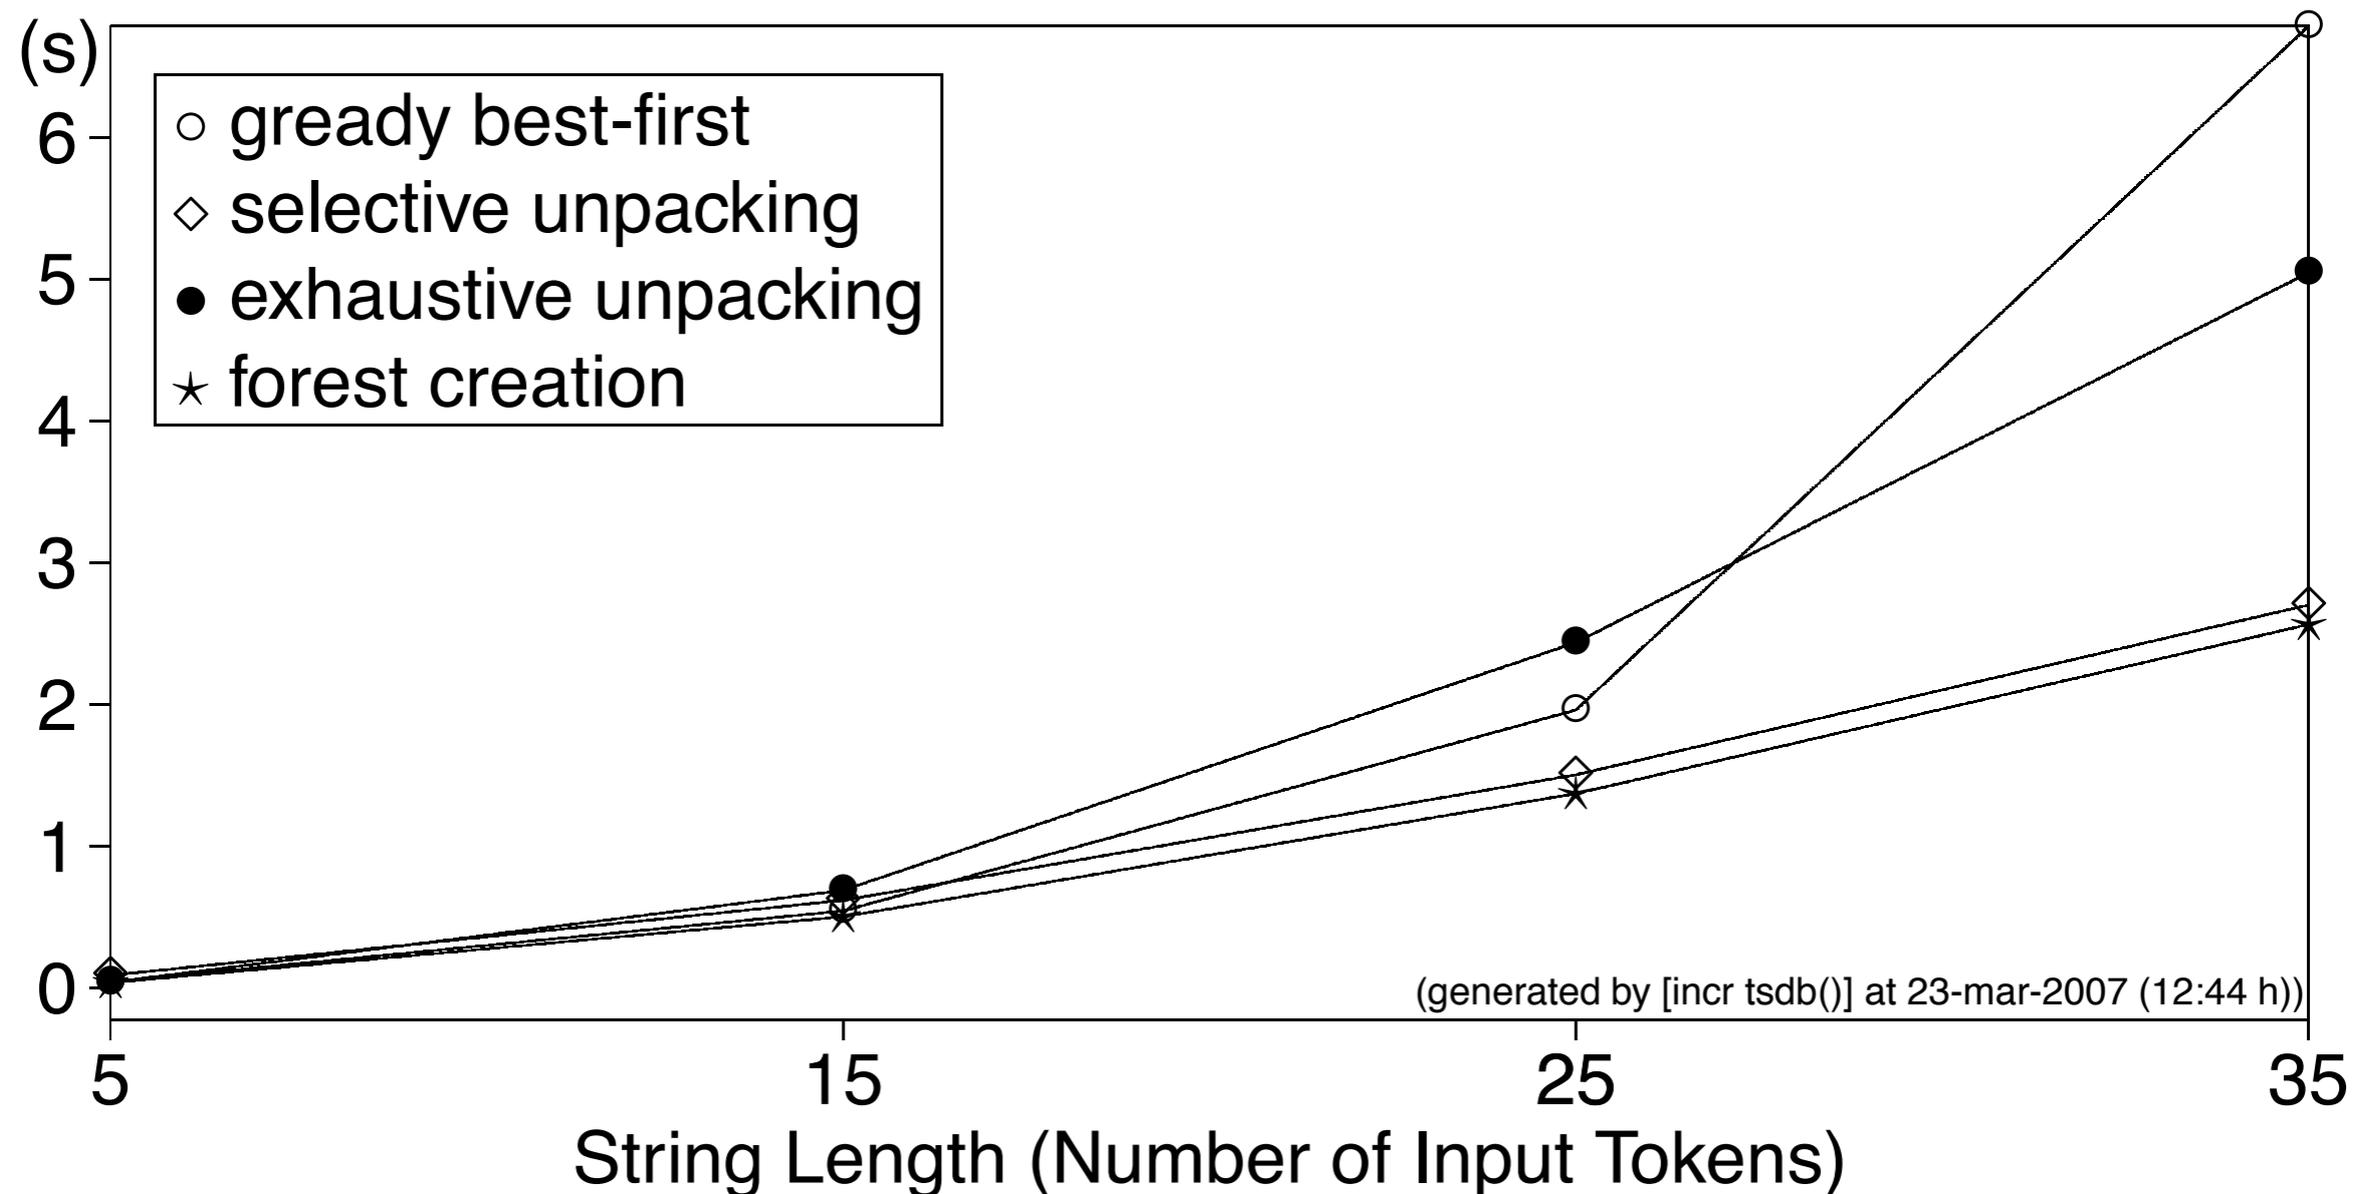


(Oepen & Carroll 2000; englisches Verbmobil-Testset mit LinGO-Grammatik)

Approximation

- HPSG-Schemata definieren Phrasenstruktur. Kann man mit kfG approximieren.
 - ▶ [cat=V, subcat=<NPnom>] →
[cat=V, subcat=<NPnom, NPacc>] [cat=N, subcat=<>]
- Mit (statistischer) kfG parsen; dann versuchen, beste Parsebäume in HPSG-Parses zu expandieren. (Kann fehlschlagen!)
- Unifikationen nur für Strukturen ausführen, die überhaupt eine Chance haben.

Polynomial Time (Practical) Parsing



→ **Average Time for 20-Word Sentences around One Second**



Stand der Kunst

- LKB: Grammatikentwicklungssystem.
 - ▶ verwendet Type Description Language (TDL), um Grammatiken aufzuschreiben
- TDL-Grammatiken kann man effizient mit dem PET-Parser verarbeiten.
 - ▶ LKB + PET + andere = DELPH-IN
 - ▶ DELPH-IN ist internationales Konsortium, das zueinander kompatible Parser, Grammatiken etc. entwickelt:
<http://www.delph-in.net/>

Zusammenfassung

- Expressivität von HPSG: turing-vollständig.
- Parsing von HPSG:
 - ▶ Wird in der Praxis dominiert von Zeit für Unifikation und Subsumptionstests.
 - ▶ Kann durch geschickte Algorithmen für diese Probleme in der Praxis effizient werden.
 - ▶ Algorithmen auch für andere Grammatikformalismen anwendbar, z.B. FTAG, LFG.

Fazit

