Definite Clause Grammar II

Übersicht

- DCG-Formalismus vs. DCG-Standard-Parser
- DCG zu Prolog-Übersetzung: Light-Version
- Erweiterungen: Komplexe Nicht-Terminal-Symbole
  - Modellierung von Kongruenz
  - Aufbau von Syntaxstrukturen
  - Abdeckungsgrad von DCGs
- Akzeptor vs. Parser
- Eingebettete Prolog-Klauseln
- Fazit: DCG und Prolog

DCG-Formalismus vs. Standard-Parser

DCG als Grammatik-Formalismus

- *Definite Clause Grammars* erlauben eine systematische Beschreibung der formalen Regularitäten einer Sprache.

```
s --> np, vp.
np --> det, n.
```

```
det --> [the].
det --> [a].
```

Der Standard-DCG-Parser von Prolog

- In den meisten Prologs gibt es einen Mechanismus, der DCGs automatisch in ein Prolog-Programm übersetzt, das die Sätze der von der DCG beschriebenen Sprache analysieren kann.
- Dieser Parser hat Probleme mit linksrekursiven Regeln.

DCG zu Prolog: Light-Version

Wie werden DCGs zu Prolog-Programmen übersetzt?

- *Im Folgenden: Vereinfachte Version der DCG-Übersetzung*
- translate/2 nimmt eine DCG-Regel und übersetzt sie in eine Prolog-Klausel.

```
translate((LHS --> RHS), (Head :- Body)) :-
   left_hand_side(LHS, Start, End, Head),
   right_hand_side(RHS, Start, End, Body).
```

```
np --> det, n.
```

```
np(Start, End) :-
  det(Start, Middle),
  n(Middle, End).
```


DCG zu Prolog: LHS

Wie wird die *Left-Hand-Side* übersetzt?

- left_hand_side/4 setzt die *Start*- und *End*-Variable
- Nicht-Terminal *NT* muss ein Atom sein (atom/1)
- *Head* wird mittels =../2 als komplexer Term zusammengesetzt

```
left_hand_side(NT, Start, End, Head) :-
  atom(NT),
  Head =.. [NT,Start,End].
```

```
np --> det, n.
```

```
np(Start, End) :-
  det(Start, Middle),
  n(Middle, End).
```

DCG zu Prolog: RHS mit Terminal

Wie wird die *RHS* übersetzt?

- Falls ein Terminal-Symbol (listenförmig!) vorliegt
  - Abbruchbedingung
  - 'C'/3-Aufruf einsetzen mit Terminal-Symbol als 2. Argument

```
right_hand_side([T], Start, End, 'C'(Start,T,End)).
```

```
det --> [der].
```

```
det(Start, End) :-
  'C'(Start, der, End).
```


DCG zu Prolog: RHS rekursiv

Wie wird die *Right-Hand-Side* (*RHS*) übersetzt?

- Falls mehrere Symbole auf der rechten Seite sind
  - Doppelte Rekursion
  - Erzeugen der Zwischenposition *Middle*

```
nt --> s1,s2,s3.
```

```
nt --> (s1,(s2,s3)).
```

```
right_hand_side((S1,S2), Start, End, (Body1, Body2)) :-
  right_hand_side(S1, Start, Middle, Body1),
  right_hand_side(S2, Middle, End, Body2).
```

```
np --> det, n.
```

```
np(Start, End) :-
  det(Start, Middle),
  n(Middle, End).
```


DCG zu Prolog: Light-Version

Wie wird die *Right-Hand-Side* übersetzt?

- Falls Nicht-Terminal-Symbol
  - NT-Symbol muss ein Atom sein
  - Rumpfteil wird als komplexer 2-stelliger Term zusammengesetzt mit =../2
  - Abbruchbedingung für die Rekursion

```
right_hand_side(NT, Start, End, Body) :-
  atom(NT),
  Body =.. [NT,Start,End].
```

```
vp --> v.
```

```
vp(Start, End) :-
  v(Start, End).
```


DCG zu Prolog: Light-Version

Die rekursive Dekomposition von right_hand_side/4 fügt die Aufrufe mit den jeweiligen Position korrekt ein:

```
?- translate((np --> det, n), X).
X = np(A,B):-det(A,C),n(C,B) ? ;
no
```

Eine NP besteht zwischen A und B, falls zwischen A und C ein Det besteht und zwischen C und B ein N.

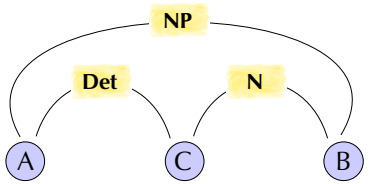

Komplexe Nicht-Terminal-Symbole

DCG mit komplexen NT-Symbolen

- Zusätzliche Information kann repräsentiert und unifiziert werden!
- Beispiel: **Kongruenz** *(Agreement)*
  - Im Deutschen müssen Genus von Artikel und Nomen muss übereinstimmen!
  - Merkmale werden hinaufunifiziert!

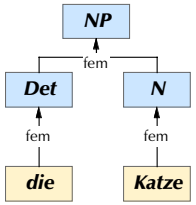


```
np(Genus) -->
   det(Genus),
   n(Genus).
n(fem) --> [katze].
det(fem) --> [die].
```

```
np(Genus, A, B) :-
   det(Genus, A, C),
   n(Genus, C, B).
n(fem, A, B) :- 'C'(A, katze, B).
det(fem, A, B) :- 'C'(A, die, B).
```


Konstruktion eines Syntaxbaums

DCG mit komplexen NT-Symbolen: Syntaxstrukturen

- In der LHS jeder Grammatikregel wird die der Regel entsprechende syntaktische Datenstrukutur im Zusatzargument aufgebaut.

```
                                  n(n(katze)) --> [katze].
np(np(Det,N)) --> det(Det),  n(N).
                  det(det(die)) --> [die].
```

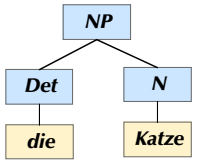

- Die Grammatiksymbole wie S, NP, Det werden dabei gerne mehrdeutig verwendet:
  - als Parseprädikate, Datenstrukturen und Variablen
  - *Man könnte auch jeweils andere Bezeichner verwenden!*

Parsen mit komplexen Symbolen

```
s(s(NP,VP)) --> np(NP,nom,Num), vp(VP,Num).
np(np(Det,N),Kas,Num) -->
   det(Det,Gen,Kas,Num), n(N,Gen,Kas,Num).
vp(v(V),Num) --> v(V,Num).

n(n(katze),fem,Kas,sg) --> [katze].
v(v(schlaeft),sg) --> [schlaeft].
v(v(schlafen),pl) --> [schlafen].
det(det(die),fem,nom,sg) --> [die].
det(det(der),fem,gen,sg) --> [der].
```

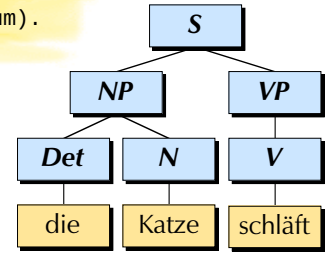


```
?- phrase(s(Baum), [die,katze,schlaeft]).
Baum = s(np(det(die),n(katze)),vp(v(schlaeft)))
```


Akzeptor – Parser

Ein Programm zur syntaktischen Analyse

- nimmt eine Kette von Wörtern entgegen.
- beurteilt, ob die Eingabe gemäss den Regeln einer Grammatik zulässig ist.

Akzeptoren

- antworten nur mit »zulässig« bzw. »nicht zulässig«.

Parser

- geben bei zulässigen Eingaben zusätzlich die mögliche(n) syntaktische(n) Struktur(en) der Eingabekette aus.

Mächtigkeit von DCG

Komplexe Nicht-Terminal-Symbole beeinflussen die mathematischen Eigenschaften des Formalismus.

- Die modellierte Sprache kann ausserhalb der Klasse der kontextfreien Sprachen liegen!

Grammatik für $\{a^n\ b^n\ c^n \mid n \geq 1\}$

```
s --> as(N), bs(N), cs(N).
as(1)       --> [a].
as(succ(A)) --> [a], as(A).
bs(1)       --> [b].
bs(succ(B)) --> [b], bs(B).
cs(1)       --> [c].
cs(succ(C)) --> [c], cs(C).
```

Anfragen

```
?- phrase(s, [a,b,c]).
yes

?- phrase(s, [a,a,b,c]).
no
```


Eingebettete Prolog-Klauseln

Prädikatsaufrufe innerhalb geschweifter Klammern

- werden bei der Übersetzung von DCGs unverändert übernommen.
- Dadurch können beliebige Prolog-Programme in die Grammatik eingebettet werden.

```
lex(cat, n).
lex(dog, n).
lex(cow, n).
```

```
n(n(N)) -->
   [N],
   {lex(N, n)}.
```

```
n(n(A), B, C) :-
   'C'(B, A, C),
   lex(A, n).
```

Beispiel
Anstelle von lexikalischen DCG-Regeln wird ein Lexikon aus lex/2-Fakten verwendet mit Lexem und lexikalischer Kategorie als Argumenten.

Eingebettete Prolog-Klauseln

Vorteile der Prolog-Einbettung

- manchmal kann die Effienz gesteigert werden
  - Es darf auch der cut/0 eingesetzt werden. (Sogar ohne geschweifte Klammern!)
- kontextsensitive Sprachen können erkannt werden

Nachteile der Prolog-Einbettung

- keine deklarative Spezifikation der Grammatik
- Grammatiken werden schnell unübersichtlich
- Reine DCGs können als Formalismus auch von anderen Programmiersprachen/Grammatikkompilierern verarbeitet werden; mit eingebettetem Prolog wird eine Prolog-Abhängigkeit geschaffen

Fazit Prolog und DCGs

Vorteile von DCGs

- in Prolog ist ein einfacher Top-Down-Parser bereits eingebaut
- DCGs sind in Prolog Grammatik und Parser-Programm gleichzeitig
- nützlich zum schnellen Spezifizieren/Ausprobieren einer Mini-Grammatik
- als reiner Formalismus unabhängig von Umsetzung in Parser-Programm

Nachteile vom Standard-Prolog-DCG-Verarbeitung

- »Aufhängen« bei linksrekursiven Grammatiken
- eher ineffizientes Verfahren
  - bei mehrdeutigen Grammatiken werden unter Umständen Teile des Satzes mehrmals analysiert
  - lexikalische Regeln werden ineffizient für grossen Lexika

- **Für richtige Sprachverarbeitungsprojekte kaum brauchbar.**