

Natuurlijke-taalverwerking

Week 2

Overzicht

Context-vrije Grammatica's

CFGs in Prolog

Definite Clause Grammars (DCGs)

Construeren van bomen

Recapitulatie

- ▶ Doel: computers taal laten begrijpen
- ▶ Noodzaak: bepaal syntactische structuur
 - ▶ Computationale grammatica
 - ▶ Lexicon
 - ▶ Parser (ontleder)
- ▶ Parse-boom: expliciete syntactische structuur

Recapitulatie (2)

- ▶ Context-vrije grammatica's
- ▶ $X \rightarrow w$
 - ▶ X is een 'non-terminal' symbool
 - ▶ w is een reeks van terminal, non-terminal of epsilon symbolen
- ▶ Bijvoorbeeld:

S	→	NP VP
NP	→	Det N
Det	→	<i>de</i>
N	→	<i>man</i>
VP	→	<i>loopt</i>

Recapitulatie (2 - boom)

S	→	NP VP
NP	→	Det N
Det	→	<i>de</i>
N	→	<i>man</i>
VP	→	<i>loopt</i>

Recapitulatie (3)

- ▶ Als er meer dan één mogelijke lezing van een zin is:
ambiguïteit
- ▶ Structurele ambiguïteit: *Ik zag de man met de verrekijker.*
- ▶ Lexicale ambiguïteit: *Wij zagen vader niet meer.*





Recapitulatie (3 - PPs)

Syntactische structuur

- ▶ Woordvolgorde;
- ▶ naamval;
- ▶ getal-, persoons-, en geslachtskenmerken.

Woordvolgorde



Andere syntactische beperkingen

- ▶ naamval
 - ▶ *Wie kust hij?*
 - ▶ *Wie kust hem?*
 - ▶ *Hij kust haar*
 - ▶ **Hij kust zij*
- ▶ getal
 - ▶ *De mannen roepen de vrouw*
 - ▶ **De mannen roept de vrouw*
- ▶ andere formele kenmerken
 - ▶ *met bossen overdekt was*
 - ▶ *met bossen overdekte was*

Recursie (rechts)

- ▶ [*De man met [de verrekijker]*]
- ▶ [*De man met [de verrekijker van [de buurman]]]*]
- ▶ [*De man met [de verrekijker van [de buurman van [mijn dochter]]]]]*]

Recursie (links)

- ▶ $[[De\ man]\ zijn\ verreijker]$
- ▶ $[[[De\ man]\ zijn\ dochter]\ zijn\ verreijker]$
- ▶ $[[[[De\ man]\ zijn\ dochter]\ zijn\ buurman]\ zijn\ verreijker]$

Recursie (centrum?)

- ▶ [*De man die [de vrouwen] kent*]
- ▶ [*De man die [de vrouwen die [hun kinderen] troosten] kent*]
- ▶ [*De man die [de vrouwen die [hun kinderen [die [hun speelgoed] kwijt zijn] troosten] kent*]
- ▶ [*De man die [de vrouwen die [hun kinderen [die [hun speelgoed dat [ik] ze gegeven had] kwijt zijn] troosten] kent*]

Overzicht

Context-vrije Grammatica's

CFGs in Prolog

Definite Clause Grammars (DCGs)

Construeren van bomen

Parsing as Deduction

$$\text{NP} \rightarrow \text{Det N}$$

- ▶ Een **NP** kan worden herschreven als een **Det** gevolgd door een **N**;
- ▶ **NP** is waar als **Det** en **N** waar zijn.

$$\text{np} \text{ :- det, n.}$$

Verschillen tussen CFG en Prolog

$$\text{NP} \rightarrow \text{Det N}$$
$$\text{np} \text{ :- det, n.}$$

Waarom kunnen we deze vertaling niet rechtstreeks maken?

Verschillen tussen CFG en Prolog

$\text{np} \text{ :- det, n.}$	$=$	$\text{np} \text{ :- n, det.}$
$\text{NP} \rightarrow \text{Det N}$	$\neq$	$\text{NP} \rightarrow \text{N Det}$
$\text{np} \text{ :- det, n.}$	$=$	$\text{np} \text{ :- det, n, n.}$
$\text{NP} \rightarrow \text{Det N}$	$\neq$	$\text{NP} \rightarrow \text{Det N N}$

- ▶ **(Woord-)volgorde** speelt een rol
- ▶ Aantal **Voorkomens** van een woord/constituent speelt een rol.

CFG in Prolog

de roze olifant ontsnapt

0 de 1 olifant 2 ontsnapt 3

```
word(0,de,1).  
word(1,olifant,2).  
word(2,ontsnapt,3).
```

CFG in Prolog (2)

Det $\rightarrow$ <i>de</i> N $\rightarrow$ <i>olifant</i> NP $\rightarrow$ Det N

vertalen we als

<pre>det(P0,P1) :- word(P0,de,P1). n(P0,P1) :- word(P0,olifant,P1). np(P0,P2) :- det(P0,P1), n(P1,P2).</pre>
--

Kort voorbeeld


```
det(P0,P1) :- word(P0,de,P1).  
n(P0,P1) :- word(P0,olifant,P1).  
np(P0,P2) :- det(P0,P1), n(P1,P2).
```

```
word(0,de,1).  
word(1,olifant,2).
```

Meer voorbeelden

```
s(P0,P2) :- np(P0,P1), vp(P1,P2).  
np(P0,P3) :- det(P0,P1), a(P1,P2), n(P2,P3).  
vp(P0,P1) :- v(P0,P1).  
vp(P0,P2) :- v(P0,P1), np(P1,P2).  
det(P0,P1) :- word(P0,de,P1).  
det(P0,P1) :- word(P0,het,P1).  
det(P0,P0).  
n(P0,P1) :- word(P0,man,P1).  
n(P0,P1) :- word(P0,huis,P1).  
v(P0,P1) :- word(P0,verlaat,P1).  
v(P0,P1) :- word(P0,schreeuwt,P1).
```

Epsilon-regels



`det(P0,P0) .`

Prolog-lijsten als string-posities

```
de olifant ontsnapt  
0 de 1 olifant 2 ontsnapt 3
```

```
0 = [de,olifant,ontsnapt]  
1 = [olifant,ontsnapt]  
2 = [ontsnapt]  
3 = [ ]
```

```
word([de,olifant,ontsnapt],de,[olifant,ontsnapt]).  
word([olifant,ontsnapt],olifant,[ontsnapt]).  
word([ontsnapt],ontsnapt,[ ]).
```

Herken het patroon

```
word([de,olifant,ontsnapt],de,[olifant,ontsnapt]).  
word([olifant,ontsnapt],olifant,[ontsnapt]).  
word([ontsnapt],ontsnapt,[]).
```

```
word([Word|Words],Word,Words).
```


My first parser

```
parse(Words) :-  
    s(Words, []).  
  
word([Word|Words], Word, Words).  
  
%% ... en verder de grammaticaregels:  
s(P0,P2) :- np(P0,P1), vp(P1,P2).  
np(P0,P2) :- det(P0,P1), n(P1,P2).  
vp(P0,P1) :- v(P0,P1).  
vp(P0,P2) :- v(P0,P1), np(P1,P2).  
det(P0,P1) :- word(P0,de,P1).  
det(P0,P1) :- word(P0,het,P1).  
det(P0,P0).  
n(P0,P1) :- word(P0,man,P1).  
n(P0,P1) :- word(P0,huis,P1).  
v(P0,P1) :- word(P0,verlaat,P1).  
v(P0,P1) :- word(P0,schreeuwt,P1).
```

Overzicht

Context-vrije Grammatica's

CFGs in Prolog

Definite Clause Grammars (DCGs)

Construeren van bomen

De DCG pijl

$$\text{NP} \rightarrow \text{Det N}$$

wordt in Prolog geschreven als

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

en wordt door Prolog vertaald in

```
np(P0,P2) :- det(P0,P1), n(P1,P2).
```

Prolog `term_expansion` vertaalt code bij het inlezen in andere code...

De DCG pijl (2)

$$\begin{array}{l} N \rightarrow \textit{olifant} \\ \textit{Det} \rightarrow \epsilon \end{array}$$

wordt in Prolog geschreven als

```
n --> [olifant].  
det --> [].
```

en wordt door Prolog vertaald in

```
n(P0,P1) :- 'C'(P0,olifant,P1).  
det(P0,P1) :- P0 = P1.
```

gegeven de volgende definitie

```
'C'([Word|P],Word,P).
```

Enkelvoud/Meervoud

	Dumbo slaapt	olifanten slapen
fout:	Dumbo slapen	olifanten slaapt

$S \rightarrow \text{NPsg VPsg}$ $\text{VPsg} \rightarrow \text{Vsg}$

$S \rightarrow \text{NPpl VPpl}$ $\text{VPpl} \rightarrow \text{Vpl}$

$\text{NPsg} \rightarrow \text{Detsg Nsg}$

$\text{NPpl} \rightarrow \text{Detpl Npl}$

$\text{Vsg} \rightarrow \text{slaapt}$

$\text{Vpl} \rightarrow \text{slapen}$

- ▶ Dit werkt
- ▶ Maar wordt snel onoverzichtelijk (naamval, persoon, ...)
- ▶ Zeer veel regels
- ▶ Generalizatie gemist

DCG's met variabelen

```
s --> np(Num), vp(Num).  
np(Num) --> det(Num), N(Num).  
vp(Num) --> v(Num).  
v(sg) --> [slaapt].  
n(sg) --> [olifant].  
v(pl) --> [slapen].  
n(pl) --> [olifanten].
```

DCG's met variabelen (2)

$$s \text{ --> } np(N), vp(N).$$

wordt door Prolog vertaald als

$$s(P0,P2) \text{ :- } np(N,P0,P1), vp(N,P1,P2).$$

- Variabelen voor string-posities worden altijd achteraan toegevoegd.

Woordenboeken

```
v(sg) --> [slaapt].  
v(pl) --> [slapen].  
v(Inf) --> [slapen].  
v(prt) --> [geslapen].  
v(sg) --> [sliep].  
.....  
n(sg) --> [olifant].  
n(pl) --> [olifanten].
```


Woordenboeken (2)

- ▶ Voor ieder werkwoord moeten dezelfde vormen worden gespecificeerd. (*Paradigma*).
- ▶ Dit vereist veel regels.
- ▶ **Woordenboek en regels scheiden:**
 - ▶ Woordenboek kan worden **geïmporteerd** uit een algemeen elektronisch woordenboek
 - ▶ **Veranderingen in de grammatica** hebben minder invloed op woordenboek
 - ▶ Woordenboek kan **herbruikt** worden.

Scheiden Woordenboek en Grammatica

```
verb(slaapt,slapen,sliep,sliepen,geslapen).
```

```
v(sg) --> [Word], {verb(Word,_,_,_,_)}.
```

```
v(sg) --> [Word], {verb(_,_,Word,_,_)}.
```

```
v(pl) --> [Word], {verb(_,Word,_,_,_)}.
```

```
v(pl) --> [Word], {verb(_,_,_,Word,_)}.
```

```
...
```

Accolade's

- ▶ Soms wil je 'gewone' Prolog-code tussen je regels vlechten.
- ▶ Accolade-notatie staat dit toe.

$$v(\text{sg}) \text{ --> } [W], \{ \text{verb}(W, -, -, -, -) \}.$$

wordt door Prolog vertaald als:

$$v(\text{sg}, P0, P1) \text{ :- 'C'(P0, W, P1), verb(W, -, -, -, -).}$$

Grammatica schrijven

Ik slaap.	*Mij slaap
Hij slaapt.	*Hem slaap
Ik zie hem.	*Ik zie hij
Hij ziet mij.	*Hij ziet ik
Jan ziet mij	
Ik zie Jan	

- ▶ *Ik* en *hij* kan alleen als onderwerp gebruikt worden (*nominatief*)
- ▶ *mij* en *hem* kan in alle posities, behalve onderwerp, gebruikt worden (*accusatief*),
- ▶ *Jan* kan in alle NP-posities gebruikt worden.

Grammatica zonder naamvallen

$s \rightarrow np\ vp$

$vp \rightarrow v\ np$

$np \rightarrow ik$

$np \rightarrow mij$

$np \rightarrow hij$

$np \rightarrow hem$

$np \rightarrow Jan$

Grammatica met naamvallen

$s \rightarrow \text{npnom } vp$

$vp \rightarrow v \text{ npacc}$

$\text{npnom} \rightarrow \text{ik}$

$\text{npnom} \rightarrow \text{hij}$

$\text{npnom} \rightarrow \text{Jan}$

$\text{npacc} \rightarrow \text{mij}$

$\text{npacc} \rightarrow \text{hem}$

$\text{npacc} \rightarrow \text{Jan}$

DCG met naamvallen

```
s --> np(nom), vp.  
vp --> v, np(acc).  
np(nom) --> [ik].  
np(acc) --> [mij].  
np(nom) --> [hij].  
np(acc) --> [hem].  
np(_) --> [jan].
```

DCG met naamvallen

```
s --> np(nom), vp.  
vp --> v, np(acc).  
np(nom) --> [W], {pronoun(W,_)}.  
np(acc) --> [W], {pronoun(_,W)}.  
np(_) --> [W], {proper_name(W)}.
```

```
pronoun(ik,mij).  
pronoun(hij,hem).  
proper_name(jan).
```


Context-free versus context-sensitive

- ▶ De taal $a^n b^n$ kan beschreven worden met een CFG, terwijl een CFG de taal $a^n b^n c^n$ niet kan beschrijven.
- ▶ Zijn DCGs krachtiger?

Uitwerking

$$a^m b^n c^o$$

`s --> as, bs, cs.`

`as --> []`

`as --> [a], as.`

`bs --> []`

`bs --> [b], bs.`

`cs --> []`

`cs --> [c], cs.`

$$a^m b^n c^o \quad (2)$$

```
s --> symbols(a), symbols(b), symbols(c).
```

```
symbols(_) --> [].
```

```
symbols(S) --> [S], symbols(S).
```

$a^n b^n c^n$ in een DCG

```
s --> symbols(Sem,a), symbols(Sem,b), symbols(Sem,c).
```

```
symbols(end,_) --> [].
```

```
symbols(s(Sem),S) --> [S], symbols(Sem,S).
```

Overzicht


Context-vrije Grammatica's

CFGs in Prolog

Definite Clause Grammars (DCGs)

Construeren van bomen

Bomen



Definitie

- ▶ Een boom bestaat uit
 - ▶ Een moederknoop
 - ▶ en 0,1,2, of meer dochters
- ▶ Dochters zijn
 - ▶ zelf weer bomen
 - ▶ of woorden.

Bomen in Prolog

- ▶ `boom(Moeder,Lijst)`
- ▶ `boom(n,[overleg])`
- ▶ `boom(det,[dit])`
- ▶ `boom(np,[boom(det,[dit]),boom(n,[overleg])])`
- ▶ `b(np,[b(det,[w(dit)]),b(n,[w(overleg)])])`

Bomen in Prolog (2)

```
np --> det, n.  
det --> [dit].  
n --> [overleg].
```

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

```
det(b(det, [w(dit)])) --> [dit].  
n(b(det, [w(overleg)])) --> [overleg].
```

```
det(b(det, [w(W)])) --> [W], {determiner(W)}.  
n(b(det, [w(W)])) --> [W], {noun(W)}.
```

Bomen in Prolog (3)

```
?- parse([de,hond,heeft,gesnurkt]).  
s ----- np ----- det --- de  
          ----- n ----- hond  
          ----- aux --- heeft  
          ----- vp ----- vc ----- aux --- epsilon  
                                ----- v ----- gesnurkt
```

Bomen in Prolog (4)

```
hilde$ sicstus -l opgave2
| ?- parse([de,hond,heeft,gesnurkt]).
  s ----- np ----- det --- de
                        ----- n ----- hond
  ----- aux --- heeft
  ----- vp ----- vc ----- aux --- epsilon
                        ----- v ----- gesnurkt

  s ----- np ----- det --- de
                        ----- n ----- hond
  ----- aux --- heeft
  ----- vp ----- vc ----- v ----- gesnurkt
                        ----- aux --- epsilon

yes
| ?-
```

Bomen in Hdrug

```
hilde$ export PATH=$PATH:/net/aps/64/bin
hilde$ export \
    NTV=/net/aps/64/src/Alpino/Hdrug/Applications/NTV1
hilde$ hdrug -flag grammar opgave2.pl -l $NTV/start
```

Bomen in Hdrug (2)

The screenshot displays the Hdrug software interface. At the top, a menu bar includes File, Debug, Hdrug, Options, Parse, Generate, Test-Suite, and View. Below the menu, a status bar shows 'Parse' and the sentence 'de directeur voert de olifant over de beer'. The main window is divided into two panes. The left pane contains a list of sentences, with 'de directeur voert de olifant over de beer' highlighted. The right pane displays two syntactic trees for this sentence. The top tree is a full parse tree with nodes labeled 'S', 'NP', 'VP', 'det', 'n', 'voert', 'NP', 'prep', 'NP', 'VP', 'over', 'det', 'n', 'voert', 'NP', 'VP', 'de', 'beert', 'epiloos'. The bottom tree is a simplified version of the same structure. The interface also includes a toolbar with buttons for 'Top', 's', 'Parser', 'parser', 'New Canvas', and 'Simple DCG'.

File Debug Hdrug Options Parse Generate Test-Suite View Help

Parse de directeur voert de olifant over de beer

de beer ontsnapt
de directeur voert de olifant
de directeur voert de olifanten
de directeur voert de olifant over de beer
de directeur voert over de beer de olifant
de directeur voert de olifant vandaag
de directeur voert de olifant hier
de directeur heeft de olifanten gevoerd
de directeur wil de olifanten voeren
het mooie metje ontsnapt

1 2 3

S
NP VP
det n voert NP VP
de directeur det n NP VP
de olifant prep NP VP
over det n voert NP VP
de beert epiloos

S
NP VP
det n voert NP VP
de directeur det n NP VP
de olifant prep NP VP
over det n voert NP VP
de beert epiloos

Top s Parser parser New Canvas Simple DCG