

Natuurlijke-Taalverwerking

Week 5

Parsing

Overzicht

- ▶ DCG's en links-recurisie
- ▶ Shift-reduce parsing
- ▶ Chart parsing
- ▶ Generatie

Links-recursie

```
ouder(geert,jan).  
ouder(jan,youri).  
  
voorouder(X,Y) :-  
    voorouder(X,Z),  
    ouder(Z,Y).  
  
voorouder(X,Y) :-  
    ouder(X,Y).
```

?- voorouder(geert,youri).

Links-recursie (2)

```
ouder(geert,jan).  
ouder(jan,youri).  
  
voorouder(X,Y) :-  
    ouder(X,Y).  
  
voorouder(X,Y) :-  
    voorouder(X,Z),  
    ouder(Z,Y).
```

?- voorouder(geert,youri).

Links-recursie en DCG's

- ▶ de bal [in de hoek]
- ▶ de bal [met rode stippen [in de hoek]]
- ▶ de bal [van de hond [met rode stippen [in de hoek]]]

n --> n, pp.

np --> det, n.

```
| ?- np([de,bal,in,de,hoek],[ ]).
```

```
1      1 Call: np([de,bal,in,de,hoek],[ ]) ?  
[...]
```

```
4      2 Call: n([bal,in,de,hoek],[ ]) ?
```

```
5      3 Call: n([bal,in,de,hoek],_3740) ?
```

```
6      4 Call: n([bal,in,de,hoek],_4300) ?
```

```
7      5 Call: n([bal,in,de,hoek],_4860) ?
```

Links-recursie en DCG's

Erben en Gerard

Erben en Gerard of Jan

Erben en Marianne of Gerard en Renate

`np --> np, [en], np.`

`np --> np, [of], np.`

Links-recursie en DCG's

de schaaten

Erben's schaatsen

Erben's vader's schaatsen

`np --> det, n.`

`det --> np, ['\'s'].`

Links-recursie en DCG

Als we de normale Prolog bewijsprocedure (top-down, backtracking) gebruiken, zijn links-recursieve DCG-regels problematisch.

- ▶ Optie 1: Pas grammatica aan.
- ▶ Optie 2: Pas ontleed algoritme aan.

Eliminatie van links-recursie

```
n --> n_lex, pps.  
pps --> pp, pps.  
pps --> [].
```


Eliminatie van links-recursie

Gegeven een grammatica met links-recursieve regels, vindt een *equivalente* grammatica zonder links-recursieve regels.


Er zijn echter verschillende vormen van equivalentie:

- ▶ *weakly equivalent*: grammatica's genereren dezelfde verzameling zinnen
- ▶ *strongly equivalent*: grammatica's genereren dezelfde verzameling zinnen met parsebomen

Boom links-recursieve grammatica



Boom herschreven grammatica



Eliminatie van links-recursie

Pas ook de parseboom aan!

Eliminatie van links-recursie

- ▶ Een grammatica met links-recursie kan automatisch worden omgezet in een grammatica zonder links-recursie
 - ▶ strongly equivalent
- ▶ Maar aantal regels kan explosief toenemen
- ▶ Regels worden onbegrijpelijk

Parse-strategieën

- ▶ Prolog (DCG) zoekt **top-down, depth-first, links-rechts**
- ▶ Alternatieven:
 - ▶ **Bottom-up**: Begin bij de input (woorden), werk naar de startcategorie (S) toe
 - ▶ **Breadth-first**: Onderzoek alle mogelijke manieren om zinsdelen te vormen parallel
 - ▶ **rechts-links, hoofd-gedreven**
- ▶ Alternatieve methode's zijn (vaak) robuuster en/of efficiënter

Alternatieve Parse-strategieën

- ▶ Vereist een scheiding tussen **regels (data)** en **parser (algoritme)**;
- ▶ grammatica-regels als Prolog-data (zie ook unificatie-grammatica):

```
% rule(Mother_Category,List_Daughters)
```


```
% s --> np(Agr), vp(Agr).  
rule(s,[np(Agr),vp(Agr)]).
```

```
% lex(Category,Word).
```

```
% np(sg) --> [kim].  
lex(np(sg),kim).
```


Top-down ontleden

S
NP VP
Det N VP
de N VP
de hond VP
de hond V
de hond snurkt



DCG = top-down

1. `s([de, hond, snurkt], []).`
2. `np([de, hond, snurkt], P1), vp(P1, []).`
3. `det([de, hond, snurkt], P2), n(P2, P1), vp(P1, []).`
4. `n([hond, snurkt], P1), vp(P1, []).`
5. `vp([snurkt], []).`
6. `v([snurkt], [])`
- 7.

Top-down ontleden


```
parse(Cat,[Word|Tail],Tail) :-  
    lex(Cat,Word).  
parse(Cat,P0,P) :-  
    rule(Cat, Daughters),  
    parse_daughters(Daughters,P0,P).  
  
parse_daughters([],List,List).  
parse_daughters([D1|Daughters],P0,P) :-  
    parse(D1,P0,P1),  
    parse_daughters(Daughters,P1,P).  
  
?- parse(s,Words,[]).
```

Bottom-up ontleding

- ▶ Begin bij de input (woorden),
- ▶ Bepaal de categorieën van de woorden,
- ▶ Combineer categorieën tot zinsdelen,
- ▶ Combineer zinsdelen tot grotere zinsdelen
- ▶ **Geen problemen met links-recursieve regels!**

Bottom-up ontleding

de hond snurkt
Det *hond snurkt*
Det N *snurkt*
NP *snurkt*
NP V
NP VP
S



Shift-reduce algoritme

- ▶ **Stack:** Een stapel van reeds gevonden zinsdelen,
- ▶ **Shift:** Verwijder het meest linkse element W van de input, en zet de categorie C van W op de stack.
- ▶ **Reduce:** Vervang $C_1..C_n$ op de stack door C_0 mits er een regel $C_0 \rightarrow C_1..C_n$ bestaat.

Shift-reduce Algoritme

stap	invoer	stapel	actie
1.	<i>de hond snurkt</i>	[]	<i>shift</i>
2.	<i>hond snurkt</i>	[Det]	<i>shift</i>
3.	<i>snurkt</i>	[Det N]	<i>reduce</i>
4.	<i>snurkt</i>	[NP]	<i>shift</i>
5.		[NP V]	<i>reduce</i>
6.		[NP VP]	<i>reduce</i>
7.		[S]	

Shift-reduce in Prolog

```
%% sr(Input,Stack0,Stack)
sr([],L,L).
sr(Input,Stack0,Stack) :-
    reduce(Stack0,Stack1),
    sr(Input,Stack1,Stack).
sr(Input,Stack0,Stack) :-
    shift(Input,Rest,Cat),
    sr(Rest,[Cat|Stack0],Stack).

parse(Words) :-
    sr(Words,[],[s]).
```


Shift/reduce

```
shift([Wrd|Input],Input,Cat) :-  
    lex(Cat,Wrd).  
  
%% reduce([vp,np|Stack],[s|Stack]). % s -> np, vp  
%% reduce([n,det|Stack],[np|Stack]). % np -> det, n  
  
reduce(Stack0,[Cat|Rest]) :-  
    rule(Cat,Dtrs),  
    reverse(Dtrs,RDtrs),  
    append(RDtrs,Rest,Stack0).
```

Voordelen van shift-reduce algoritme

- ▶ Links-recursie is geen probleem.
- ▶ Omvang van de stack is nooit groter dan aantal woorden in de input.
- ▶ Parsing termineert zolang de grammatica geen cyclische regels bevat.

$\begin{array}{l} np \rightarrow n \\ n \rightarrow np \end{array}$

Maar ...

$$\text{det} \rightarrow \epsilon$$

- ▶ Epsilon-regels voegen een categorie toe aan de stack, zonder dat dit correspondeert met een element van de input;
- ▶ omvang van de stack is niet langer kleiner of gelijk aan de input;
- ▶ epsilon-regels kunnen ertoe leiden dat de parsing niet termineert.

SR en Epsilon's

	String	Stack	actie	regel
1	honden blaffen	[]	sh	
2	honden blaffen	[det]	sh	
3	honden blaffen	[det,det]	sh	
...				

Eliminatie van Epsilons

- ▶ Het effect van epsilon-regels kan ook altijd door regels zonder epsilon bereikt worden,
- ▶ iedere grammatica met epsilons heeft een equivalente grammatica zonder epsilons.

$$\frac{np \rightarrow det \ n \qquad det \rightarrow \epsilon}{np \rightarrow n}$$

Eliminatie van Epsilons

Voor alle regels $C \rightarrow \epsilon$ en
alle regels $M \rightarrow C_1 \dots C_i, \mathbf{C}, C_j \dots C_n,$
voeg toe $M \rightarrow C_1 \dots C_i, C_j \dots C_n.$

Eliminatie van Unaire regels

- ▶ Vergelijkbare constructie

Eliminatie van Epsilons en Unaire regels

- ▶ Kan altijd voor CFG
- ▶ Voor DCG lastiger:
 - ▶ $x(A) \rightarrow x(s(A)).$
 - ▶ $y(s(A)) \rightarrow y(A).$

Parse-strategieën

- ▶ Prolog (DCG) zoekt **top-down, depth-first, links-rechts**
- ▶ Alternatieven:
 - ▶ **Bottom-up**: Begin bij de input (woorden), werk naar de startcategorie (S) toe
 - ▶ **Breadth-first**: Onderzoek alle mogelijke manieren om zinsdelen te vormen parallel
 - ▶ **rechts-links, hoofd-gedreven**
- ▶ Alternatieve methode's zijn (vaak) robuuster en/of efficiënter

Zoeken

- ▶ Prolog (en onze parsers tot nu toe): depth-first met backtracking
- ▶ Alternatief: breadth-first met chart (datastructuur met alle gevonden deelresultaten)
- ▶ Depth-first met backtracking
 - ▶ vaak inefficiënt (rekentijd)
 - ▶ vaak zuinig in geheugengebruik
- ▶ Breadth-first met chart
 - ▶ vaak efficiënt (rekentijd)
 - ▶ vaak enorm geheugengebruik

Depth-first zoeken

- ▶ Als er een **keuze** is (tussen regels, tussen shift en reduce acties);
- ▶ onderzoek je 1 mogelijkheid volledig (**depth-first**);
- ▶ en andere mogelijkheden pas als de eerste keuze faalt;
- ▶ Maakt gebruik van **back-tracking**.

Depth-first parsing

- ▶ DCG: **top-down**, depth-first, link-rechts
- ▶ Shift-reduce: **bottom-up**, depth-first, links-rechts

Nadelen van backtracking

Marie ziet de jongen *met de hond*


Ander nadeel: ongrammaticale input

- ▶ Als de zin niet correct is, heb je niets
- ▶ Liever: geef betekenisvolle delen terug
- ▶ Chart

Chart Parsing

- ▶ Bereken nooit iets twee keer!
- ▶ Bewaar gedeeltelijke resultaten in een tabel (chart),
 - ▶ B.v. een lijst van constituenten die zijn gevonden in de input (*well-formed substring table*).
- ▶ Is toepasbaar voor depth-first en breadth-first

Een chart



Een chart als een lijst

0 Marie 1 ziet 2 de 3 jongen 4 met 5 de 6 hond 7

$\langle 0,1,np \rangle$	$\langle 1,2,v \rangle$	$\langle 2,3,det \rangle$
$\langle 3,4,n \rangle$	$\langle 2,4,np \rangle$	$\langle 1,4,vp \rangle$
$\langle 0,4,s \rangle$	$\langle 4,5,p \rangle$	$\langle 5,6,det \rangle$
$\langle 6,7,n \rangle$	$\langle 5,7,np \rangle$	$\langle 4,7,pp \rangle$
$\langle 1,7,vp \rangle$	$\langle 3,7,np \rangle$	$\langle 0,7,s \rangle$

Chart Parsing

- ▶ **Doel:** Vind alle constituenten in de input,
- ▶ **Succes:** Er is een constituent in de chart die de hele input beslaat en van categorie S is.

Chart Parsing

- ▶ SCANNING

$$\frac{\text{lex}(C, \text{Wrd}), \text{Wrd op positie } i + 1}{\langle i, i + 1, C \rangle}$$

- ▶ COMPLETION

$$\frac{C \rightarrow C_1 C_2, \langle i_0, i_j, C_1 \rangle \quad \langle i_j, i_n, C_2 \rangle}{\langle i_0, i_n, C \rangle}$$

Chart Parser

- ▶ Gebruik *chart* met alle gevonden items
- ▶ Gebruik *agenda* met alle recent toegevoegde items
- ▶ Voor elk item in de agenda bepaal je of er nieuwe items kunnen worden toegevoegd
- ▶ `item(Cat,P0,P,HisList)`

Prolog

```
parse(Sent) :-  
    add_words_to_agenda(Sent,0,P,Agenda),  
    process_agenda(Agenda),  
    extract_tree(s,0,P,Tree).  
  
process_agenda([]).  
  
process_agenda([Item|Agenda]) :-  
    chart_member_check(Item),!,  
    process_agenda(Agenda).  
  
process_agenda([Item|Agenda0]) :-  
    chart_add(Item),  
    findall(NewItem,completion(Item,NewItem),Agenda1),  
    append(Agenda0, Agenda1, Agenda),  
    process_agenda(Agenda).
```

Completion

Alleen regels met 1 of 2 dochters

```
completion(item(D2,P1,P),item(Cat,P0,P)) :-  
    rule(Cat,[D1,D2]),  
    chart_member(item(D1,P0,P1)).
```

```
completion(item(D1,P0,P1),item(Cat,P0,P)) :-  
    rule(Cat,[D1,D2]),  
    chart_member(item(D2,P1,P)).
```

```
completion(item(D,P0,P), item(Cat,P0,P)) :-  
    rule(Cat,[D]).
```

Geschiedenis bijhouden

Deze parser is nog niet ideaal, we houden namelijk niet bij hoe een consituent geconstrueerd is. Bijvoorbeeld in

0 Marie 1 ziet 2 de 3 jongen 4 met 5 de 6 hond 7

kan `item(vp,1,7)` geconstueerd zijn met:

- ▶ `item(vp,1,4)` en `item(pp,4,7)`
- ▶ `item(v,1,2)` en `item(np,2,7)`

Geschiedenis bijhouden (2)

We gaan in een item, `item(Cat,P0,P,HisList)`, een lijstje bijhouden van hoe het geconstrueerd is. Bijvoorbeeld:

```
item(vp,1,7,[r(vp,4,pp),r(v,2,np)])
```


Prolog

```
parse(Sent) :-  
    add_words_to_agenda(Sent,0,P,Agenda),  
    process_agenda(Agenda),  
    extract_tree(s,0,P,Tree).  
  
process_agenda([]).  
  
process_agenda([Item|Agenda]) :-  
    chart_member_check(Item),!,  
    process_agenda(Agenda).  
  
process_agenda([Item|Agenda0]) :-  
    chart_add(Item),  
    findall(NewItem,completion(Item,NewItem),Agenda1),  
    append(Agenda0, Agenda1, Agenda),  
    process_agenda(Agenda).
```

Completion

Alleen regels met 1 of 2 dochters

```
completion(item(D2,P1,P,_),item(Cat,P0,P,[r(D1,P1,D2)])) :-  
    rule(Cat,[D1,D2]),  
    chart_member(item(D1,P0,P1,_)).
```

```
completion(item(D1,P0,P1,_),item(Cat,P0,P,[r(D1,P1,D2)])) :-  
    rule(Cat,[D1,D2]),  
    chart_member(item(D2,P1,P,_)).
```

```
completion(item(D,P0,P,_), item(Cat,P0,P,[r(D)])) :-  
    rule(Cat,[D]).
```

Terugvinden van parsebomen

- Samenpakken van geschiedenis van items

```
chart_member_check(item(Cat,P0,P,His0)) :-  
    chart_delete(item(Cat,P0,P,His1)),  
    append(His0,His1,His),  
    chart_add(item(Cat,P0,P,His)).
```

Terugvinden van parsebomen

- Terugvinden van parseboom:

```
extract_tree(Cat,P0,P,b(Cat,Ds)) :-  
    chart_item(Cat,P0,P,HIS),  
    member(Single,HIS), % kies eentje  
    extract_trees(Single,P0,P,Ds).
```

```
extract_trees(r(D),P0,P,[Tree]) :-  
    extract_tree(D,P0,P,Tree).
```

```
extract_trees(r(D1,P1,D2),P0,P,[Tree1,Tree2]) :-  
    extract_tree(D1,P0,P1,Tree1),  
    extract_tree(D2,P1,P,Tree2).
```

```
extract_trees(lex(Word),[w(Word)]).
```

Chart

- ▶ Resultaat van parsing: chart
- ▶ Bevat (impliciet) alle parses voor de input
- ▶ Elk item kan extra informatie bevatten:
 - ▶ Welke regel voor dit item is gebruikt
 - ▶ Welke items voor elk van de dochters van de regel is gebruikt
- ▶ Compacte representatie van alle parse bomen

Partial parsing

- ▶ Vind alle NPs in de invoer,
- ▶ Geen volledige parse (grammatica) nodig.
- ▶ Gemakkelijk met een chart,
- ▶ Moeilijk (en langzaam) met een shift-reduce parser.

Partial Parsing Experiment

	Runtime (ms)	
Zinnen	Shift-Reduce	Chart
5	804	5
10	1229	12
20	41295	26