

Parsning

Språkteknologi DH2418
Ola Knutsson

Varför parsning?

Grammatikkontroll
Fråge-svarsystem
Maskinöversättning
Semantisk analys (vad menas?)
Testa grammatikformaliser och
“grammatiker” (undvika länsstolslingvistik)

Parsningens olika nivåer

- Deep vs. shallow (djup vs. ytlig)
- Full vs. partial (fullständig vs. partiell)

Flertydig lexikal kategori: Ordklasstagning med disambiguering
Strukturell flertydighet: vi får flera parseträd till en sats.

Hängningsproblem: PP-attachment problem

Jag ser mannen med kikaren.

Han äter pizza med gaffel. Jämför:

Han äter pizza med ansjovis.

Coordination: Jämför:

Hunden eller katten äter fisken och köttet.

Hunden äter köttet och katten äter fisken.

NP problem: *Igår sjöng jag och Jonas Mozart.*

[jag och Jonas Mozart] eller [jag och Jonas] [Mozart]:

Partial och shallow parsning (Partiell och Ytparsning)

- Ofta utan fullständiga träd
- Ger analyser av de allra flesta meningar, robust?
- Behöver man veta satsen fullständiga uppbyggnad? Är det t.ex. endast alla NP man är ute efter?
- Chunking
- Bracketing
- Ytorienterad dependensparsning – ligger mitt emellan, kan innehålla begränsad semantisk information.

Robust parsning

En robust parser skall ge en korrekt eller användbar analys av 90 % av meningar (Briscoe). Åtminstone följande tre problem måste lösas:

1. Tokenisering/Sentensering, vad är en mening?
2. Disambiguation, att välja rätt analys bland alla syntaktiskt möjliga
3. Undergeneration, eller att hantera fall som ligger utanför systemets lexikala och syntaktiska täckning.

Robust parsning II

Ett system måste vara robust mot följande (enligt Menzel 1997):

- Oförutsägbarheten hos autentiska data
- brusiga miljöer (om talaren befinner sig i en larmig miljö)
- variationer mellan talare; dialekt och sociolekt
- ”felaktig” indata jämfört mot språknormen
- ofullständig indata, fragmentarisk
- okända ord och termer
- andraspråkstalare

Disambiguering skall ske på all tre delproblemen

- Utgå ifrån värsta fallet: tilldelning av alla möjliga tolkningar (enligt lexikon)
- Varje regel skall förkasta så många tolkningar som möjligt.
- Regel efter regel tillämpas så länge det går – så länge det finns flertydighet kvar som kan tas bort med reglerna i grammatiken

Kontextvillkor:

(1 N)

(NOT *-1 VFIN)

(1 DT)

(2 N)

(3 VFIN)

Constraint Grammar (CG)

Parsningsalgoritm:

1. Preprocessing
2. Morfologisk analys
3. Morfologisk heuristik
4. Morfologisk disambiguering (“taggning”)
5. Morfosyntaktisk mappning
6. Ytsyntaktisk disambiguering

domain operator target context_conditions

@w – vilket ord som helst (standard)

“<att>” – specifik ordform

=! ! välj tolkning om alla villkor uppfyllda, ta bort tolkning om falska

=! väljer en tolkning och förkastar övriga

=0 förkastar en tolkning sparar övriga

Exempelregler för engelska

(@w =0 VFIN (-1 TO))

Väljer bort finit verb-tolkningen om det föregående ordet är “to”, jmf: to do, *to does

(“<for>” =! (CS) (NOT -1 VFIN) (1 TO) (2 INF) (*3 VFIN))

väljer subjunktion

Preprocessing

*dessa
entreprenöriella
faktorer
hade
än_så_länge
dämpat
explosionen
\$.

150 fasta uttryck, 5000 förkortningar

13

```
"<*dessa>"
"denna" <*> <DEM> <MD> DET UTR/NEU DEF PL NOM @DN>
"denna" <*> <DEM> PRON UTR/NEU DEF PL NOM
"<entreprenöriella>"
"<faktorer>"
"faktor" N UTR INDEF PL NOM
"<hade>"
"ha" <AUX> V ACT PAST
"<än_så_länge>"
"än_så_länge" <COLLOCATION> ADV
"<dämpat>"
"dämpa" V ACT SUPINE
"dämpa" <PCP2> A NEU INDEF SG NOM
"<explosionen>"
"explosion" N UTR DEF SG NOM
"<$.>"
"$." CLB <PUNCT>
```

Analyserat med Swetwol med 75 000 basformer

14

```
"<entreprenöriella>"
"entreprenöriella" <NON-SWETWOL> A UTR/NEU DEF SG NOM
"entreprenöriella" <NON-SWETWOL> A UTR/NEU DEF/INDEF PL NOM
```

Vid test på 10600 ord analyserades 97, 8 % av orden. Resten försökte suffixregler ta hand om.

15

```
"<*dessa>"
"denna" <*> <DEM> <MD> DET UTR/NEU DEF PL NOM @DN>
"denna" <*> <DEM> PRON UTR/NEU DEF PL NOM
"<entreprenöriella>"
"entreprenöriella" <NON-SWETWOL> A UTR/NEU DEF SG NOM
"entreprenöriella" <NON-SWETWOL> A UTR/NEU DEF/INDEF PL NOM
"<faktorer>"
"faktor" N UTR INDEF PL NOM
"<hade>"
"ha" <AUX> V ACT PAST
"<än_så_länge>"
"än_så_länge" <COLLOCATION> ADV
"<dämpat>"
"dämpa" V ACT SUPINE
"dämpa" <PCP2> A NEU INDEF SG NOM
"<explosionen>"
"explosion" N UTR DEF SG NOM
"<$.>"
"$." CLB <PUNCT>
```

16

Morfologisk disambiguering

(@w =0 (A SG) (-1 DET PL) (1 N PL))

(@w =! (DET) (1 A) (2 N))

Hur gör vi med "<dämpat">

17

Mannen NN UTR SIN DEF @SUBJ @OBJ
@IOBJ
spelar VB PRS ACTIVE @+FMV
fotboll NN UTR SIN IND @SUBJ @OBJ
@IOBJ @<P
. CLB <PUNCT>

18

Morfosyntaktisk mappning

Efter ordklassdisambiguering genomförs en morfosyntaktisk mappning:

<matchningsankare kontextvillkor

syntaktiska_taggar>

Ex: ((N) ((-1C PREP) (1 <<<)) (@<P))

N tilldelas den syntaktiska funktionen prepositionskomplement om N föregås av en preposition och följs av meningsslut.

SWECG-regler

((@w !=! (@SUBJ) (1 @+FMV) (NOT *-1 @SUBJ) (NOT *1 @SUBJ))

((@w =0 (@<P) (NOT *-1 PREP) (NOT *1 PREP)

((@w !=! (@+OBJ) (-1 @+FMV) (NOT *-1 @OBJ) (NOT *1 @OBJ))

Jabberwocky (Källgren 1992)

De iggla skviggarna trassade vombigt i den harliga gopen.

- Hurk, najdade den ena skviggen, maffar pem en bunne?
- Snå, bebbade den umre skviggen aldrig. Snafs på nerfen.
- Lytrik snafs det?
- Pej gemmer det fraskar för kloxigt.
- Så vatrik jeggade skviggen snafen bunne.

Gunnel Källgrens Morp-parser

- Den ytliga informationen i en text är underskattad.
- Minimalt lexikon med funktionsord
- Mönstermatchning av morfologiska och ytsyntaktiska mönster.
- Märker orden med ordklass, känner igen enkla NP och PP. (extrauppgift?)

Parsning med Finite-state

Karttunen, Chanod, Grefenstette & Schiller (1996)

Regular Expressions for Natural Language Engineering

- Välkänt och beprövat för morfologisk analys och generering. Men fungerar också för partiell parsning. Indata=ordklasstagad text
- Ganska enkla operatorer kan användas till sådant som skulle vara komplicerat att uttrycka i andra språk/formalismer:

A, B och C är reguljära uttryck.

A | B Union

A B konkaternering

(A) Optionellt A; union med tomma strängen

A+ Iteration; en eller flera konkaterneringar av A

A* Kleene star; (A+)

~A komplementet(negation)

A & B Snittet, skärning

A – B Subtraktion

restriction: A => B _ C

replacement: A -> B

longest match replacement: A @-> B ... C

Kaskader av regler (regexp)

Indata: de+DT glada+JJ studenterna+NN

```
define AP [Ord JJ]
```

```
define NP = [Ord [PN] | [ (DT) ([AP]+) NN] | [PS ([AP]+) NN]]
```

```
regexp NP @-> "[NP " ... " NP]"
```

Utdata: [NP de+DT glada+JJ studenterna+NN NP]

Indata: [NP de+DT glada+JJ studenterna+NN NP]

```
define HuvudN [NN => _NP]  
regexp HuvudN @-> "[HuvudN" ... "HuvudN]"
```

Utdata: [NP de+DT glada+JJ [HuvudN [studenterna+NN]HuvudN] NP]

GTA – Granska Text Analyzer

Grunddesign:

- Arbetar på ordklasstaggad indata (entydiggjord)
- Tar ibland inte hänsyn till grammatisk/ogrammatisk
- Meningar delas upp i satser, därefter frasanalys. Inga fullständiga träd, varför?

Fraskategorier

NP: Han såg **den lilla mannen** på bänken

VC: Han **har spelat** kort hela natten

PP: Han såg spår **i sanden**

AP: Han ogillade **små vita** lögner

ADVP: Han vill **inte** gå på bio.

INFP: Han tycker om **att spela**.

Regelmatchning/parsning

Varje regel kan appliceras var som helst i texten. Toppen-ner, djupet-först, vänster-höger
Stannar så fort något regelement ej matchar
Optimerad matchning med statistiska medel.
Reglerna förhandsgranskas och ett "regelankare" väljs ut.

Delregler matchas endast när det behövs.
Alla delträd som matchas sparas undan.

En minimal NP


```
Npmin@  
X(wordcl=dt | wordcl=ps)?,  
Y(wordcl=jj)*,  
Z(wordcl=nn | wordcl=pm)  
-->  
action(help, gender:=Z.gender,  
num:=Z.num, if X.wordcl=ps then  
spec:=def else spec:=Z.spec end,  
case:=Z.case)
```

```

Npkonj@
{
  (Npmin/X)(),
  Y(wordcl=kn),
  (Npmin/Z)()
-->
action(help, num:=plu)
}
NP@
{
  Npkonj --> action(help);
  ...;
  Npmin --> action(help)    }

```

The Tetris Algorithm



Grundförutsättningar för fullständig parsning

- Vänster till höger?
- Är orden ordklasstaggade? Entydiggjorda?
- Från första ordet i satsen till sista ordet i satsen.
- Trädet måste ha en rot.
- I vilken ordning tolkas grammatikreglerna?
- Hitta alla träd (alla delträd). Parsning som sökning.
- Backtracking.

Fullparserns huvuduppgifter

- Känna igen orden som bildar grammatiska satser i indata
 - Tolka grammatiken
 - Tilldela struktur
 - Styra hur sökningen sker
- Problem:**
Språkets flertydighet (och grammatikens!)


Toppen-ner parsning

- Mål-driven (goal-directed) sökning
- Utgår från toppnoden (S)
 - Toppen-ner, djupet-först
 - Toppen-ner, bredden-först
 - I vilken ordning tillämpas reglerna?


Botten-upp parsning

Data-driven sökning
Utgår från strängen (data/orden)
Botten-upp, bredden-först


Toppen-ner, djupet-först



Toppen-ner, bredden-först



Botten-upp, bredden-först



Vilka är problemen med dessa två angreppssätt?

Toppen-ner:

- Vänsterrekursion
- Flertydighet från ovan
- Upprepad parsning av delträd (prövar onödiga hypoteser)

Botten-upp:

- Kan söka efter topp-noder och grannkonstituer som inte finns.
- Försöker expandera flertydiga tolkningar av lexikala enheter.

Earleyparsning

- Dynamisk programmering, i det här fallet att spara undan delträd när de påträffas, för senare användning. Delträden läggs i en s.k. chart
- Använder look-up istället för att parsa igen
 - Look-up är mindre komplex än parsning
 - Earley-parsern använder en *Chart*, en lista med $N+1$ ingångar
 - Alla ord i meningen motsvarar en position i charten där de partiella träd som byggts upp hittills lagras
 - När strängen genomlöpts innehåller charten en kompakt representation av flera möjliga analyser av indata
 - Varje ingång i charten har tre typer av information:
 - delträd
 - hur långt man kommit i trädet
 - position i charten

Tre operatorer

Prediktor: skapar nya tillstånd som representerar toppen-ner förväntningar som genereras under parsningsprocessen. Prediktorn tillämpas på varje tillstånd som har en icke-terminal till höger om ”punkten” som inte är en ordklasskategori. Läger upp tillstånd in den ”chart” som processas.

Skanner:

När ett tillstånd har en ordklasskategori till höger om ”punkten”, används skannern för att granska indata om det finns något ord med denna ”förutsagda” ordklasskategori. Här löses en hel del flertydighet upp. Läger upp tillstånd i en ”chart”.

Kompletterare: När ett tillstånd når slutet till höger i en regel backar komplementeraren tillbaka och fyller i kedjan av delanalyser. När t.ex. tillståndet $NP \rightarrow DT\ NN$. [1,3] letar komp. efter tillstånd som slutar på 1, t.ex. $VP \rightarrow VB$. NP [0,1]. Detta resulterar i sin tur i ett nytt komplett tillstånd $VP \rightarrow VB\ NP$. [0,3]. Läger upp tillstånd in den ”chart” som processas.

Tre exempeltillstånd

$S \rightarrow .\ VP$ [0,0]

En toppen-ner prediktion för ett speciellt S

Konstituenten skall börja i startposition av indata (första 0), andra 0 anger ”punktens” placering

$NP \rightarrow Dt .\ Nn$ [1,2]

En NP börjar i position 1, en Dt har parsats, och att en Nn står i tur.

$VP \rightarrow Vb\ NP$. [0,3]

Det finns ett träd VP som spänner över hela indata

Grammatik:

$S \rightarrow NP\ VP$

$S \rightarrow VP$

$NP \rightarrow Dt\ Nn$

$NP \rightarrow Pm$

$VP \rightarrow Vb$

$VP \rightarrow Vb\ NP$

$VP \rightarrow Vb\ NP\ PP$

$PP \rightarrow Prep\ NP$

Lexikon:

$Dt \rightarrow en \mid ett \mid de \mid den$

$Nn \rightarrow köp \mid flyg \mid måltid \mid biljett$

$Vb \rightarrow köp \mid flyga \mid köpa$

$Prep \rightarrow från \mid till$

$Pm \rightarrow Arlanda \mid$

Landvetter

Chart[0]

$\gamma \rightarrow .\ S$ [0, 0] Dummy start

$S \rightarrow .\ NP\ VP$ [0, 0] P

$NP \rightarrow .\ Dt\ Nn$ [0,0] P

$NP \rightarrow .\ Pm$ [0,0] P

$S \rightarrow .\ VP$ [0,0] P

$VP \rightarrow .\ Vb$ [0,0] P

$VP \rightarrow .\ Vb\ NP$ [0,0] P

Chart[1]

$Vb \rightarrow köp .$ [0,1] s

$VP \rightarrow Vb .$ [0,1] c

$S \rightarrow VP .$ [0,1] c

$VP \rightarrow Vb .\ NP$ [0,1] c

$NP \rightarrow .\ Dt\ Nn$ [1,1] p

$NP \rightarrow .\ Pm$ [1,1] p

Chart[2]

$Dt \rightarrow en .$ [1,2] s

$NP \rightarrow Dt .\ Nn$ [1,2] c

Chart[3]

Nn $\rightarrow$ biljett . [2,3] s

NP $\rightarrow$ Dt Nn . [1,3] c

VP $\rightarrow$ Vb NP. [0,3] c

S $\rightarrow$ VP . [0,3] c

Webbtips och extrauppgifter

Functional Dependency Parser:

- www.connexor.com

GTA: <http://skrutten.nada.kth.se/grim/form.html>

Bygg en enkel Morp-parser

Bygg en enkel dependensparser