

Einführung in die Computerlinguistik

Syntax II

WS 2011/2012

Manfred Pinkal

Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UdS Computerlinguistik

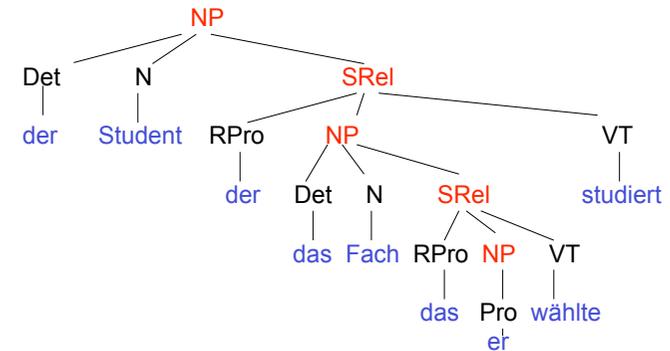
Eine Kostprobe aus dem Rechtswesen

- "Der für die Werkstoffabholung auf der Annahme von drei An- und Abfahrten mit LKW, die Wertstoffe umfüllen, und zwei An- und Abfahrten eines LKW, der zuerst die volle Schrottmulde abholt und diese nach Leerung wiederabliefern, errechnete Beurteilungspegel..."

Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UdS Computerlinguistik

Geschachtelte Strukturen in natürlicher Sprache

[_{NP} der an computerlinguistischen Fragestellungen interessierte Student im ersten Semester, [_{SRel} der [_{NP} das Fach, [_{SRel} das [_{NP} er] nach langer Überlegung gewählt hat]], eifrig studiert]



Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UdS Computerlinguistik

Eine kontextfreie Grammatik für deutsche Sätze

$G_1 = \langle V, \Sigma, P, S \rangle$ mit

$V = \{S, SRel, NP, VI, VT, N, Det, RPro\} \cup \Sigma$

$\Sigma = \{schläft, arbeitet, studiert, wählte, Student, Fach, der, das, er\}$

$S \rightarrow NP VI$

$SRel \rightarrow RPro VI$

$NP \rightarrow Det N (SRel)$

$VI \rightarrow schläft \mid arbeitet$

$N \rightarrow Student \mid Fach$

$Det \rightarrow der \mid das$

$S \rightarrow NP VT NP$

$SRel \rightarrow RPro NP VT$

$NP \rightarrow Pro$

$VT \rightarrow wählte \mid studiert$

$RPro \rightarrow der \mid das$

$Pro \rightarrow er \mid sie$

Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UdS Computerlinguistik

CFG: Konstituentenstruktur

- Anders als endliche Automaten beschreibt eine CFG nicht nur die zulässigen Ausdrücke einer Sprache, sondern gibt ihnen implizit auch eine Struktur.
- Sie ordnet den Sätzen der Sprache Ableitungsbäume zu (auch „Parse-Bäume“ genannt, Parsing = automatische syntaktische Analyse).
- Durch den Ableitungsbaum werden Teilausdrücke (Teilketten) u von Wörtern (Terminalsymbolen) einer „Kategorie“ zugeordnet: dem nicht-terminalen Symbol A, aus dem u abgeleitet wurde. Wir nennen u eine „Konstituente“ von der Kategorie A, und sagen, dass A die Elemente von u „dominiert“.

Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UdS Computerlinguistik

Beispiel 1

CFG für einfache arithmetische Gleichungen:

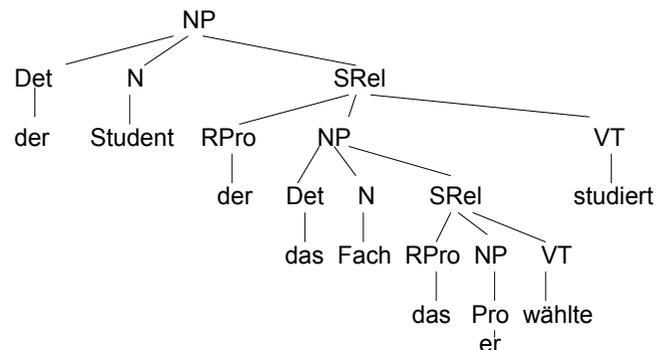
$$\begin{aligned}
 S &\rightarrow \text{Term} = \text{Term} & \text{Term} &\rightarrow x \mid y \mid z \\
 \text{Term} &\rightarrow (\text{Term} \text{Op} \text{Term}) & \text{Op} &\rightarrow + \mid - \mid * \mid : \\
 \text{Term} &\rightarrow - \text{Term}
 \end{aligned}$$

Konstituenten der Kategorie „Term“ sind zum Beispiel $x, y, -z, -(x*(y+z))$

Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UdS Computerlinguistik

Beispiel 2

[_{NP} der an computerlinguistischen Fragestellungen interessierte Student im ersten Semester, [_{SRel} der [_{NP} das Fach, [_{SRel} das [_{NP} er] nach langer Überlegung gewählt hat]], eifrig studiert]]



Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UdS Computerlinguistik

Beispiel 2

- *er* ist eine Konstituente der Kategorie Pro
- *er*, *das Fach*, und *der Student, der Informatik studiert* sind Konstituenten der Kategorie NP
- *der Informatik studiert - der arbeitet* sind Konstituenten der Kategorie SRel

Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UdS Computerlinguistik

CFG: Konstituentenstruktur

- CFGs drücken in eleganter Weise strukturelle Regularitäten aus:
 - „Eine Gleichung besteht aus zwei Termen, die durch ein Gleichheitszeichen verbunden sind“.
- Umgekehrt ausgedrückt: Ersetzungsregeln und Kategorien sollten so gewählt werden, dass die Grammatik in möglichst eleganter Weise strukturelle Regularitäten ausdrückt.
- Das ist trivial für formale Sprachen: Die werden ja explizit mithilfe von CFGs definiert.
- Wie geht man aber bei natürlichen Sprachen vor?

Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UoS Computerlinguistik

Konstituenten-Tests 1: Verschieben

- *Peter hat der Dozentin das neue Übungsblatt heute ins Büro gebracht.*
- *Peter hat der [Dozentin das] neue Übungsblatt heute ins Büro gebracht.*
- *[Peter hat] der Dozentin das neue Übungsblatt heute ins Büro gebracht.*
- *Peter hat der Dozentin [das neue Übungsblatt] heute ins Büro gebracht.*
- *[Das neue Übungsblatt] hat Peter der Dozentin heute ins Büro gebracht.*
- *Der Dozentin hat Peter heute [das neue Übungsblatt] ins Büro gebracht.*
- *Heute hat Peter [das neue Übungsblatt] der Dozentin ins Büro gebracht.*

Verschiebetest: Teilketten, die sich (nur) gemeinsam im Satz verschieben lassen, sind (tendenziell) Konstituenten

Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UoS Computerlinguistik

Konstituenten-Tests 2: Substituieren

- *[_{NP} Er] hat die Übungen gemacht.*
- *[_{NP} Peter] hat die Übungen gemacht.*
- *[_{NP} Der Student] hat die Übungen gemacht.*
- *[_{NP} Der an computerlinguistischen Fragestellungen interessierte Student] hat die Übungen gemacht.*

Substitutionstest: Lassen sich Wortfolgen in einem gegebenen Kontext füreinander ersetzen, handelt es sich (vermutlich) um Konstituenten der gleichen Kategorie.

Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UoS Computerlinguistik

Konstituenten-Tests 3: Vorfeldbesetzung

- *[_{NP} Peter] hat der Dozentin das Übungsblatt heute ins Büro gebracht.*
- *[_{NP} Das Übungsblatt] hat Peter der Dozentin heute ins Büro gebracht.*
- *[_{NP} Der Dozentin] hat Peter heute das Übungsblatt ins Büro gebracht.*
- *[_{PP} Ins Büro] hat heute Peter der Dozentin das Übungsblatt gebracht.*
- *[_{Adv} Heute] hat Peter das Übungsblatt der Dozentin ins Büro gebracht.*

"**Verb-Zweit**" bietet einen verlässlicher Konstituententest fürs Deutsche: Vor dem finiten Verb im Hauptsatz ("Vorfeld") steht (im allgemeinen) genau eine Konstituente.

Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UoS Computerlinguistik

Weitere Kriterien für Konstituentenstruktur

- Distributionelle Eigenschaften:
 - Verschiebbarkeit, Substituierbarkeit
- Strukturelle Eigenschaften:
 - Komplexe Ausdrücke besitzen tendenziell einen „Kopf“, der ihren grammatischen Charakter bestimmt
 - Beispiel: Nominalausdrücke besitzen einheitlich als „Kopf“ ein Substantiv oder ein Pronomen
- Semantisches Kriterium:
 - Konstituenten beschreiben sinnvolle Bedeutungseinheiten
 - Beispiel: Nominalausdrücke bezeichnen/ "denotieren" Entitäten (Personen und Objekte)

Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UdS Computerlinguistik

Kategoriale Ebenen

- **Lexikalische Kategorien** („Präterminale Symbole“): Sie bilden die linke Seite von Regeln, deren rechte Seite aus einem Terminalsymbol (lexikalischen Ausdruck) besteht, z.B. N, A, V, Det, Pro, ...
- **Phrasale Kategorien** wie NP und PP, die „maximale Konstituenten“ bezeichnen, die im Satz eine relative Unabhängigkeit besitzen: kommen als „Satzteile“ innerhalb von anderen Phrasen vor, lassen sich verschieben, können nicht durch anderes Material unterbrochen werden.
- **Zwischenkategorien**: Hier nimmt man meist genau eine weitere Ebene an, die zwischen der phrasalen und der lexikalischen Ebene vermittelt. Sie werden üblicherweise als N', A', V' etc. notiert, alternativ mit einem Überstrich, daher als „N-Bar“, „V-Bar“ etc. ausgesprochen.

Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UdS Computerlinguistik

Phrasale Kategorien

- Für die drei „großen“ oder „offenen“ Wortarten Substantiv, Verb und Adjektiv und die Präpositionen werden üblicherweise vier **lexikalische Hauptkategorien** (N, V, A und P) angenommen.
- Entsprechend nimmt man vier **phrasale Hauptkategorien** (NP, VP, AP, PP) an, die Ausdrücke der jeweiligen lexikalischen Kategorie als Kopf besitzen:
 - **Nominalphrasen**: *der interessierte Student – die Übungen – computerlinguistische Fragestellungen*
 - **Präpositionalphrasen**: *an computerlinguistischen Fragestellungen – im ersten Semester – nach langer Überlegung*
 - **Adjektivphrasen**: *an computerlinguistischen Fragestellungen interessiert(e), sehr schön, viel größer als Peter*
 - **Verbphrasen**: *studiert Informatik – entscheidet sich für das Fach*

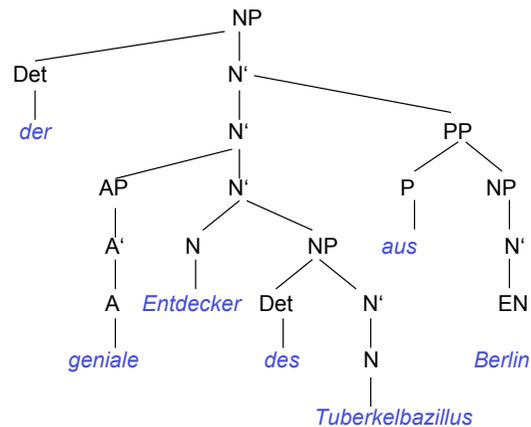
Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UdS Computerlinguistik

NP-Struktur

- NP-Struktur im Deutschen (vereinfacht)
 - NP → EN | Pro | Det N'
 - N' → AP N'
 - N' → N' PP
 - N' → N (NP)

Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UdS Computerlinguistik

NP-Struktur: Ein Beispiel



Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UdS Computerlinguistik

Kategorie und Funktion

- **Syntaktische Kategorien** bezeichnen Klassen von Ausdrücken mit ähnlicher innerer Struktur und ähnlichem distributionellem Verhalten.
- **Grammatische Funktionen** dagegen bezeichnen die Rolle, die eine Konstituente im größeren Ausdruck spielt. Eine NP kann, je nach Stellung im Satz unter anderem die Funktion von **Subjekt** oder (direktem oder indirektem) **Objekt** eines Satzes, (Genitiv-) **Attribut** einer anderen NP oder **Argument** einer Präpositionalphrase bilden. - Grammatische Funktionen sind relationale Konzepte!
- Unterschiedliche Kategorien können die gleiche Funktion ausüben: Subjekte können zum Beispiel Nominalphrasen oder Sätze sein:
 - *Dass es regnet, ist lästig*
 - *Der Regen ist lästig.*

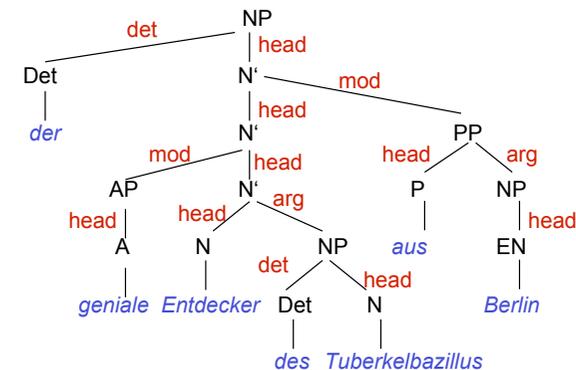
Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UdS Computerlinguistik

Grammatische Funktionen

- **Köpfe** sind die Kernbestandteile einer Konstituente, die für den syntaktischen „Charakter“ der Phrase verantwortlich sind. Die Merkmale des „lexikalischen Kopfes“ vererben sich über die „Kopflinie“ nach oben zur Phrase.
- **Argumente** werden durch lexikalische Köpfe „subkategorisiert“ oder „regiert“: Ein lexikalischer Ausdruck (V, N, A, P) kann ein oder mehrere Argumente mit bestimmten grammatischen Eigenschaften verlangen. Verbarargumente sind Subjekt, direktes Objekt, Präpositionales Objekt etc.; Substantive können Argumente als PP oder als Genitivattribut realisieren; die PP nimmt eine NP als Argument.
- **Modifikatoren** sind freie Ergänzungen, die einen Ausdruck erweitern, ohne seine Kategorie zu verändern. Nominale Modifikatoren heißen **Attribute** (pränominaler AP, postnominaler PP, Relativsatz), Satzmodifikatoren **Adjunkte** (auch „adverbiale Bestimmungen“).

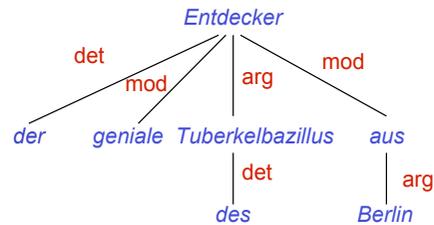
Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UdS Computerlinguistik

Grammatische Funktionen



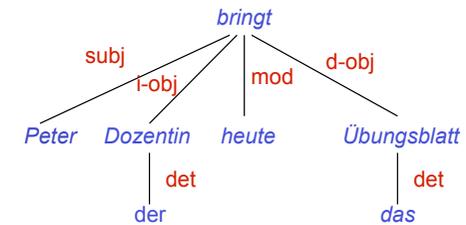
Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UdS Computerlinguistik

Dependenzgrammatik: Beispielstruktur



Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UoS Computerlinguistik

Dependenzgrammatik: Beispielstruktur2



Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UoS Computerlinguistik

Kontextfreie Grammatik und Dependenzgrammatik

- Dependenzgrammatiken unterscheiden zwischen **funktionaler Struktur** (die im Dependenzbaum dargestellt wird) und **Wortstellung**, die durch separate Bedingungen geregelt wird: „Lineare Präzedenzregeln“.
- Dependenzgrammatiken eignen sich deshalb zur Modellierung von Sprachen mit **variabler oder freier Wortstellung**.
- Dependenzstrukturen sind „**semantiknäher**“ als Konstituentenstrukturen. Sie eignen sich deshalb besser als Grundlage für die semantische Interpretation.
- CFG-basierte Grammatiktheorien haben in der Linguistik und Computerlinguistik jahrzehntelang das Feld beherrscht. Seit einigen Jahren haben Dependenzgrammatiken stark an Bedeutung gewonnen.

Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UoS Computerlinguistik

Syntaktische Struktur und semantische Interpretation

93.000€ in Gütersloh gefunden in der Handtasche einer Rentnerin, die auf einem Friedhof am Lenker eines Fahrrads baumelte.

Aus dem Spiegel, Rubrik „Hohlspiegel“

Vorlesung "Einführung in die CL" 2011/2012 © M. Pinkal UoS Computerlinguistik

Syntaktische Struktur und semantische Interpretation

- Die syntaktische Struktur ist Grundlage für die semantische Interpretation.
- Beispiel Arithmetik:
 - Terme bezeichnen („bedeuten“) Zahlen
 - Operatoren bilden (Paare von) Termbedeutungen/Zahlen auf Termbedeutungen/Zahlen ab.
 - Bedeutung einer Gleichung ist ein Wahrheitswert.
- Die Bedeutung des Gesamtausdrucks wird „kompositionell“, entlang der syntaktischen Struktur berechnet.
- Strukturelle Mehrdeutigkeit, wenn Klammern und Klammerkonventionen fehlen. Beispiel: „3+4*5“: =23 oder =60?

Grammatische Mehrdeutigkeit

- Grammatiken für formale Sprachen werden so definiert, dass strukturelle Mehrdeutigkeit in jedem Fall vermieden wird.
- Natürliche Sprachen **sind** strukturell mehrdeutig:

Peter sah den Mann mit dem Teleskop

- Eine Grammatik, die die Mehrdeutigkeit modelliert:

$S \rightarrow NP VP$ $NP \rightarrow ART N' | EN$ $N' \rightarrow N' PP$ $N' \rightarrow N (NP)$
 $VP \rightarrow V'$ $V' \rightarrow V' PP$ $V' \rightarrow VT NP$ $V' \rightarrow VI$
 $PP \rightarrow P NP$

- Die zwei Analysevarianten (Zwischenknoten z.T. weggelassen)
 - [_S Peter [_{VP} sah [_{NP} den [_{N'} Mann [_{PP} mit dem Teleskop]]]]]
 - [_S Peter [_{VP} [_{V'} sah [_{NP} den Mann]] [_{PP} mit dem Teleskop]]]