

CFG-Parsing

CFG-Parsing

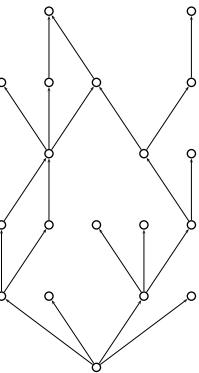
- rein strukturelle Mehrdeutigkeit
 - [NP der Mann [PP mit dem Hut [PP auf der Stange]]]
 - [NP der Mann [PP mit dem Hut] [PP auf der Stange]]
 - ... weil [NP dem Sohn des Meisters] / [NP Geld] fehlt.
 - ... weil [NP dem Sohn] / [NP des Meisters Geld] fehlt.
- lokale Mehrdeutigkeiten
 - können im weiteren Verlauf der Analyse aufgelöst werden
 - globale Mehrdeutigkeiten
 - bleiben bis zum Abschluss der Analyse bestehen



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 9



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 10



- Parsing als Suche
 - alternative Regelanwendungen spannen einen Suchraum auf

CFG Parsing

CFG Parsing

- kontextfreie Phrasenstrukturregeln werden möglichcherweise erst im Parser generiert
- ID/LP-Grammatiken
 - $S \rightarrow \{NP, VP\}$ $NP < VP$
- LP-Constraints meist auf der Basis von Merkmalen für komplexe Kategorien formuliert



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 11



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 12

CFG Parsing

CFG Parsing

- Dependenzgrammatiken
 - Valenzmuster
- "flache" Phrasenstrukturregel
 - "tief" Phrasenstrukturregeln
- $S \rightarrow C1_{SUBJ} VFIN C2_{DOBJ}$
- $S \rightarrow C1_{SUBJ} C2_{VP}$
- $C2_{VP} \rightarrow VFIN C3_{DOBJ}$



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 12

Parsingstrategien

Parsingstrategien

erwartungsgesteuert (top-down, expand-reduce)

- Problem: links-/rechtsrekursive Regeln verursachen Terminierungsprobleme
 - auch über mehrere Regeln hinweg:
 $X \rightarrow Y a$
 $X \rightarrow Y$
- Lösung: Transformation in schwach äquivalente Grammatik ohne Links-/Rechtsrekursion



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 13

datengesteuert (bottom-up, shift-reduce)

- Problem: leere Produktionen
 - eventuell "Lizenierung" durch lexikalische Knoten
- Problem: unäre Regeln, die Zyklen bilden
 - vermeiden



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 14

Parsingstrategien

Parsingstrategien

erwartungsgesteuert (top-down, expand-reduce)

- Problem: links-/rechtsrekursive Regeln verursachen Terminierungsprobleme
 - auch über mehrere Regeln hinweg:
 $X \rightarrow Y a$
 $X \rightarrow Y$
- Lösung: Transformation in schwach äquivalente Grammatik ohne Links-/Rechtsrekursion



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 14

Parsingstrategien

Parsingstrategien

erwartungsgesteuert (bottom-up, shift-reduce)

- Problem: leere Produktionen
 - eventuell "Lizenierung" durch lexikalische Knoten
- Problem: unäre Regeln, die Zyklen bilden
 - vermeiden



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 14

Parsingstrategien

Parsingstrategien

- Tiefe zuerst
 - alternative Regelanwendungen werden erst später untersucht
 - Speicherung auf einem Stack
- Breite zuerst
 - alternative Regelanwendungen werden "gleichzeitig" abgearbeitet
 - Verwaltung der Alternativen in einer Warteschlange



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 15



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 16

Parsingstrategien

- gemischte Strategien
 - Left-Corner-Parsing: Top-down-Analyse mit Aktivierung der Regeln durch die linke Ecke
 - Robustheit gegenüber fehlerhaften Input: bottom up-Analyse mit top down-Rekonstruktion im Fehlerfall (MELLISSH 1989)
 - Inselparsing: bidirektionale Analyse von sicheren Hypothesen ausgehend (z.B. Spracherkennung)



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 17

Tabellenparsing

- Effizienzproblem: Mehrfachanalysen in unterschiedlichen Analysepfaden
 - Daten
 - Deutsch mit kopffinaler Verbgruppe
 - Normalfall: Nebensatzreihung
 - ... weil der Vater seine Kinder liebt.
 - ... weil der Vater seinen Kindern ein Eis versprach.
 - ... weil der Vater seinen Kindern mit einer Strafe droht.



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 18

Tabellenparsing

Grammatik

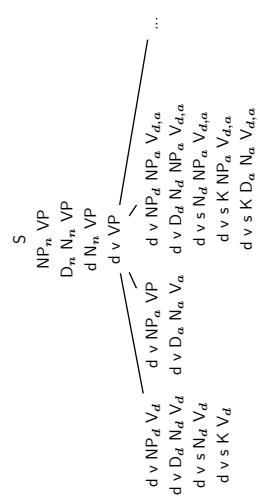
$$\begin{aligned} S &\rightarrow \text{Konj } S \\ S &\rightarrow NP_n VP \\ VP &\rightarrow NP_a V_a \\ VP &\rightarrow NP_d V_d \\ VP &\rightarrow NP_d NP_a V_{d,a} \\ VP &\rightarrow NP_d PP_{mit,d} V_{d,mit} \\ NP_X &\rightarrow D_X N_X \\ PP_{X,Y} &\rightarrow P_X NP_Y \\ \end{aligned}$$

- Beispielanalyse: top-down, Tiefe-zuerst
 - ... der Vater **seinen** Kindern ein Eis versprach.



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 19

Tabellenparsing



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 20

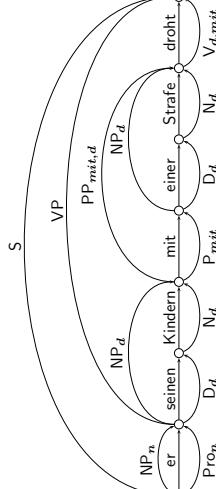
Tabellenparsing

Well-formed Substring Table (Chart)

- gerichteter azyklischer Graph mit
 - einer Quelle (Satzanfang)
 - einer Senke (Satzende) und
 - einer totalen Präzedenzrelation über den Knoten
 - Kanten entsprechen erfolgreich erkannten Konstituenten



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 21



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 22

Tabellenparsing

- Cocke-Younger-Kasami-Algorithmus (KASAMI 1965, YOUNGER 1967)
 - Grammatik in Chomsky-Normalform
 - binärverzweigende Regeln: $X \rightarrow Y Z$
 - präterminale Regeln: $X \rightarrow a$



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 23

	1	2	3	4	5	6	7
0 er NP_n							S
1 seinen D_d			NP_d				VP
2 Kindern N_d			Kindern N_d	mit P_mit		PP_mit	
3 er D_d			er D_d		NP_d		
4 NP_d					NP_d		
5 Strafe N_d					Strafe N_d		
6 droht V_d,mit						droht V_d,mit	

Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 24

Tabellenparsing

Tabellenparsing

■ CYK: Eigenschaften

1. Länge der Ableitung konstant:
n lexikalische Regeln + n-1 syntaktische Regeln
 $((\text{a})) (\text{b} \text{ c} \text{ d})$
 $((\text{a} \text{ b})) (\text{c} \text{ d})$
 $((\text{a} \text{ b} \text{ c})) (\text{d})$
2. Anzahl der Binärzerlegungen eines Satzes ist konstant: n-1
 Überdeckung der Eingabekette entfallen
 $\text{VP} \rightarrow \text{NP NP V}$
 $\text{VP} \rightarrow \text{NP V}$
 $\text{VP} \rightarrow \text{V}$
3. Strukturelle Mehrdeutigkeiten durch unterschiedliche
 Überdeckung der Eingabekette entfallen
 $\text{VP} \rightarrow \text{NP NP V}$
 $\text{VP} \rightarrow \text{NP V}$
 $\text{VP} \rightarrow \text{V}$



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 25

Tabellenparsing

■ Bottom up-Analyse

- Zeitbedarf $\mathcal{O}(n^3)$
- Speicherbedarf $\mathcal{O}(n^2)$
- durch Wiederverwendung von Zwischenergebnissen
- Nachteil: es werden immer noch Konstituenten generiert, die in keine übergegenden Strukturen eingebaut werden können
 → EARLEY-Parser



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 27

Chart-Parsing

■ Aktive Chart

- Erweiterung: auch Versuche einer Regelanwendung werden in die Chart eingetragen
- Aktive Kanten:
 offene Erwartungen für den rechten Kontext
 Notation: $\langle \text{a}, \text{b}, \text{A} \rightarrow \text{B . C D} \rangle$
- Inaktive Kanten:
 vollständig gesättigte Erwartungen für den rechten Kontext
 Notation: $\langle \text{a}, \text{b}, \text{A} \rightarrow \text{B C D .} \rangle$



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 26

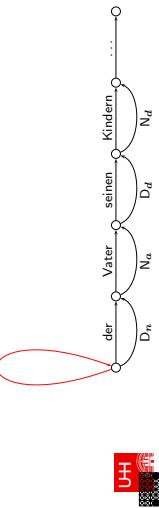
Chart-Parsing

■ TD-Regel (Initialisierung)

Für alle Regeln $\text{A} \rightarrow w_1$ bei denen A ein Startsymbol der Grammatik ist, füge eine Kante $\langle \text{0}, \text{0}, \text{A} \rightarrow \cdot, w_1 \rangle$ in die Chart ein.

■ Regel: $S \rightarrow \text{NP}_n \text{ VP}$

$S \rightarrow \text{NP}_n \text{ VP}$



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 29

Chart-Parsing

■ TD-Regel (Kanteneinführung)

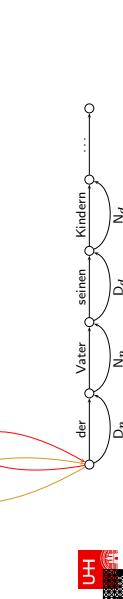
Beim Eintragen einer Kante $\langle \text{i}, \text{j}, \text{A} \rightarrow w_1 \cdot \text{B } w_2 \rangle$ ergänze für jede Regel $\text{B} \rightarrow w_3$ eine Kante $\langle \text{j}, \text{j}, \text{B} \rightarrow \cdot, w_3 \rangle$.

■ Regel: $\text{NP}_x \rightarrow \text{D}_x \text{ N}_x$

$S \rightarrow \text{NP}_n \text{ VP}$

$\text{NP}_n \rightarrow \cdot, \text{D}_n \text{ N}_n$

$\text{D}_n \rightarrow \text{NP}_n \text{ VP}$



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 30

Chart-Parsing

■ Fundamentalsregel (Kantenexpansion)

Enthält die Chart zwei Kanten $\langle \text{i}, \text{j}, \text{A} \rightarrow w_1 \cdot \text{B } w_2 \rangle$ und $\langle \text{i}, \text{k}, \text{B} \rightarrow w_3 \cdot \rangle$, dann füge eine dritte Kante $\langle \text{j}, \text{k}, \text{A} \rightarrow w_1 \text{ B . } w_2 \rangle$ hinzu.

$S \rightarrow \cdot, \text{NP}_n \text{ VP}$

$\text{NP}_n \rightarrow \cdot, \text{D}_n \text{ N}_n$



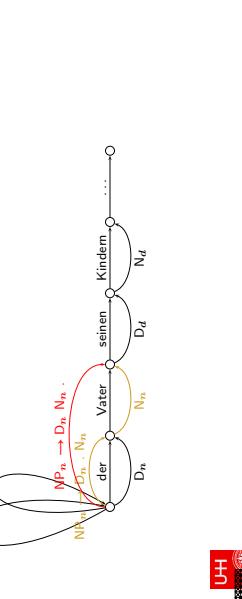
Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 31

Chart-Parsing

■ Erneute Anwendung der Fundamentalsregel

$S \rightarrow \cdot, \text{NP}_n \text{ VP}$

$\text{NP}_n \rightarrow \cdot, \text{D}_n \text{ N}_n$

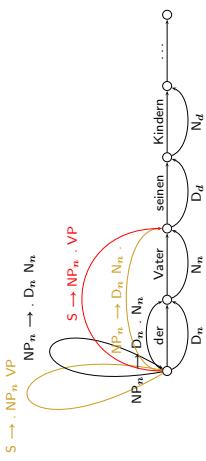


Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 32

Chart-Parsing

Chart-Parsing

■ Erneute Anwendung der Fundamentalsregel



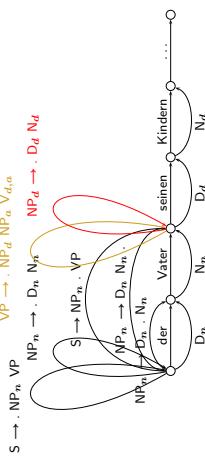
Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 33



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 34

Chart-Parsing

■ Erneute Anwendung der Top-Down-Regel



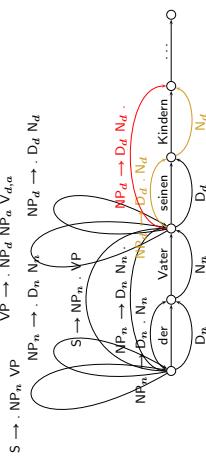
Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 35



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 36

Chart-Parsing

■ Erneute Anwendung der Fundamentalsregel



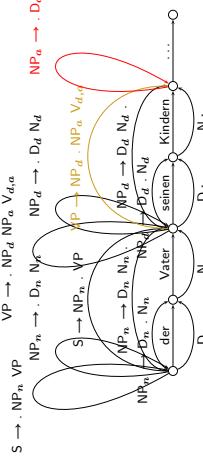
Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 37



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 38

Chart-Parsing

■ Erneute Anwendung der Top-Down-Regel

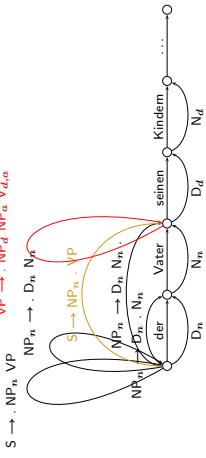


Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 39



Chart-Parsing

■ Erneute Anwendung der Top-Down-Regel



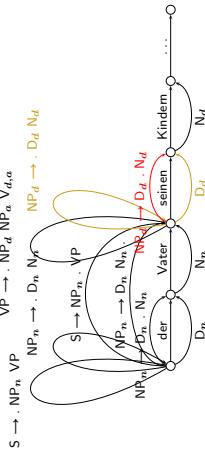
Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 33



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 34

Chart-Parsing

■ Erneute Anwendung der Fundamentalsregel



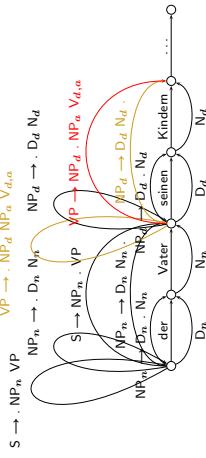
Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 36



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 38

Chart-Parsing

■ Erneute Anwendung der Fundamentalsregel



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 38



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 39

Chart-Parsing

■ Earley-Algorithmus (EARLEY 1970)

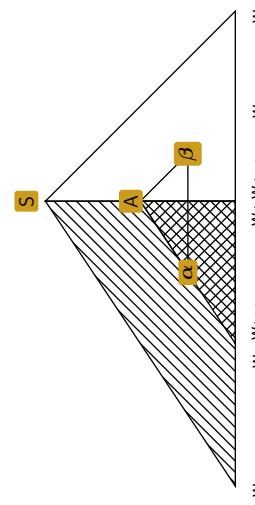
- für beliebige CF-Grammatiken
 - auch mit Rekursion, Zyklen und Tilgungen
 - gemischte Top down/Bottom up-Strategie, um die Erzeugung nicht weiter verwendbarer Konstituenten weitgehend zu vermeiden
1. Top-Down-Bedingung:
es werden nur solche Kanten generiert, deren linker Kontext mit der Grammatik verträglich ist
 2. Bottom up-Bedingung:
der bereits abgearbeitete Regelteil muß sich auf die Daten ableiten lassen

Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 40



Chart-Parsing

Chart-Parsing



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 41



Chart-Parsing

■ EARLEY-Algorithmus

1. Initialisierung

$$\text{für alle } (S \rightarrow \beta) \in R: \text{CHART}_{0,0} \leftarrow \langle S, \emptyset, \beta \rangle$$

wende EXPAND solange auf die zuvor erzeugten Kanten an,
bis keine neuen Kanten mehr erzeugt werden können.

2. Berechnung der übrigen Kanten

für $i = 0, \dots, n$:

berechne $\text{CHART}_{1,j}$:

1. wende SHIFT auf alle geeigneten Kanten in $\text{CHART}_{i,j-1}$ an
2. Vende EXPAND und COMPLETE solange an, bis keine neuen Kanten mehr erzeugt werden können.

wenn $\langle S, \beta, \emptyset \rangle \in \text{CHART}_{0,n}$
dann RETURN(true) sonst RETURN(false)

Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 43

Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 41



Chart-Parsing

■ Chart-basierte Algorithmen sind nur Erkennen

■ Erweiterung zum Parser:

- Extraktion von Strukturbäumen (Ableitungen) aus der Chart in einem separaten Schritt
- Grundlage: Verwaltung eines Verweises auf die verursachende Kante in der Fundamentalregel
- "Aufsammler" der Bäume beginnend bei allen vollständigen S-Kanten

Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 44



Chart-Parsing

■ Ressourcenbedarf: Speicher

$$\mathcal{O}(n^2)$$

- für deterministische Grammatiken: $\mathcal{O}(n^2)$
- in vielen praktisch relevanten Fällen: $\mathcal{O}(n)$

■ Zeitkomplexität nur für das Aufbauen der Chart

- Resultatextraktion kann bei exponentiell vielen Resultaten exponentiellen Aufwand erfordern

Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 46



Chart-Parsing

■ Anwendung der Fundamentalregel

Beim Eintragen einer Kante $\langle i, j, B \rightarrow w_1 \rangle$ ergänze
für jede Regel $A \rightarrow B$ eine Kante $\langle i, i, A \rightarrow . B, w_1 \rangle$

$$\text{NP}_n \rightarrow . D_n N_n$$

$$\text{NP}_d \rightarrow . D_d N_d$$



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 46



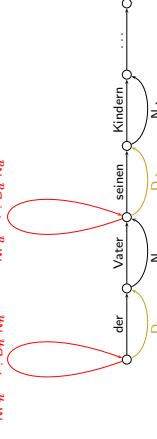
Chart-Parsing

■ Bottom-Up-Regel (Kanteneinführung)

Beim Eintragen einer Kante $\langle i, j, B \rightarrow w_1 \rangle$ ergänze
für jede Regel $A \rightarrow B$ eine Kante $\langle i, i, A \rightarrow . B, w_1 \rangle$

$$\text{NP}_d \rightarrow . D_n N_n$$

$$\text{NP}_n \rightarrow . D_d N_d$$



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 47

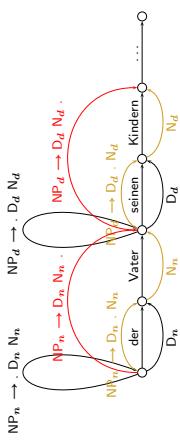
Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 48



Chart-Parsing

Chart-Parsing

Anwendung der Fundamentalregel

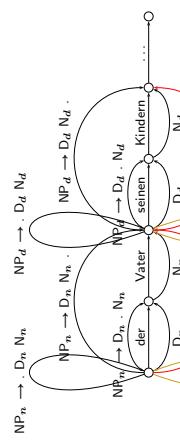


Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 49



Chart-Parsing

Anwendung der Fundamentalregel



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 51



Chart-Parsing

Agenda

- Liste der aktiven Kanten
- beliebig sortierbar
- Kellerspeicher: Tiefe-zuerst
- Warteschlange: Breite zuerst
- TD-Regel: erwartungsgesteuerte Analyse
- BU-Regel: datengesteuerte Analyse

Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 53



Chart-Parsing

best-first-Parsing

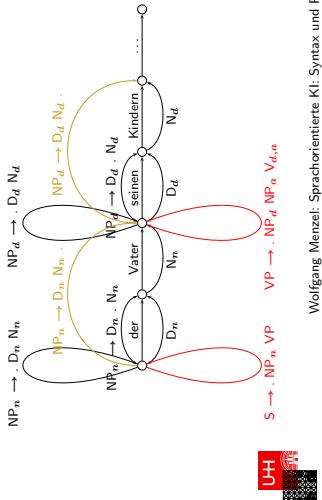
- Sortieren der Agenda nach Konfidenzwerten
- Hypothesenbewertungen der Spracherkennung
- Regelbewertungen (z.B. Häufigkeit in Korpus)

Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 55



Chart-Parsing

Anwendung der Bottom-Up-Regel

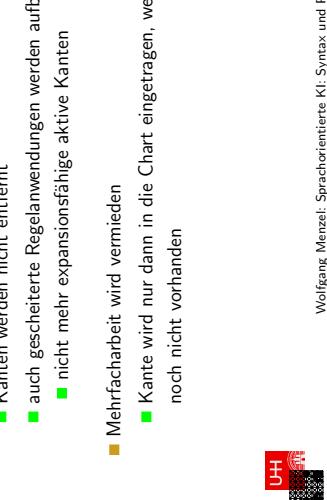


Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 49



Chart-Parsing

Anwendung der Bottom-up-Regel



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 52



Chart-Parsing

Chart wächst monoton

- Kanten werden nicht entfernt
- auch gescheiterte Regelauswendungen werden aufbewahrt
- nicht mehr expansionsfähige aktive Kanten
- Mehrfacharbeit wird vermieden
- Kante wird nur dann in die Chart eingetragen, wenn dort noch nicht vorhanden

Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 54



Chart-Parsing

Aufgabe der Verbundenheit des Hypothesengraphen:

- Lattice-Parsing
- Worthypothesegraphen bei der Verarbeitung gesprochener Sprache
- Tabelle mit der Zuordnung zwischen Regeln und ihren möglichen linken Ecken wird aus der Grammatik berechnet
- z.B. Ergebnisse einer HMM-Worterkennung
- Aufgabe der Verbundenheit des Hypothesengraphen:
- Grid-Parsing
- z.B. Ergebnisse eines Wordspotters mit Hypothesalternativen

Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 56



Stochastisches Parsing

Stochastisches Parsing

- Ergebnismehrdeutigkeit

- *Hinter dem Betrug werden die gleichen Täter vermutet, die während der vergangenen Tage in Griechenland gefälschte Banknoten in Umlauf brachten.*
- Parigram (KUHN UND ROHRER 1997): 92 Lesarten
- Gepard (LANGER 2001): 220 Lesarten



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 64

Stochastisches Parsing

- Ergebnismehrdeutigkeit

- *Hinter dem Betrug werden die gleichen Täter vermutet, die während der vergangenen Tage in Griechenland gefälschte Banknoten in Umlauf brachten.*
- Parigram (KUHN UND ROHRER 1997): 92 Lesarten
- Gepard (LANGER 2001): 220 Lesarten
- durchschnittliche Ambiguität über ein Zeitungstextkorporus: 78 bei einer mittleren Satzlänge von 11-43 syntaktischen Wörtern (Gepard)
- Extremfall: $6 \cdot 4875 \cdot 10^{22}$ Lesarten für einen Satz (BLOCK 1995)



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 64

Stochastisches Parsing

- Ambiguitätsquellen:

- lexikalische Mehrdeutigkeit
- Attachment
- *We saw the Eiffel Tower flying to Paris.*
- Koordination:
- *alte Männer und Frauen*
- NP-Klammerung
- *... der Sohn des Meisters Geld*



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 64

Stochastisches Parsing

- Beispiel: PP-Attachment

der Ball mit den Punkten in der Tasche auf dem Tisch

- wächst exponentiell (Catalan) mit der Anzahl der PPs

$$C(n) = \frac{1}{n+1} \binom{2n}{n}$$

# PPs	# Parses
2	2
3	5
4	14
5	132
6	469
7	1430
8	4867



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 66



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 67

Stochastisches Parsing

- Ausweg: stochastische kontextfreie Grammatiken (PCFG)
- Schätzen von Ableitungswahrscheinlichkeiten für alle Regeln

$$\Pr(N \rightarrow \zeta)$$

bzw.

$$\Pr(N \rightarrow \zeta | N) \quad \text{mit} \quad \sum_{\zeta} \Pr(N \rightarrow \zeta) = 1$$

z.B.

$S \rightarrow NP VP$	0.8
$S \rightarrow Aux NP VP$	0.15
$S \rightarrow VP$	0.05

Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 68

Stochastisches Parsing

- Abdeckung (coverage)

■ partieller Parser (WAUTSCHKUHN 1996): 56..5% der Sätze

■ Gepard: 33..51%

- auf Testsuites (bessere Lexikonabdeckung, kürzere und weniger ambige Sätze) bis zu 66%



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 67

Stochastisches Parsing

- Sprachmodelle: Zuordnung einer Wahrscheinlichkeit zu einer Terminalkette

$$\Pr(w_{1,n}) = \sum_{t_{1,n}} \Pr(t_{1,n})$$

(mehrere Ableitungen für einen Satz)

$$= \sum_{t_{1,n}} \prod_{r_j \in t_{1,n}} \Pr(r_j)$$

■ Ermittlung der wahrscheinlichsten Wortfolge



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 69

Stochastisches Parsing

Stochastisches Parsing

- Disambiguierung: Ermittlung der wahrscheinlichsten Ableitung

$$t_{1,n} = \arg \max_{t_{1,n} \in T} \Pr_{r_j \in t_{1,n}} \Pr(r_j)$$

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 70

Stochastisches Parsing

- Evaluation von Parsern (PARSEVAL, BLACK ET AL. 1991)
- Vergleich mit einer Referenzannotation (*gold standard*)
- labelled recall

$$LR = \frac{\# \text{ korrekte Konstituenten im Resultat}}{\# \text{ Konstituenten im Referenz}}$$

- labelled precision

$$LP = \frac{\# \text{ korrekte Konstituenten im Resultat}}{\# \text{ Konstituenten im Resultat}}$$

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 72

Stochastisches Parsing

- crossing brackets
- Ein Konstituent eines Parsebaumes enthält Teile von zwei Konstituenten aus der Referenz, ohne dass die beiden vollständig im Parsergebnis enthalten sind.

$$\begin{array}{c} \text{Resultat: } [\ [A \ B \ C] \ [D \ E \]] \\ \text{Referenz: } [\ [A \ B \] \ [C \ D \ E \]] \end{array}$$

$$CB = \frac{\# \text{ crossing brackets}}{\# \text{ Sätze}}$$

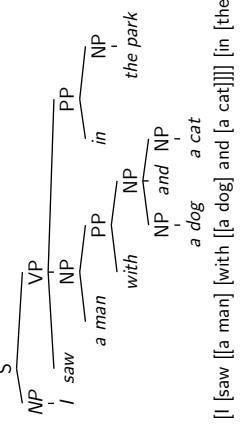
$$0CB = \frac{\# \text{ Sätze ohne crossing brackets}}{\# \text{ Sätze}}$$

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 73

Stochastisches Parsing

- Wie aussagekräftig sind die Qualitätsmaße?

- Referenz:

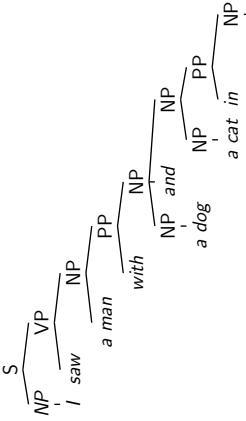


[[I [saw [[a man] [with [[a dog] and [[a cat]] [in [the park]]]]]]]

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 74

Stochastisches Parsing

- 1. Resultat: eine fehlerhafte strukturelle Anbindung

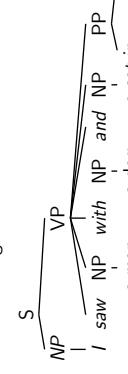


[[I [saw [[a man] [with [[a dog] and [[a cat] [in [the park]]]]]]]]]

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 73

Stochastisches Parsing

- 2. Resultat: weitgehend flache Analyse
- Vermeiden aller Entscheidungen über strukturelle Anbindungen

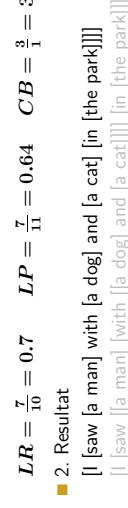


[[I [saw [a man] with [a dog] and [a cat] [in [the park]]]]]

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 74

Stochastisches Parsing

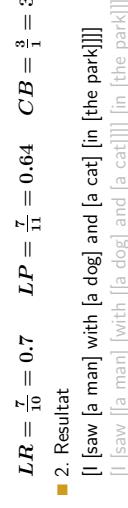
- 1. Resultat



[[I [saw [[a man] [with [[a dog] and [[a cat]] [in [the park]]]]]]]]]

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 73

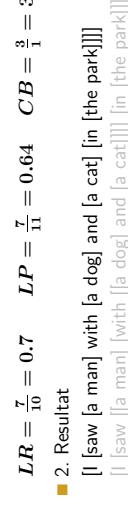
- 2. Resultat



[[I [saw [a man] with [a dog] and [a cat] [in [the park]]]]]]

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 74

- Alternative (LIN 1996): Transformation in eine Dependenzstruktur und Evaluation der Anbindungsfehler



[[I [saw [[a man] [with [[a dog] and [[a cat]] [in [the park]]]]]]]]]]

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 73

Stochastisches Parsing

Stochastisches Parsing

- Schätzen der Regelanwendungswahrscheinlichkeiten
- Einfachster Fall: Treebank-Grammatiken (CHARNIAK 1996)

$$\Pr(N \rightarrow \zeta | N) = \frac{C(N \rightarrow \zeta)}{\sum_{\zeta} C(N \rightarrow \zeta)} = \frac{C(N \rightarrow \zeta)}{C(N)}$$

■ Penn-Treebank: 10605 Regeln, davon 3943 nur einmal beobachtet

■ Resultate für Sätze bis max. 40 Wortformen:

■ LR = 80.4%, LP = 78.8%

■ Konstituenten ohne crossing brackets: 87.7%

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 78

Stochastisches Parsing

- inside-Wahrscheinlichkeit: Wahrscheinlichkeit für Expansion eines Nichterminals zu einer bestimmten Terminalkette \approx backward-probability

$$\beta_j(k, l) = \Pr(w_{k,l} | N_{k,l}^j)$$

- outside-Wahrscheinlichkeit: Wahrscheinlichkeit für die Ableitung eines Baumkontextes \approx forward-probability

$$\alpha_j(k, l) = \Pr(w_{l,k-1}, N_{k,l}^j, w_{l+1,n})$$

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 80

Stochastisches Parsing

- Regelwahrscheinlichkeit (für Chomsky-Normalform)

$$C(N^j \rightarrow N^p N^q) \\ = \frac{1}{\Pr(w_{1,n})} \sum_{k,l,m} \alpha_j(k, l) \cdot \Pr(N^j \rightarrow N^p N^q) \\ \cdot \beta_p(k, m) \cdot \beta_q(m + 1, l)$$

$$C(N^i \rightarrow w^j) \\ = \frac{1}{\Pr(w_{1,n})} \sum_k \alpha_i(k, k) \cdot \Pr(N^i \rightarrow w^j, w^j = w^k)$$

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 78

Stochastisches Parsing

- Parsing mit modifiziertem EARLEY/CYK-Algorithmus

- dynamische Programmierung:

- rekursiver Aufbau der Parsingtabelle und Auswahl der lokalen optimalen Interpretation

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 82

Stochastisches Parsing

- Problem: Unabhängigkeitsannahme ist systematisch falsch

- Subjekt wird häufiger pronominalisiert als Objekt
- besonders deutlich in gesprochener Sprache
- Auswirkung der Informationsstruktur
- Subkategorisierungspräferenzen disambiguieren Anbindungsprobleme

- NP Anbindung ist häufiger als V-Anbindung (2:1)
- aber: einige Verben erzwingen Anbindung bestimmter Präpositionen

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 83

Stochastisches Parsing

- lexikalische Abhängigkeiten lassen sich in PCFG nicht ausdrücken
- nur stochastische Abhängigkeit vom dominierenden Nichtterminal

$$\Pr(N \rightarrow \zeta | N)$$

- Erweiterung des stochastischen Modells um zusätzliche Bedingungen

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 84

Stochastisches Parsing

- → lexikalisierte Regelanwendungswahrscheinlichkeiten (CHARNIAK 2000)

$$\Pr(N \rightarrow \zeta | N, h(r))$$

- lexikalische Abhängigkeiten (CHARNIAK 2000, COLLINS 1999)

- vom Kopf der unmittelbar übergeordneten Phrase

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 83

Stochastisches Parsing

- vom Kopf der beiden übergeordneten Phrasenebenen

$$\Pr(r = N \rightarrow \zeta | N, h(r), h(m(r)))$$

- vom Kopf der unmittelbar übergeordneten Phrase

 Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 85

Stochastisches Parsing

Stochastisches Parsing

- Problem: Datenmangel
 - Backoff
 - Glätteln

■ stochastische Modellierung der Schwesternknoten zum Kopf als Markov-Prozess (COLLINS 1999)



Wolfgang Menzel: Sprachorientierte KI: Syntax und Parsing – p. 86

Stochastisches Parsing

- Parsing als stochastischer Mustervergleich

MAGERMAN 1994

■ "Parsing ohne Grammatik"

- Training eines binären Entscheidungsbaumes (decision tree)

■ strukturelle Anbindung von Wortformen und Teilstämmen

■ Wahl der strukturellen Kategorie

- extension: linke oder rechte Konstituentengrenze, bzw.
mittlere Position (right, left, up)



Wolfgang Menzel: Sprachorientierte KI: Syntax und Parsing – p. 88

Stochastisches Parsing

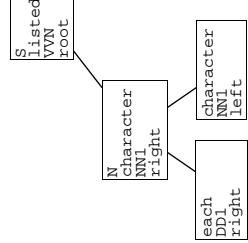
- Merkmalsrepräsentation für Syntaxbäume

- label: phrasale Kategorie (N,V,S, ...)
 - nur für nichtterminale Knoten
- word: Wortform des Blattknotens bzw. des Konstituentenkopfes
- tag: Wortart des Blattknotens bzw. des Konstituentenkopfes
- extension: linke oder rechte Konstituentengrenze, bzw.
mittlere Position (right, left, up)



Wolfgang Menzel: Sprachorientierte KI: Syntax und Parsing – p. 89

Stochastisches Parsing



Wolfgang Menzel: Sprachorientierte KI: Syntax und Parsing – p. 90

Stochastisches Parsing

- Resultate

- Trainingsdaten: Baumkorpus mit 1473 Sätzen
- 78% korrekte Klammersstruktur (crossing-brackets score)
- 35% korrekte Baumstruktur (mit Wortarttagging)
- 50% korrekte Baumstruktur (ohne Wortarttagging)
- Vergleich: 69% korrekte Klammerstruktur für klassischen Parser



Wolfgang Menzel: Sprachorientierte KI: Syntax und Parsing – p. 92

Stochastisches Parsing

- Datenorientiertes Parsing (DOP) (BOD 1992, 2003)

- Zerlegung der Parsebäume in Teilbäume bis zu einer maximalen Höhe n ($n \leq 6$)
- Schätzen der Auftretenswahrscheinlichkeit aller Teilbäume
- Ermitteln der Ableitungswahrscheinlichkeit für eine Ergebnistruktur als Summe über alle Ableitungsvarianten
- geschlossene Berechnung nicht mehr möglich
 - Monte-Carlo-sampling
 - LR=90.7%, LP=90.8% (Satzlänge ≤ 100)



Wolfgang Menzel: Sprachorientierte KI: Syntax und Parsing – p. 93

Stochastisches Parsing

Stochastisches Parsing

- Supertagging (BANGALORE 1997)
 - Zeilegen des Parsebaumes in lexikalierte Baumfragmente
 - analog zu einer Tree Adjoining Grammar (TAG)
 - Verwendung der Baumfragmente als strukturell reichhaltige lexikalische Kategorien
 - Training eines stochastischen Taggers
 - Auswahl der wahrscheinlichsten Folge von Strukturfragmenten
 - almost parsing



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 94

Stochastisches Parsing

- Anwendungen:
 - approximatives Parsing für unrestrictierten Text
 - Informationsextraktion
 - Diskursanalyse
 - Analyse ungrammatischer Äußerungen
 - Sprachmodelle in der Spracherkennung
 - Lernen von Grammatiken



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 96

Supertagging

- Supertagging
 - Rekonstruktion eines Parsebaumes aus den Baumfragmenten
 - bessere Resultate (geringere Perplexität) mit einer Constraint Dependency Grammar (HARPER 2002)
 - auch bei Training auf fehlerhaften Baumbanken (HARPER 2003)



Wolfgang Menzel: Sprachorientierte Kl: Syntax und Parsing – p. 95