

# Formale Methoden 1

**Gerhard Jäger**

Gerhard.Jaeger@uni-bielefeld.de

Uni Bielefeld, WS 2007/2008

12. Dezember 2007

## Baumdiagramme

Ein Baumdiagramm eines Satzes stellt drei Arten von Information dar:

- die Konstituenten-Struktur des Satzes,
- die grammatische Kategorie jeder Konstituente, sowie
- die lineare Anordnung der Konstituenten.

## Konventionen

- Ein Baum besteht aus **Knoten**, die durch
- **Kanten** verbunden werden.
- Kanten sind implizit von oben nach unten **gerichtet** (ähnlich zu Hasse-Diagrammen, wo die implizite Richtung aber von unten nach oben ist.)
- Jeder Knoten ist mit einem **Etikett** (engl. **label**) versehen.

## Dominanz

- Ein Knoten  $x$  **dominiert** Knoten  $y$  wenn es eine zusammenhängende Seq von gerichteten Ästen gibt, die mit  $x$  beginnt und mit  $y$  endet.
- Für einen Baum  $T$  bildet

$$D_T = \{\langle x, y \rangle \mid x \text{ dominiert } y \text{ in } T\}$$

die zugehörige **Dominanz-Relation**

- $D_T$  ist eine schwache Ordnung, also reflexiv, transitiv und anti-symmetrisch.

## Konventionen

- Wenn  $x$  nach  $D_T$  der unmittelbare Vorgänger von  $y$  ist, dann **dominiert**  $x$   $y$  **unmittelbar**.
- Der unmittelbare Vorgänger von  $x$  bzgl.  $D_T$  heißt der **Mutterknoten** von  $x$ .
- Die unmittelbaren Nachfolger von  $x$  heißen **Tochterknoten** von  $x$ .
- Wenn zwei Knoten nicht identisch sind, aber den selben Mutterknoten haben, heißen sie **Schwesterknoten**.
- Jeder Baum hat endlich viele Knoten.
- Jeder Baum hat ein Infimum. Das Infimum heißt **Wurzel** oder **Wurzelknoten** des Baums.
- Die maximalen Elemente eines Baumes heißen **Blätter**.

## Präzedenz

- Baum-Diagramme beinhalten (anders als Hasse-Diagramm) Informationen über die lineare Abfolge der Knoten.
- Knoten  $x$  **geht** Knoten  $y$  **voran** (engl.  $x$  precedes  $y$ ) gdw.  $x$  links von  $y$  steht und keiner der beiden Knoten den anderen dominiert.
- Für einen Baum  $T$  bildet

$$\{\langle x, y \rangle \mid x \text{ geht } y \text{ voran}\}$$

die zugehörige **Präzedenz-Relation**.

- $P_T$  ist eine starke Ordnung, also irreflexiv, transitiv und asymmetrisch.

## Exklusivität

In einem Baum  $T$  stehen die Knoten  $x$  und  $y$  in der Präzedenz-Relation (also  $P_t(x, y)$  oder  $P_t(y, x)$ ) gdw. sie nicht in der Dominanz-Relation stehen (also weder  $D_T(x, y)$  noch  $D_T(y, x)$ ).

## Nicht-Überkreuzung

Wenn in einem Baum der Knoten  $x$  dem Knoten  $y$  vorangeht, dann geht jeder Knoten  $x'$ , der von  $x$  dominiert wird, jedem Knoten  $y'$  voran, der von  $y$  dominiert wird.

Diese Bedingung schließt aus, dass

- ein Knoten mehrere Mutterknoten hat, oder dass
- sich Äste überkreuzen.



## Etikettierung

Für jeden Baum  $T$  gibt es eine Etikettierungs-Funktion  $L_T$ , die jedem Knoten ein Etikett zuweist.

- $L_T$  muss nicht injektiv sein (mehrere Knoten können das selbe Etikett tragen).
- Bei Ableitungsbäumen werden Blätter (auch **Terminal-Knoten** genannt) auf Terminalsymbole abgebildet und alle anderen Knoten auf Nichtterminal-Symbole.

# Bäume

Mit Hilfe dieser Eigenschaften von Bäumen können *Theoreme* bewiesen werden, also Sachverhalte, die für alle Bäume gelten. Zum Beispiel

## Theorem

*Wenn  $x$  und  $y$  Schwesterknoten sind, dann gilt entweder  $P(x, y)$  oder  $P(y, x)$ .*

## Theorem

*Die Menge der Blätter eines Baumes sind durch  $P$  total geordnet.*

# Grammatiken und Bäume

- Bäume repräsentieren die relevanten Aspekte einer Ableitung
- Zusammenhang zwischen Ableitung und Baum am einfachsten, wenn alle Regeln der Grammatik die Form

$$A \rightarrow \alpha$$


haben (mit  $A \in V_N$  und  $\alpha \in (V_T \cup V_N)^*$ )

# Grammatiken und Bäume

## Definition

Eine Grammatik  $G = \langle V_T, V_N, S, R \rangle$ , bei der alle Regeln als linke Seite genau ein Nichtterminal-Symbol haben, **generiert** einen Baum  $T$  genau dann wenn

- die Wurzel von  $T$  mit  $S$  etikettiert ist,
- die Blätter entweder mit Terminalsymbolen oder mit  $\epsilon$  etikettiert sind, sowie
- es für jeden Teilbaum



in  $T$  eine Regel

$A \rightarrow \alpha_1, \dots, \alpha_n$  in  $R$  gibt.


# Grammatiken und Bäume

## Beispiel-Grammatik

$$G = \langle \{a, b\}, \{S, A, B\}, S, R \rangle$$
$$R = \left\{ \begin{array}{ll} S \rightarrow AB & B \rightarrow Bb \\ A \rightarrow aAb & B \rightarrow b \\ A \rightarrow \epsilon & \end{array} \right\}$$

# Grammatiken und Bäume

Diese Grammatik generiert z.B. folgende Baum:



Frage: Welche Sprache wird durch diese Grammatik generiert?

# Kontext-sensitive Regeln

Manchmal möchte man die Anwendung bestimmter Regeln auf bestimmte Kontexte einschränken. Zum Beispiel:

- $D \rightarrow des$  nur wenn das nachfolgende Nomen maskulin oder neutrum singular Genitiv ist
- $/d/ \rightarrow [d]$  nur wenn das Segment nicht am Wortende steht
- [Präteritum]  $\rightarrow -t-$  nur wenn direkt davor der Stamm eines schwachen Verbs steht
- ...

Aufgabe: Finde mehr Beispiele für kontext-abhängige grammatische Regeln!

# Kontext-sensitive Regeln

- übliches Format für kontext-sensitive Regeln:

$$A \rightarrow \gamma / \alpha \_ \beta$$

- $A$ : Nichtterminal-Symbol
- $\alpha, \beta, \gamma$ : Ketten von Terminal- und Nichtterminal-Symbolen
- $\gamma \neq \epsilon$
- $\alpha \_ \beta$  gibt Kontext an, in dem die Regel  $A \rightarrow \gamma$  angewendet werden kann
- „offizielle“ Schreibweise:

$$\alpha A \beta \rightarrow \alpha \gamma \beta$$



# Die Chomsky-Hierarchie

Unterschiedliche Einschränkung für das Format von Grammatik-Regeln führt zu folgender Hierarchie von Grammatik-Typen:

## Chomsky-Hierarchie

- |              |   |  |
|--------------|---|--|
| <b>Typ 0</b> | keine Einschränkung   |  |
| <b>Typ 1</b> | Regeln der Form $\alpha A \beta \rightarrow \alpha \gamma \beta$<br>$A \in V_N, \alpha \neq \epsilon$ | <i>kontext-sensitive<br/>Grammatik</i> |
| <b>Typ 2</b> | Regeln der Form $A \rightarrow \gamma$<br>$A \in V_N$   | <i>kontext-freie Grammatik</i>         |
| <b>Typ 3</b> | Regeln der Form $A \rightarrow xB$<br>oder $A \rightarrow x$<br>$A, B \in V_N, x \in V_T^*$           | <i>reguläre Grammatik</i>              |

# Die Chomsky-Hierarchie

- keine strikte Hierarchie, weil bei kontext-freien Grammatiken  $\epsilon$  als rechte Seite auftreten kann, bei kontext-sensitiven Grammatiken jedoch nicht

**Typ 3  $\subset$  Typ 2  $\not\subset$  Typ 1  $\subset$  Typ 0**

# Die Chomsky-Hierarchie

Grammatik-Hierarchie entspricht Hierarchie formaler Sprachen:

- *Typ-0-Sprachen* („rekursiv aufzählbare Sprachen“): Sprachen, die von Typ-0-Grammatik generiert werden
- *Typ-1-Sprachen* („kontext-sensitive Sprachen“): Sprachen, die von Typ-1-Grammatik generiert werden
- *Typ-2-Sprachen* („kontext-freie Sprachen“): Sprachen, die von Typ-2-Grammatik generiert werden
- *Typ-3-Sprachen* („reguläre Sprachen“): Sprachen, die von Typ-3-Grammatik generiert werden

## Theorem

*Wenn  $L$  eine kontext-freie Sprache ist und  $\epsilon \notin L$ , dann ist  $L$  auch eine kontext-sensitive Sprache.*

# Die Chomsky-Hierarchie

- Alle kontext-freien und kontext-sensitiven Sprachen sind **entscheidbar** — es gibt für jede dieser Sprachen ein Computerprogramm, das in endlicher Zeit entscheidet, ob eine gegebene Kette zu der Sprache gehört oder nicht.
- Rekursiv aufzählbare Sprachen sind nicht immer entscheidbar. Zum Beispiel bildet die Menge aller beweisbaren mathematischen Aussagen eine rekursiv aufzählbare Sprache, die nicht entscheidbar ist.
- Kontext-freie Sprachen können vom Computer effizient verarbeitet werden (maximal kubische Zeitkomplexität).
- Reguläre Sprachen können vom Computer sehr effizient verarbeitet werden (lineare Zeitkomplexität).
- Kontext-sensitive Sprachen sind im allgemeinen Fall nicht effizient verarbeitbar.

# Die Chomsky-Hierarchie

- 1957 (Chomsky): Nachweis, dass Englisch keine reguläre Sprache ist.
- 1957 (Chomsky): Vermutung, dass natürliche Sprachen generell nicht kontext-frei, sondern kontext-sensitiv sind.
- 1982 (Pullum & Gazdar): „English as a context-free language“ — Argumente, dass Englisch (und alle anderen nat. Sprachen) kontext-frei sind.
- 1984 (Huybregts), 1985 (Shieber): Beweis, dass Schweizerdeutsch nicht kontext-frei ist
- 1985 (Culy): Beweis, dass Bambara (westafrikanische Sprache) nicht kontext-frei ist
- Die meisten phonologischen und morphologischen Prozesse in natürlichen Sprachen können durch reguläre Grammatiken erfasst werden.

# Die Chomsky-Hierarchie

