

# Einführung in die Computerlinguistik

## – Formale Grammatiken

### rechtslineare und kontextfreie Grammatiken

### Kellerautomaten

Dozentin: Wiebke Petersen

13. Foliensatz

# Formale Grammatik

## Definition

Eine **formale Grammatik** ist ein 4-Tupel  $G = (N, T, S, P)$  aus

- einer Alphabet von Terminalsymbolen  $T$  (häufig auch  $\Sigma$ )
- einer Alphabet von Nichtterminalsymbolen  $N$  mit  $N \cap T = \emptyset$
- einem Startsymbol  $S \in N$
- einer Menge von Regeln/Produktionen  
 $P \subseteq \{ \langle \alpha, \beta \rangle \mid \alpha, \beta \in (N \cup T)^* \text{ und } \alpha \notin T^* \}$ .

Für eine Regel  $\langle \alpha, \beta \rangle$  schreiben wir auch  $\alpha \rightarrow \beta$ .

S	→	NP VP	VP	→	V	NP	→	D N
D	→	the	N	→	cat	V	→	sleeps

Generiert: the cat sleeps

Konvention: Wir verwenden Großbuchstaben für Nichtterminalsymbole und Kleinbuchstaben für Terminalsymbole

# Terminologie

$$G = \langle \{S, NP, VP, V, D, N, EN\}, \{the, cat, peter, chases\}, S, P \rangle$$

$$P = \left\{ \begin{array}{llll} S & \rightarrow & NP VP & VP & \rightarrow & V NP & NP & \rightarrow & D N \\ NP & \rightarrow & EN & D & \rightarrow & the & N & \rightarrow & cat \\ EN & \rightarrow & peter & V & \rightarrow & chases & & & \end{array} \right\}$$

# Terminologie

$$G = \langle \{S, NP, VP, V, D, N, EN\}, \{the, cat, peter, chases\}, S, P \rangle$$

$$P = \left\{ \begin{array}{lll} S & \rightarrow & NP VP \\ NP & \rightarrow & EN \quad D \rightarrow the \quad N \rightarrow cat \\ EN & \rightarrow & peter \quad V \rightarrow chases \end{array} \right\}$$

“NP VP” ist **in einem Schritt** aus **S ableitbar**

# Terminologie

$$G = \langle \{S, NP, VP, V, D, N, EN\}, \{the, cat, peter, chases\}, S, P \rangle$$

$$P = \left\{ \begin{array}{lll} S & \rightarrow & NP VP \\ NP & \rightarrow & EN \quad D \rightarrow the \quad N \rightarrow cat \\ EN & \rightarrow & peter \quad V \rightarrow chases \end{array} \right\}$$

“NP VP” ist **in einem Schritt** aus  $S$  **ableitbar**

“the cat chases peter” ist **ableitbar** aus  $S$ :

**Ableitung:**

$$\begin{array}{lll} S & \rightarrow & NP VP & \rightarrow & NP V NP & \rightarrow & NP V EN \\ & \rightarrow & NP V peter & \rightarrow & NP chases peter & \rightarrow & D N chases peter \\ & \rightarrow & D cat chases peter & \rightarrow & the cat chases peter & & \end{array}$$

# Terminologie

$$G = \langle \{S, NP, VP, V, D, N, EN\}, \{the, cat, peter, chases\}, S, P \rangle$$

$$P = \left\{ \begin{array}{l} S \rightarrow NP VP \quad VP \rightarrow V NP \quad NP \rightarrow D N \\ NP \rightarrow EN \quad D \rightarrow the \quad N \rightarrow cat \\ EN \rightarrow peter \quad V \rightarrow chases \end{array} \right\}$$

“NP VP” ist **in einem Schritt** aus  $S$  **ableitbar**

“the cat chases peter” ist **ableitbar** aus  $S$ :

**Ableitung:**

$$\begin{array}{lll} S & \rightarrow NP VP & \rightarrow NP V NP & \rightarrow NP V EN \\ & \rightarrow NP V peter & \rightarrow NP chases peter & \rightarrow D N chases peter \\ & \rightarrow D cat chases peter & \rightarrow the cat chases peter & \end{array}$$

Die Menge aller aus dem Startsymbol  $S$  ableitbarer Wörter ist die von der Grammatik  $G$  **erzeugte Sprache**  $L(G)$ .

$$L(G) = \left\{ \begin{array}{ll} the\ cat\ chases\ peter, & peter\ chases\ the\ cat, \\ peter\ chases\ peter, & the\ cat\ chases\ the\ cat \end{array} \right\}$$

# rechtslineare Grammatiken

## Definition

Eine Grammatik  $(N, T, S, P)$  heißt **rechtslinear**, wenn alle Regeln/Produktionen die folgende Form haben:

$A \rightarrow a$  oder  $A \rightarrow aB$  wobei  $a \in T \cup \{\varepsilon\}$  und  $A, B \in N$ .

Eine durch eine rechtslineare Grammatik erzeugte Sprache heißt **rechtslinear**.

(Vorsicht, häufig werden schärfere [aber äquivalente] Bedingungen gefordert!)

# rechtslineare Grammatiken

## Definition

Eine Grammatik  $(N, T, S, P)$  heißt **rechtslinear**, wenn alle Regeln/Produktionen die folgende Form haben:

$A \rightarrow a$  oder  $A \rightarrow aB$  wobei  $a \in T \cup \{\varepsilon\}$  und  $A, B \in N$ .

Eine durch eine rechtslineare Grammatik erzeugte Sprache heißt **rechtslinear**.


(Vorsicht, häufig werden schärfere [aber äquivalente] Bedingungen gefordert!)

Beispiel:

$G = (\{S, B\}, \{a, b\}, S, P)$  mit

$$P = \left\{ \begin{array}{l} S \rightarrow aS \\ S \rightarrow aB \\ B \rightarrow bB \\ B \rightarrow b \end{array} \right\}$$

$G$  generiert  $L(G) = L(a^+b^+)$



Ableitungsbaum  $(aabbbb \in L(G))$



# rechtslineare Grammatiken und reguläre Sprachen

## Theorem

Sei  $L$  eine formale Sprache, dann sind die folgenden Aussagen äquivalent:


- 1  $L$  ist regulär.
- 2 Es gibt eine rechtslineare Grammatik  $G$ , die  $L$  erzeugt.
- 3 Es gibt einen endlichen Automaten  $A$ , der  $L$  akzeptiert.
- 4 Es gibt einen regulären Ausdruck  $R$ , der  $L$  beschreibt.

rechtslineare Grammatik:

$$G = (\{S, B\}, \{a, b\}, S, P) \text{ mit}$$

$$P = \left\{ \begin{array}{l} S \rightarrow aS \\ S \rightarrow aB \\ B \rightarrow bB \\ B \rightarrow b \end{array} \right\}$$


endlicher Automat:



regulärer Ausdruck:

$a^+ b^+$

# Zusammenfassung: reguläre Sprachen



# kontextfreie Grammatik

## Definition

Eine Grammatik  $(N, T, S, P)$  heißt **kontextfrei**, wenn alle Regeln/Produktionen die folgende Form haben:

$$A \rightarrow \alpha, \text{ wobei } A \in N \text{ und } \alpha \in (T \cup N)^*.$$

Eine durch eine kontextfreie Grammatik erzeugte Sprache heißt **kontextfrei**.

# kontextfreie Grammatik

## Definition

Eine Grammatik  $(N, T, S, P)$  heißt **kontextfrei**, wenn alle Regeln/Produktionen die folgende Form haben:

$$A \rightarrow \alpha, \text{ wobei } A \in N \text{ und } \alpha \in (T \cup N)^*.$$

Eine durch eine kontextfreie Grammatik erzeugte Sprache heißt **kontextfrei**.

Die Menge der kontextfreien Sprachen ist eine echte Obermenge der Menge der regulären Sprachen

# kontextfreie Grammatik

## Definition

Eine Grammatik  $(N, T, S, P)$  heißt **kontextfrei**, wenn alle Regeln/Produktionen die folgende Form haben:


$$A \rightarrow \alpha, \text{ wobei } A \in N \text{ und } \alpha \in (T \cup N)^*.$$

Eine durch eine kontextfreie Grammatik erzeugte Sprache heißt **kontextfrei**.

Die Menge der kontextfreien Sprachen ist eine echte Obermenge der Menge der regulären Sprachen

**Beweis:** Jede reguläre Sprache ist per Definition auch kontextfrei und es gibt mindestens eine kontextfreie Sprache, nämlich  $L(a^n b^n)$  mit  $n \geq 0$ , die nicht regulär ist. ( $S \rightarrow aSb, S \rightarrow \varepsilon$ )

# Ableitungsbaum



# Beispiel einer kontextfreien Sprache


$$G = \langle \{S, A, B, C\}, \{a, b, c\}, S, P \rangle$$

$$P = \left\{ \begin{array}{ll} S \rightarrow ASB & S \rightarrow C \\ A \rightarrow a & B \rightarrow b \\ C \rightarrow cC & C \rightarrow \varepsilon \end{array} \right\}$$

# Beispiel einer kontextfreien Sprache

$$G = \langle \{S, A, B, C\}, \{a, b, c\}, S, P \rangle$$

$$P = \left\{ \begin{array}{ll} S \rightarrow ASB & S \rightarrow C \\ A \rightarrow a & B \rightarrow b \\ C \rightarrow cC & C \rightarrow \varepsilon \end{array} \right\}$$



Übung: Welche Sprache generiert diese Grammatik? Können Sie eine äquivalente Grammatik angeben, die mit weniger Nichtterminalsymbolen auskommt?



# Linksableitung


Gegeben eine kontextfreie Grammatik  $G$ . Eine Ableitung bei der stets das am weitesten links stehende nichtterminale Symbol ersetzt wird, heißt **Linksableitung**

S	→ NP VP	→ D N VP	→ the N VP
	→ the cat VP	→ the cat V NP	→ the cat chases NP
	→ the cat chases EN	→ the cat chases peter	

# Linksableitung

Gegeben eine kontextfreie Grammatik  $G$ . Eine Ableitung bei der stets das am weitesten links stehende nichtterminale Symbol ersetzt wird, heißt **Linksableitung**

$S$	$\rightarrow NP VP$	$\rightarrow D N VP$	$\rightarrow the N VP$
	$\rightarrow the\ cat\ VP$	$\rightarrow the\ cat\ V\ NP$	$\rightarrow the\ cat\ chases\ NP$
	$\rightarrow the\ cat\ chases\ EN$	$\rightarrow the\ cat\ chases\ peter$	



Zu jeder Linksableitung gibt es genau einen Ableitungsbaum und zu jedem Ableitungsbaum gibt es genau eine Linksableitung.

# ambige Grammatik

Eine Grammatik  $G$  heißt **ambig**, wenn es für ein Wort  $w \in L(G)$  mehr als eine Linksableitung gibt.

$G = (N, T, NP, P)$  mit  $N = \{S, EN, NP, VP, PP, D, N, P\}$ ,

$T = \{\text{Eva, sieht, den, Mann, mit, dem, Fernglas}\}$ ,

$$P = \left\{ \begin{array}{lll} S \rightarrow EN VP & VP \rightarrow V NP & VP \rightarrow V NP PP \\ NP \rightarrow D N & NP \rightarrow D N PP & PP \rightarrow P NP \\ EN \rightarrow \text{Eva} & P \rightarrow \text{mit} & V \rightarrow \text{sieht} \\ D \rightarrow \text{den} & D \rightarrow \text{dem} & N \rightarrow \text{Mann} \\ N \rightarrow \text{Fernglas} & & \end{array} \right\}$$



# ambige Grammatik

Eine Grammatik  $G$  heißt **ambig**, wenn es für ein Wort  $w \in L(G)$  mehr als eine Linksableitung gibt.

$G = (N, T, NP, P)$  mit  $N = \{S, EN, NP, VP, PP, D, N, P\}$ ,

$T = \{\text{Eva, sieht, den, Mann, mit, dem, Fernglas}\}$ ,

$$P = \left\{ \begin{array}{lll} S \rightarrow EN VP & VP \rightarrow V NP & VP \rightarrow V NP PP \\ NP \rightarrow D N & NP \rightarrow D N PP & PP \rightarrow P NP \\ EN \rightarrow \text{Eva} & P \rightarrow \text{mit} & V \rightarrow \text{sieht} \\ D \rightarrow \text{den} & D \rightarrow \text{dem} & N \rightarrow \text{Mann} \\ N \rightarrow \text{Fernglas} & & \end{array} \right\}$$



# Kellerautomaten

**Ziel:** Automatenmodell mit dem genau die kontextfreien Sprachen akzeptiert werden können (analog zu endlichen Automaten und regulären Sprachen).

# Kellerautomaten

**Ziel:** Automatenmodell mit dem genau die kontextfreien Sprachen akzeptiert werden können (analog zu endlichen Automaten und regulären Sprachen).

**Lösung:** Hinzunahme eines unbeschränkten Speichers in Form eines Stapels, von dessen Spitze etwas genommen und auf dessen Spitze etwas abgelegt werden kann.

Kellerautomaten entstehen aus endlichen Automaten durch

- Hinzunahme eines Kelleralphabets
- Erweiterung der Transitionen (es muss das Lesen und Ersetzen der Kellerspitze realisiert werden)

## Informelles Beispiel

Wir betrachten die Sprache  $\{a^i b^i \mid i > 0\}$ .

Das Akzeptieren eines Eingabewortes geschieht wie folgt:

1. **Aufbau des Kellers:** für jedes gelesene  $a$  lege ein Symbol auf dem Keller ab (wir nehmen das Symbol  $Z$ )
2. **Abbau des Kellers:** für jedes gelesene  $b$  nehme ein Symbol  $Z$  vom Keller herunter
3. **durch zwei Kontrollzustände** Sorge dafür, dass Aufbau und Abbau nur in dieser Reihenfolge möglich sind (Aufbau mit  $q_0$ , Abbau mit  $q_1$ , keine Rückkehr nach  $q_0$ )
4. **Akzeptiere**, wenn am Ende des Eingabewortes der Kellerboden erreicht ist.

Der Keller realisiert in diesem Fall eine Zählervariable.

# Transition

**(p, a, Z, v, q)**




# Transition

**(p, a, Z, v, q)**

aktueller Zustand



# Transition



## Transition

oberstes Symbol auf dem Stack

(wird entfernt)

- pop up -

**(p, a, Z̄, v, q)**

aktueller Zustand

zu lesendes Eingabesymbol

## Transition

oberstes Symbol auf dem Stack

(wird entfernt)

- pop up -

**(p, a, Z, v, q)**

aktueller Zustand

zu lesendes Eingabesymbol

Wort, das auf den Stack gelegt wird

- push down -

# Transition

oberstes Symbol auf dem Stack

(wird entfernt)

- pop up -

neuer Zustand

**(p, a, Z̄, v, q)**


aktueller Zustand

zu lesendes Eingabesymbol




Wort, das auf den Stack gelegt wird

- push down -



# Transition



# Transition




# Transition






## Beispiel eines Kellerautomaten



dieser Kellerautomat akzeptiert  
die Sprache  $a^n b^n$


## Arbeitsweise eines Kellerautomaten




(noch) zu lesendes Wort:

a a a b b b

aktueller Stack:



## Arbeitsweise eines Kellerautomaten




(noch) zu lesendes Wort:

a a b b b

aktueller Stack:

Z

## Arbeitsweise eines Kellerautomaten




(noch) zu lesendes Wort:

a b b b

aktueller Stack:

Z  
Z

## Arbeitsweise eines Kellerautomaten




(noch) zu lesendes Wort:

**b b b**


aktueller Stack:

**Z**  
**Z**  
**Z**


## Arbeitsweise eines Kellerautomaten




(noch) zu lesendes Wort:



aktueller Stack:



## Arbeitsweise eines Kellerautomaten




(noch) zu lesendes Wort:

**b**

aktueller Stack:

**Z**


## Arbeitsweise eines Kellerautomaten



(noch) zu lesendes Wort:




aktueller Stack:





## Arbeitsweise eines Kellerautomaten




(noch) zu lesendes Wort:




Das Wort ist abgearbeitet!

aktueller Stack:



## Arbeitsweise eines Kellerautomaten




(noch) zu lesendes Wort:




Das Wort ist abgearbeitet!

aktueller Stack:



Der Stack ist leer!

## Arbeitsweise eines Kellerautomaten




Der Automat befindet  
sich in einem Endzustand!

(noch) zu lesendes Wort:




Das Wort ist abgearbeitet!

aktueller Stack:



Der Stack ist leer!

## Arbeitsweise eines Kellerautomaten



Der Automat befindet sich in einem Endzustand!


Darum akzeptiert der Kellerautomat das Wort!

(noch) zu lesendes Wort:



Das Wort ist abgearbeitet!

aktueller Stack:



Der Stack ist leer!

# Von kontextfreien Grammatiken zu Kellerautomaten

- Für das Akzeptieren einer kontextfreien Sprache genügt ein Kellerautomat mit nur zwei Zuständen, wobei die einzige Aufgabe des Startzustands darin besteht, das Startsymbol  $S$  der Grammatik in den Keller zu legen.

# Von kontextfreien Grammatiken zu Kellerautomaten

- Für das Akzeptieren einer kontextfreien Sprache genügt ein Kellerautomat mit nur zwei Zuständen, wobei die einzige Aufgabe des Startzustands darin besteht, das Startsymbol  $S$  der Grammatik in den Keller zu legen.
- Während der eigentlichen Rechnung befindet sich der Automat permanent in dem selben Zustand (dem Nichtstartzustand), die Rechnung findet nur in dem Keller statt.


# Von kontextfreien Grammatiken zu Kellerautomaten

- Für das Akzeptieren einer kontextfreien Sprache genügt ein Kellerautomat mit nur zwei Zuständen, wobei die einzige Aufgabe des Startzustands darin besteht, das Startsymbol  $S$  der Grammatik in den Keller zu legen.
- Während der eigentlichen Rechnung befindet sich der Automat permanent in dem selben Zustand (dem Nichtstartzustand), die Rechnung findet nur in dem Keller statt.
- Der konstruierte Automat vollzieht zwei verschiedene Arbeitsschritte:
  - Nicht-Leseschritt mit Bezug auf Grammatikregel  $B \rightarrow \beta$ : Ersetze die Kellerspitze  $B$  mit  $\beta$  (Expansion).
  - Leseschritte:  
Lies ein  $a \in T$  der Eingabekette und entferne  $a$  von der Kellerspitze (Scan).

# Beispiel: Von kontextfreien Grammatiken zu Kellerautomaten

Grammatik:  $(\{S\}, \{a, b, c\}, S, \{S \rightarrow aSb, S \rightarrow c\})$

generierte Sprache:  $L(a^n cb^n)$





# Hausaufgaben

- ① Sei  $L$  die Sprache, die aus allen nichtleeren Wörtern über dem Alphabet  $\{a, b\}$  besteht, in denen auf jedes  $a$  unmittelbar ein  $b$  folgt. Beispiele für Wörter dieser Sprache:  $bbbab$ ,  $abababab$ ,  $bb$ ,  $babbbbab$ .
- (a) geben Sie eine rechtslineare Grammatik  $G$  an, die  $L$  erzeugt und zeichnen Sie den Ableitungsbaum für das Wort  $bbababb$
- (b) geben Sie einen endlichen Automaten  $A$  an, der  $L$  akzeptiert.
- (c) geben Sie einen regulären Ausdruck  $R$  an, der  $L$  beschreibt.
- ② Geben sie jeweils eine kontextfreie Grammatik zu den folgenden Sprachen an:
- (a)  $L_1 = \{a^i b^j \mid i > j > 0\}$
- (b)  $L_2 = \{w \in \{a, b\}^* \mid w \text{ ist ein Palindrom}\}$

Wählen Sie pro Sprache ein Wort, das mindestens die Länge 5 hat, und zeichnen Sie den Ableitungsbaum in Bezug auf Ihre Grammatik.