

## Motivation – natürliche Sprachen

(Satz)  $\rightarrow$  (Substantivphrase)(Verbphrase)

(Satz)  $\rightarrow$  (Substantivphrase)(Verbphrase)(Objektphrase)

(Substantivphrase)  $\rightarrow$  (Artikel)(Substantiv)

(Verbphrase)  $\rightarrow$  (Verb)(Adverb)

(Substantiv)  $\rightarrow$  Hund      (Substantiv)  $\rightarrow$  Banane

(Artikel)  $\rightarrow$  der      (Artikel)  $\rightarrow$  ein

(Verb)  $\rightarrow$  geht      (Verb)  $\rightarrow$  singt

(Adverb)  $\rightarrow$  langsam

## Motivation – natürliche Sprachen

(Satz)  $\implies$  (Substantivphrase)(Verbphrase)  
 $\implies$  (Substantivphrase)(Verb)(Adverb)  
 $\implies$  (Substantivphrase) geht (Adverb)  
 $\implies$  (Substantivphrase) geht langsam  
 $\implies$  (Artikel)(Substantiv) geht langsam  
 $\implies$  der (Substantiv) geht langsam  
 $\implies$  der Hund geht langsam

(Satz)  $\implies$  ...  $\implies$  ein Banane singt langsam

## Motivation – Programmiersprachen

(unsigned integer)  $\rightarrow$  (digit) | (digit){digit}

(unsigned real)  $\rightarrow$  (unsigned integer).(digit){digit} |  
(unsigned integer)E(scale factor)

(scale factor)  $\rightarrow$  (unsigned integer) | (sign) (unsigned integer)

(digit)  $\rightarrow$  0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9

(sign)  $\rightarrow$  + | -

(unsigned real)  $\implies$  (unsigned integer)E(scale factor)

$\implies$  (digit){digit}E(scale factor)

$\implies$  3{digit}E(scale factor)

$\implies$  314E(scale factor)  $\implies$  314E(sign)(unsigned integer)

$\implies$  314E-(unsigned integer)  $\implies$  314E-(digit)

$\implies$  314E-2

## Regelgrammatik – Definition

**Definition:** Eine Regelgrammatik (oder kurz Grammatik) ist ein Quadrupel

$$G = (N, T, P, S),$$

wobei

- $N$  und  $T$  endliche, disjunkte Alphabete sind ( $V = N \cup T$ ),
- $P$  eine endliche Teilmenge von  $(V^* \setminus T^*) \times V^*$  ist, und
- $S \in N$  gilt.

## Regelgrammatik – Ableitung und Sprache

**Definition:** Sei  $G = (N, T, P, S)$  eine Regelgrammatik.

Wir sagen, dass aus dem Wort  $\gamma \in V^+$  das Wort  $\gamma' \in V^*$  erzeugt wird, wenn

$$\gamma = \gamma_1 \alpha \gamma_2, \quad \gamma' = \gamma_1 \beta \gamma_2, \quad \alpha \longrightarrow \beta \in P$$

für gewisse  $\gamma_1, \gamma_2 \in V^*$  gelten.

Schreibweise:  $\gamma \Longrightarrow \gamma'$

$\Longrightarrow^*$  — reflexiver und transitiver Abschluss von  $\Longrightarrow$

**Definition:** Für eine Grammatik  $G = (N, T, P, S)$  definieren wir die von  $G$  erzeugte Sprache  $L(G)$  durch

$$L(G) = \{w : w \in T^* \text{ und } S \Longrightarrow^* w\}.$$

## Regelgrammatik – Beispiele I

$$G_1 = (\{S, A, B\}, \{a, b\}, \{p_1, p_2, p_3, p_4, p_5\}, S)$$

$$p_1 = S \rightarrow AB, p_2 = A \rightarrow aA, p_3 = A \rightarrow \lambda, p_4 = B \rightarrow Bb, p_5 = B \rightarrow \lambda$$

$$L(G_1) = \{a^n b^m : n \geq 0, m \geq 0\}$$

$$G_2 = (\{S\}, \{a, b\}, \{S \rightarrow aSb, S \rightarrow ab\}, S)$$

$$L(G_2) = \{a^n b^n : n \geq 1\}$$

$$G_3 = (\{S, A\}, \{a, b\}, \{S \rightarrow \lambda, S \rightarrow aS, S \rightarrow Sb\}, S)$$

$$L(G_3) = \{a^n b^m : n \geq 0, m \geq 0\}$$

$$G_4 = (\{S, A\}, \{a, b\}, P_4, S)$$

$$P_4 = \{S \rightarrow \lambda, S \rightarrow aS, S \rightarrow a, S \rightarrow A, A \rightarrow bA, A \rightarrow b\}$$

$$L(G_4) = \{a^n b^m : n \geq 0, m \geq 0\}$$

## Regelgrammatik – Beispiele II

$G_i = (\{S, A, B, B', B''\}, \{a, b, c\}, P_i, S)$  für  $i \in \{5, 6\}$

$P_5$	$P_6$
$p_1 = S \rightarrow ABA$	$p_0 = S \rightarrow abc$
$p_2 = AB \rightarrow aAbB'$	$p_1 = S \rightarrow aABbA$
$p_3 = AB \rightarrow abB''$	$p_2 = AB \rightarrow aAbB'$
$p_4 = B'b \rightarrow bB'$	$p_3 = AB \rightarrow abB''$
$p_5 = B''b \rightarrow bB''$	$p_4 = B'b \rightarrow bB'$
$p_6 = B'A \rightarrow BA c$	$p_5 = B''b \rightarrow bB''$
$p_7 = B''A \rightarrow c$	$p_6 = B'A \rightarrow BA c$
$p_8 = bB \rightarrow Bb$	$p_7 = B''A \rightarrow cc$
	$p_8 = bB \rightarrow Bb$

$L(G_5) = L(G_6) = \{a^n b^n c^n \mid n \geq 1\}$

## Regelgrammatik – Beispiele III

$G_7 = (N, T, P, S)$  mit

$$N = \{S\},$$

$$T = \{x, y, z, +, -, \cdot, :, (, )\},$$

$$P = \{S \longrightarrow (S + S), S \longrightarrow (S - S), S \longrightarrow (S \cdot S), S \longrightarrow (S : S), \\ S \longrightarrow x, S \longrightarrow y, S \longrightarrow z\}.$$

$L(G_7)$  besteht aus allen exakt geklammerten arithmetischen Ausdrücken mit den Variablen  $x, y, z$

## Regelgrammatik – Beispiele IV

$G_8 = (\{A, I, J\}, T, P, A)$  mit

$T = \{S, P, \mathbf{LOOP}, \mathbf{WHILE}, \mathbf{BEGIN}, \mathbf{END}, :=, \neq, ;, (, )$   
 $0, 1, 2, 3, 4, 5, 6, 7, 8, 9, x, [, ]\},$

$P = \{A \rightarrow x[I] := 0, A \rightarrow x[I] := x[I], A \rightarrow x[I] := S(x[I]),$   
 $A \rightarrow x[I] := P(x[I]), A \rightarrow A; A, A \rightarrow \mathbf{LOOP} x[I] \mathbf{BEGIN} A \mathbf{END},$   
 $A \rightarrow \mathbf{WHILE} x[I] \neq 0 \mathbf{BEGIN} A \mathbf{END}\}$   
 $\cup \{I \rightarrow Jx, J \rightarrow Jx \mid x \in \{0, 1, 2, 3, 4, 5, 6, 7, 8, 9\}\}$   
 $\cup \{I \rightarrow x, J \rightarrow x \mid x \in \{1, 2, 3, 4, 5, 6, 7, 8, 9\}\}$

$L(G_8)$  besteht aus allen **LOOP/WHILE**-Programmen

## Typen von Regelgrammatiken

**Definition:** Sei  $G = (N, T, P, S)$  eine Regelgrammatik. Wir sagen

- a)  $G$  ist monoton, wenn für alle Regeln  $\alpha \rightarrow \beta \in P$  die Bedingung  $|\alpha| \leq |\beta|$  erfüllt ist, wobei als Ausnahme  $S \rightarrow \lambda$  zugelassen ist, wenn  $|\beta'|_S = 0$  für alle Regeln  $\alpha' \rightarrow \beta' \in P$  gilt,
- b)  $G$  ist kontextabhängig, wenn alle Regeln in  $P$  von der Form  $uAv \rightarrow u w v$  mit  $u, v \in V^*$ ,  $A \in N$  und  $w \in V^+$  sind, wobei als Ausnahme  $S \rightarrow \lambda$  zugelassen ist, wenn  $|\beta'|_S = 0$  für alle Regeln  $\alpha' \rightarrow \beta' \in P$  gilt,
- c)  $G$  ist kontextfrei, wenn alle Regeln in  $P$  von der Form  $A \rightarrow w$  mit  $A \in N$  und  $w \in V^*$  sind,
- d)  $G$  ist regulär, wenn alle Regeln in  $P$  von der Form  $A \rightarrow wB$  oder  $A \rightarrow w$  mit  $A, B \in N$  und  $w \in T^*$  sind.

# Typen von Sprachen

**Definition:** Eine Sprache  $L$  heißt monoton (bzw. kontextabhängig, kontextfrei oder regulär), wenn es eine monotone (bzw. kontextabhängige, kontextfreie oder reguläre) Grammatik  $G$  mit  $L = L(G)$  gibt.

- $\mathcal{L}(REG)$  – Menge der regulären Sprachen
- $\mathcal{L}(CF)$  – Menge der kontextfreien Sprachen
- $\mathcal{L}(CS)$  – Menge der kontextabhängigen Sprachen
- $\mathcal{L}(MON)$  – Menge der monotonen Sprachen
- $\mathcal{L}(RE)$  – Menge der von Regelgrammatiken erzeugbaren Sprachen

**Lemma:**

$$\mathcal{L}(CS) \subseteq \mathcal{L}(MON) \subseteq \mathcal{L}(RE) \quad \text{und} \quad \mathcal{L}(REG) \subseteq \mathcal{L}(CF) \subseteq \mathcal{L}(RE)$$

# Normalformen I

**Lemma:**

Zu jeder Regelgrammatik  $G = (N, T, P, S)$  kann eine Regelgrammatik  $G' = (N', T, P', S)$  so konstruiert werden, dass alle Regeln aus  $P'$  von der Form

$$\alpha \longrightarrow \beta \text{ oder } A \longrightarrow a \text{ mit } \alpha, \beta \in (N')^*, A \in N', a \in T$$

sind und  $L(G) = L(G')$  gilt. Ist außerdem  $G$  eine monotone, kontextabhängige bzw. kontextfreie Grammatik, so ist auch  $G'$  monoton, kontextabhängig bzw. kontextfrei.

## Normalformen II

### Satz:

Zu jeder monotonen Grammatik  $G = (N, T, P, S)$  kann eine monotone Grammatik  $G' = (N', T, P', S')$  so konstruiert werden, dass jede Regel aus  $P'$  von einer der Formen

$$A \longrightarrow BC, A \longrightarrow B, AB \longrightarrow CB, AB \longrightarrow AC, B \longrightarrow a \text{ oder } S' \longrightarrow \lambda$$

mit  $A \in N'$ ,  $B, C \in N' \setminus \{S'\}$ ,  $a \in T$  ist und  $L(G) = L(G')$  gilt.

**Folgerung:**  $\mathcal{L}(MON) = \mathcal{L}(CS)$ .

## Normalformen III

### Lemma:

Zu jeder kontextfreien Grammatik  $G = (N, T, P, S)$  existiert eine kontextfreie Grammatik  $G' = (N', T, P', S)$  derart, dass

- i)  $P'$  keine Regel der Form  $A \rightarrow \lambda$  mit  $A \neq S$  enthält,
- ii)  $|w|_S = 0$  für alle Regeln  $A \rightarrow w \in P'$  gilt, und
- iii)  $L(G) = L(G')$  ist.

**Folgerung:**  $\mathcal{L}(CF) \subseteq \mathcal{L}(MON)$ .

$$(\mathcal{L}(REG) \subseteq \mathcal{L}(CF) \subseteq \mathcal{L}(CS) = \mathcal{L}(MON) \subseteq \mathcal{L}(RE))$$

## Normalformen IV

### Lemma:

Zu jeder kontextfreien Grammatik  $G = (N, T, P, S)$  kann eine kontextfreie Grammatik  $G' = (N, T, P', S)$  so konstruiert werden, dass  $P'$  keine Regel der Form  $A \rightarrow B$  mit  $A, B \in N$  enthält und  $L(G) = L(G')$  gilt.

### Satz (CHOMSKY-Normalform):

Zu jeder kontextfreien Grammatik  $G = (N, T, P, S)$  kann eine kontextfreie Grammatik  $G' = (N', T, P', S)$  so konstruiert werden, dass  $P'$  nur Regeln der Form

$$A \rightarrow BC \quad \text{und} \quad A \rightarrow a \quad \text{mit} \quad A, B, C \in N', \quad a \in T$$

enthält, wobei  $S \rightarrow \lambda$  als Ausnahme zugelassen ist, falls  $S$  in keiner rechten Seite einer Regel aus  $P'$  vorkommt, und  $L(G) = L(G')$  gilt.

## Normalformen V

### Satz:

Zu jeder regulären Grammatik  $G = (N, T, P, S)$  kann eine reguläre Grammatik  $G' = (N', T, P', S)$  so konstruiert werden, dass  $P'$  nur Regeln der Form

$$A \longrightarrow aB \quad \text{und} \quad A \longrightarrow a \quad \text{mit} \quad A, B \in N', \quad a \in T$$

enthält, wobei  $S \longrightarrow \lambda$  als Ausnahme zugelassen ist, falls  $P'$  keine Regel der Form  $A \longrightarrow aS$  enthält, und  $L(G) = L(G')$  gilt.

## Schleifensätze I

**Satz** (Schleifensatz / Pumping-Lemma für reguläre Sprachen):

Sei  $L$  eine reguläre Sprache. Dann gibt es eine (von  $L$  abhängige) Konstante  $k$  derart, dass es zu jedem Wort  $z \in L$  mit  $|z| \geq k$  Wörter  $u, v, w$  gibt, die den folgenden Eigenschaften genügen:

- i)  $z = uvw$ ,
- ii)  $|uv| \leq k$ ,  $|v| > 0$ , und
- iii)  $uv^i w \in L$  für alle  $i \geq 0$ .

**Lemma:**  $L = \{a^n b^n : n \geq 1\} \in \mathcal{L}(CF) \setminus \mathcal{L}(REG)$ .

## Schleifensätze II

**Satz** (Schleifensatz / Pumping-Lemma für kontextfreie Sprachen):

Sei  $L$  eine kontextfreie Sprache. Dann gibt es eine (von  $L$  abhängige) Konstante  $k$  derart, dass es zu jedem Wort  $z \in L$  mit  $|z| \geq k$  Wörter  $u, v, w, x, y$  gibt, die folgenden Eigenschaften genügen:

- i)  $z = uvwxy$ ,
- ii)  $|vwx| \leq k$ ,  $|v| + |x| > 0$ , und
- iii)  $uv^iwx^iy \in L$  für alle  $i \geq 0$ .

**Lemma:**  $L = \{a^n b^n c^n : n \geq 1\} \in \mathcal{L}(MON) \setminus \mathcal{L}(CF)$ .

**Satz:**  $\mathcal{L}(REG) \subset \mathcal{L}(CF) \subset \mathcal{L}(CS) = \mathcal{L}(MON) \subseteq \mathcal{L}(REG)$ .