

# Kontextfreie Sprachen

- besitzen große Bedeutung im Compilerbau
- Chomsky-Normalform
- effiziente Lösung des Wortproblems (CYK-Algorithmus)
- Grenzen kontextfreier Sprachen (Pumping Lemma)
- Charakterisierung durch Kellerautomaten
- Deterministisch kontextfreie Sprachen

## Beispiel für eine kontextfreie Grammatik

$$G = (\{S, X, C\}, \{x, c, 0, +, -, ;, :=, \neq, \text{LOOP}, \text{WHILE}, \text{DO}, \text{END}\}, P, S)$$

mit folgenden Regeln in der Regelmenge  $P$ :

$$S \rightarrow S; S$$

$$S \rightarrow \text{LOOP } X \text{ DO } S \text{ END}$$

$$S \rightarrow \text{WHILE } X \neq 0 \text{ DO } S \text{ END}$$

$$S \rightarrow X := X + C$$

$$S \rightarrow X := X - C$$

$$X \rightarrow x$$

$$C \rightarrow c$$

## Weiteres Beispiel für eine kontextfreie Grammatik

$$G = (\{S\}, \{a_1, a_2, b_1, b_2\}, P, S)$$

mit der Regelmenge  $P = \{S \rightarrow SS, S \rightarrow a_1Sb_1, S \rightarrow a_2Sb_2, S \rightarrow \varepsilon\}$ .

$G$  erzeugt die Sprache  $D_2$ , die sogenannte *Dyck-Sprache* über zwei Klammerpaaren. Induktive Definition von  $D_2$ :

1.  $\varepsilon \in D_2$ .
2. Aus  $w_1 \in D_2, w_2 \in D_2$  folgt  $w_1w_2 \in D_2$ .
3. Aus  $w \in D_2$  folgt  $a_1wb_1 \in D_2$  und  $a_2wb_2 \in D_2$ .
4.  $D_2$  enthält keine weiteren Wörter.

# Syntaxbäume

Jeder Ableitung eines Wortes  $w$  in einer kontextfreien Grammatik kann eindeutig ein **Syntaxbaum** zugeordnet werden.

Sei  $w \in L(G)$  und  $S = w_0 \implies w_1 \implies w_2 \implies \dots \implies w_n = w$  eine Ableitung für  $w$ . Dann wird der Syntaxbaum folgendermaßen konstruiert:

- Die Wurzel hat die Beschriftung  $S$ .
- Nach dem  $i$ -ten Schritt ergeben die Beschriftungen der Blätter von links nach rechts gelesen das Wort  $w_i$ ,  $0 \leq i \leq n$ .
- Wird bei der Ableitung eine Regel  $A \rightarrow \alpha$  angewendet, so erhält das zugehörige Blatt (mit der Beschriftung  $A$ )  $|\alpha|$  Söhne, deren Beschriftung von links nach rechts das Wort  $\alpha$  ergibt.

# Linksableitungen

**Definition.** Eine Ableitung in einer kontextfreien Grammatik heißt **Linksableitung**, wenn in jedem Schritt das am weitesten links stehende Nichtterminalsymbol ersetzt wird.

Jedem Syntaxbaum zu einer Ableitung kann eindeutig eine **Linksableitung** zugeordnet werden, d.h.:

## Satz

Die von einer kontextfreien Grammatik  $G$  erzeugte Sprache ist die Menge der durch Linksableitungen in  $G$  erzeugbaren Wörter.

# Chomsky Normalform

## Definition

Eine kontextfreie Grammatik  $G = (V, \Sigma, P, S)$  ist in **Chomsky Normalform**, falls jede Regel in  $P$  in einer der Formen (i)-(iii) ist:

- (i)  $A \rightarrow BC$  mit  $A, B, C \in V$ ,
- (ii)  $A \rightarrow a$  mit  $A \in V$  und  $a \in \Sigma$ ,
- (iii)  $S \rightarrow \varepsilon$ , wobei  $S$  auf keiner rechten Seite einer Regel vorkommt.

## Satz

Zu jeder kontextfreien Grammatik  $G$  kann man eine kontextfreie Grammatik  $G'$  in Chomsky Normalform konstruieren mit  $L(G) = L(G')$ .

# Der Algorithmus von Cocke, Younger und Kasami

- Eingabe:** kontextfreie Grammatik  $G = (V, \Sigma, P, S)$  in Chomsky NF,  
Wort  $w \in \Sigma^*$
- Ausgabe:** *ja*, falls  $w \in L(G)$ ; *nein*, sonst.

## Grundidee des CYK-Algorithmus

- $w[s, t]$  sei das Teilwort von  $w$  von der Stelle  $s$  bis zur Stelle  $t$ , wobei  $1 \leq s \leq t \leq n = |w|$ .
- Bestimme für  $1 \leq j \leq n$  und  $1 \leq i \leq n - j + 1$  die Mengen

$$T[i, j] = \{A \in V \mid A \xRightarrow{*} w[i, i + j - 1]\}.$$

- Es gilt  $w \in L(G)$  genau dann, wenn  $S \in T[1, n]$ .

# CYK-Algorithmus – Fortsetzung

Induktive Bestimmung der Mengen  $T[i, j]$ :

- Für  $j = 1$ :  $T[i, 1] = \{A \in V \mid A \rightarrow w[i, i] \in P\}$
- Für  $j > 1$ :

$$T[i, j] = \{A \in V \mid \text{es gibt } B, C \in V \text{ und } 1 \leq k < j \text{ mit} \\ A \rightarrow BC \in P, B \in T[i, k], C \in T[i + k, j - k]\}$$

- CYK-Algorithmus ist Beispiel für **Dynamische Programmierung**.



## Beispiel für CYK-Algorithmus

Die Sprache  $L = \{a^n b^n c^m \mid m, n \geq 1\}$  ist kontextfrei und wird von der Grammatik  $G = (V, \Sigma, P, S)$  mit den Regeln

$$S \rightarrow AB, \quad A \rightarrow aAb \mid ab, \quad B \rightarrow cB \mid c$$

erzeugt. Eine äquivalente Grammatik in Chomsky Normalform für  $L$  hat folgende Menge von Regeln:

$$\begin{array}{lll} S \rightarrow AB, & B \rightarrow EB \mid c, & C \rightarrow a, \\ A \rightarrow CD \mid CF, & F \rightarrow AD, & D \rightarrow b, \quad E \rightarrow c. \end{array}$$

Sei  $x = aaabbbcc$ . Dann erzeugt der Algorithmus folgende Tabelle.

# Beispiel für CYK-Algorithmus – Tabelle

$\xrightarrow{\quad\quad\quad} i$

	$a$	$a$	$a$	$b$	$b$	$b$	$c$	$c$	$= x$
	$C$	$C$	$C$	$D$	$D$	$D$	$E, B$	$E, B$	
			$A$				$B$		
			$F$						
		$A$							
		$F$							
	$A$								
	$S$								
	$S$								

$\downarrow j$

## Beispiel für CYK-Algorithmus – Erklärung

In der Tabelle stellt jedes Feld eine Menge  $T[i, j]$  von Nichtterminalen dar. Die Koordinatenachsen für  $i$  und  $j$  sind eingezeichnet.

Der Algorithmus besteht aus drei Teilen. Im ersten Teil wird die oberste Zeile ( $T[i, 1]$ ) berechnet.

Im zweiten Teil werden zeilenweise die weiteren Mengen  $T[i, j]$  berechnet, indem immer die zugehörige Spalte von oben und die nach rechts oben führende Diagonale betrachtet werden.

Im dritten Teil des Algorithmus schließlich wird die Menge  $T[1, n]$  betrachtet, hier  $T[1, 8]$ . Ausgabe “ja” genau dann, wenn  $S \in T[1, n]$ .

## Fortsetzung CYK-Algorithmus

Noch eine Bemerkung: aus der aufgestellten Tabelle kann man auch die Ableitung für das Wort  $x$  ablesen, indem wir rückwärts die Regeln anwenden, die auf  $S$  in  $T[1, n]$  geführt haben. Hier sieht die Ableitung für  $aaabbbc$  dann folgendermaßen aus (die Nonterminale, die ersetzt werden, sind jeweils unterstrichen).

$$\begin{aligned} \underline{S} &\Longrightarrow \underline{A}B \Longrightarrow C\underline{F}B \Longrightarrow C\underline{A}DB \Longrightarrow CC\underline{F}DB \Longrightarrow CC\underline{A}DDB \\ &\Longrightarrow \underline{C}CCDDB \Longrightarrow a\underline{C}CCDDB \Longrightarrow aa\underline{C}DDB \Longrightarrow aaa\underline{D}DDB \\ &\Longrightarrow aaab\underline{D}DB \Longrightarrow aaabb\underline{D}B \Longrightarrow aaabbb\underline{B} \Longrightarrow aaabbbc \end{aligned}$$

# Pumping Lemma für kontextfreie Sprachen

Sei  $L$  eine kontextfreie Sprache. Dann gibt es eine Konstante  $k \in \mathbb{N}$ , so dass für alle Wörter  $z \in L$  mit  $|z| \geq k$  eine Zerlegung  $z = uvwxy$  existiert, so dass gilt:

- (i)  $|vwx| \leq k$  und  $|vx| \geq 1$ ,
- (ii) für alle  $i \in \mathbb{N}$  gilt  $uv^iwx^iy \in L$ .

# Pumping Lemma – Anwendung

Mit Hilfe des Pumping Lemmas kann man zeigen, dass folgende Sprachen nicht kontextfrei sind:

- $\{a^n b^n c^n \mid n \geq 1\}$ ,
- $\{ww \mid w \in \{a, b\}^*\}$ ,
- $\{a^m b^n a^m b^n \mid m, n \geq 1\}$ ,
- $\{a^{2^n} \mid n \geq 0\}$ ,
- $\{a^m b^n \mid 0 \leq m, 1 \leq n \leq 2^m\}$ .

# Abschlusseigenschaften

## Satz

Die Menge der kontextfreien Sprachen ist unter den Operationen

- (i) Vereinigung,
- (ii) Produkt (Konkatenation) und
- (iii) Kleene-Stern

abgeschlossen. Sie ist unter den Operationen

- (iv) Durchschnitt und
- (v) Komplement

nicht abgeschlossen.

# Weitere Entscheidungsprobleme

## Satz

Das Leerheitsproblem und das Endlichkeitsproblem für kontextfreie Grammatiken sind entscheidbar.

## Satz

Das Schnittproblem und das Äquivalenzproblem für kontextfreie Grammatiken sind unentscheidbar.



# Kellerautomaten

- **endliche Automaten** besitzen nur **begrenzten** Speicherplatz (ihre Zustände).
- **Turingmaschinen** besitzen **unbegrenzten** Speicherplatz mit im Prinzip **wahlfreiem Zugriff**.
- **Kellerautomaten** besitzen **unbegrenzten** Speicherplatz in Form eines **Kellerspeichers (Stack)**.

# Definition Kellerautomat

**Definition** Ein (nichtdeterministischer) Kellerautomat (kurz PDA von *push-down automaton*)  $M$  ist ein 6-Tupel  $M = (Z, \Sigma, \Gamma, \delta, z_0, \#)$ . Dabei ist


- $Z$  das Zustandsalphabet,
- $\Sigma$  das Eingabealphabet,
- $\Gamma$  das Kellularphabet,
- $z_0 \in Z$  der Anfangszustand,
- $\delta: Z \times (\Sigma \cup \{\varepsilon\}) \times \Gamma \rightarrow 2_{E}^{Z \times \Gamma^*}$  die Zustandsüberföhrungsfunktion ( $2_{E}^X$  bedeutet dabei die Menge der endlichen Teilmengen von  $X$ ),
- $\# \in \Gamma$  das Kelleraufangssymbol.

# Arbeitsweise von Kellerautomaten

- Der PDA startet im Zustand  $z_0$  und mit dem Kellerinhalt  $\#$ .
- Bei  $(z', B_1B_2 \dots B_k) \in \delta(z, a, A)$  mit  $a \in \Sigma$  befindet sich der PDA im Zustand  $z$ , liest auf dem Eingabeband ein  $a$  und im Keller ein  $A$  (das oberste Symbol). Er entfernt dieses  $A$  aus dem Keller, geht in den Zustand  $z'$  über, bewegt den Lesekopf auf dem Eingabeband einen Schritt nach rechts und schreibt auf den Keller das Wort  $B_1B_2 \dots B_k$  derart, dass  $B_1$  das neue oberste Symbol des Kellers ist.
- Bei  $(z', B_1B_2 \dots B_k) \in \delta(z, \varepsilon, A)$  liest er im Gegensatz zur obigen Aktion auf dem Eingabeband nichts ein und bewegt den Lesekopf auf dem Eingabeband nicht.
- Der PDA akzeptiert die Eingabe, wenn er sie vollständig eingelesen hat und der Keller leer ist (auch  $\#$  steht nicht mehr im Keller).

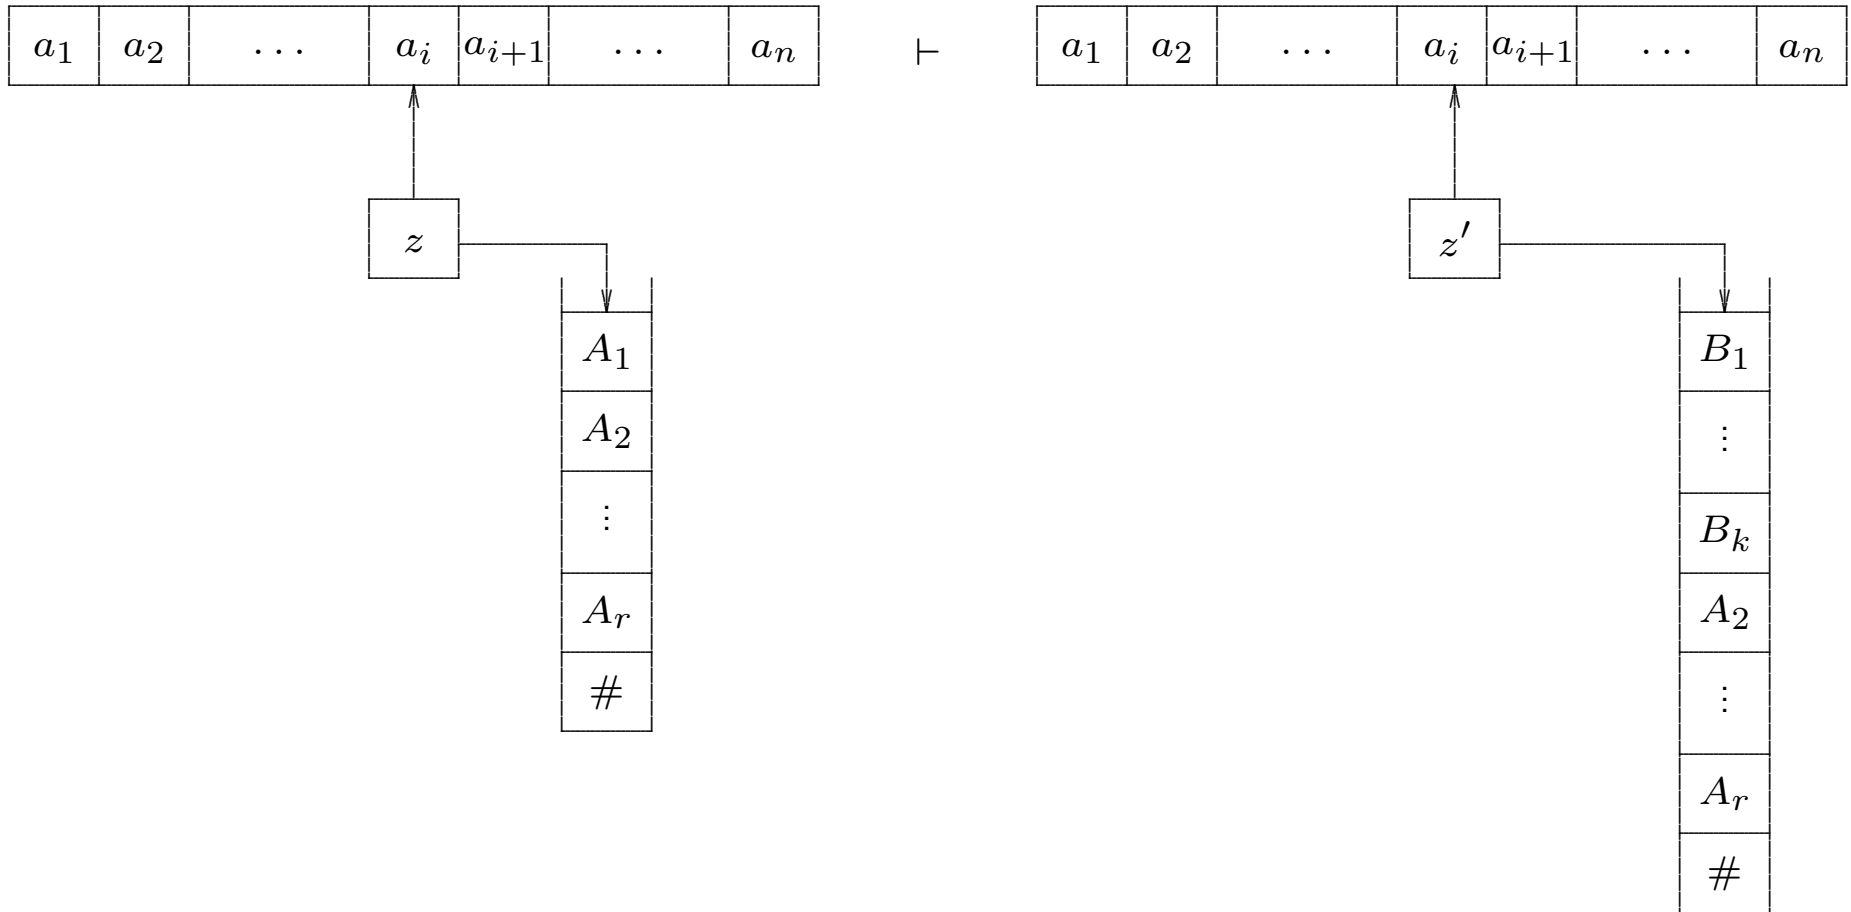
# Kellerautomat: Arbeitsweise für

$$(z', B_1 B_2 \cdots B_k) \in \delta(z, a_i, A_1)$$



# Kellerautomat: Arbeitsweise für

$$(z', B_1 B_2 \cdots B_k) \in \delta(z, \varepsilon, A_1)$$



# Konfiguration von Kellerautomaten

**Definition** Sei  $M = (Z, \Sigma, \Gamma, \delta, z_0, \#)$  ein Kellerautomat. Eine **Konfiguration** von  $M$  ist ein Tripel  $k \in Z \times \Sigma^* \times \Gamma^*$ .

Anschaulich beschreibt eine Konfiguration  $k = (z, v, \gamma)$  folgende augenblickliche Situation des PDA:

- er befindet sich im Zustand  $z$ ,
- $v$  ist die noch nicht verarbeitete Eingabe auf dem Eingabeband und
- im Keller steht das Wort  $\gamma$ , wobei das erste Symbol von  $\gamma$  das oberste Kellersymbol sein soll.

# PDA – Konfigurationsübergänge und akzeptierte Sprache

$k_1 \vdash k_2$  bedeutet, dass der Kellerautomat die Konfiguration  $k_1$  in genau einem Schritt in die Konfiguration  $k_2$  überführt.

$k_1 \vdash^* k_2$  bedeutet, dass der Kellerautomat  $k_1$  in endlich vielen Schritten (auch null) in  $k_2$  überführt.

## Definition

Für einen PDA  $M = (Z, \Sigma, \Gamma, \delta, z_0, \#)$  sei die von ihm **akzeptierte Sprache**  $T(M)$  definiert durch

$$T(M) = \{w \in \Sigma^* \mid (z_0, w, \#) \vdash^* (z, \varepsilon, \varepsilon) \text{ für ein } z \in Z\}.$$

## Beispiel eines PDA

Es sei  $M = (\{z_0, z_1\}, \{a, b\}, \{A, B, \#\}, \delta, z_0, \#)$  ein Kellerautomat, mit

$$\delta(z_0, a, X) = \{(z_0, AX)\} \quad \text{für } X \in \{B, \#\},$$

$$\delta(z_0, a, A) = \{(z_0, AA), (z_1, \varepsilon)\},$$

$$\delta(z_0, b, X) = \{(z_0, BX)\} \quad \text{für } X \in \{A, \#\},$$

$$\delta(z_0, b, B) = \{(z_0, BB), (z_1, \varepsilon)\},$$

$$\delta(z_0, \varepsilon, \#) = \{(z_1, \varepsilon)\},$$

$$\delta(z_1, a, A) = \{(z_1, \varepsilon)\},$$

$$\delta(z_1, b, B) = \{(z_1, \varepsilon)\},$$

$$\delta(z_1, \varepsilon, \#) = \{(z_1, \varepsilon)\}.$$

Dann gilt  $T(M) = \{ww^R \mid w \in \{a, b\}^*\}$ .



# Kellerautomaten und kontextfreie Sprachen

**Satz**

Eine Sprache  $L$  ist kontextfrei genau dann, wenn ein (nichtdeterministischer) Kellerautomat  $M$  mit  $T(M) = L$  existiert.

# Deterministisch kontextfreie Sprachen

**Definition.** Ein Kellerautomat  $M = (Z, \Sigma, \Gamma, \delta, z_0, \#)$  heißt **deterministisch**, wenn:

$$|\delta(z, a, A)| + |\delta(z, \varepsilon, A)| \leq 1 \text{ für alle } z \in Z, a \in \Sigma, A \in \Gamma.$$

**Definition.** Eine Sprache  $L \subseteq \Sigma^*$  heißt **deterministisch kontextfrei**, wenn  $L\$$  von einem deterministischen Kellerautomaten akzeptiert wird, wobei  $\$ \notin \Sigma$  ein Sondersymbol ist.

## Satz

Die Menge der deterministisch kontextfreien Sprachen ist eine **echte Teilmenge** der Menge der kontextfreien Sprachen.

## Beispiel eines deterministischen PDA

$M = (\{z_0\}, \{a_1, a_2, b_1, b_2, \$\}, \{A_1, A_2, \#\}, \delta, z_0, \#)$  ein Kellerautomat mit

$$\begin{aligned}\delta(z_0, a_1, X) &= \{(z_0, A_1X)\} && \text{für } X \in \{A_1, A_2, \#\}, \\ \delta(z_0, a_2, X) &= \{(z_0, A_2X)\} && \text{für } X \in \{A_1, A_2, \#\}, \\ \delta(z_0, b_1, A_1) &= \{(z_0, \varepsilon)\}, \\ \delta(z_0, b_2, A_2) &= \{(z_0, \varepsilon)\}, \\ \delta(z_0, \$, \#) &= \{(z_0, \varepsilon)\}.\end{aligned}$$

$T(M) = \{w\$ \mid w \in D_2\}$ , d.h.

die Dyck-Sprache  $D_2$  ist deterministisch kontextfrei.

## Weiteres Beispiel eines deterministischen PDA

Sei  $M = (\{z_0, z_1\}, \{a, b, c, \$\}, \{A, B, \#\}, \delta, z_0, \#)$  ein Kellerautomat mit

$$\delta(z_0, a, X) = \{(z_0, AX)\} \quad \text{für } X \in \{A, B, \#\},$$

$$\delta(z_0, b, X) = \{(z_0, BX)\} \quad \text{für } X \in \{A, B, \#\},$$

$$\delta(z_0, c, X) = \{(z_1, X)\} \quad \text{für } X \in \{A, B, \#\},$$

$$\delta(z_1, a, A) = \{(z_1, \varepsilon)\},$$

$$\delta(z_1, b, B) = \{(z_1, \varepsilon)\},$$

$$\delta(z_1, \$, \#) = \{(z_1, \varepsilon)\}.$$

Dann gilt  $T(M) = \{wcw^R\$ \mid w \in \{a, b\}^*\}$ .

# Bedeutung der deterministisch kontextfreien Sprachen

- Wortproblem entscheidbar **in linearer Zeit**  
(gegenüber kubischer Laufzeit des CYK-Algorithmus)
- Ausdruckskraft hinreichend für syntaktische Analyse im Compilerbau
- Bei realen Programmiersprachen kommen  **$LR(k)$ -Grammatiken** und deren Varianten zum Einsatz.

# Formale Sprachen – Übersichten

Chomsky-Hierarchie: **Typ 3  $\subsetneq$  Typ 2  $\subsetneq$  Typ 1  $\subsetneq$  Typ 0.**

Beispiele für die Echtheit der Inklusionen.

- $\{a^n b^n \mid n \geq 1\} \in \mathbf{Typ\ 2} \setminus \mathbf{Typ\ 3}$ ,
- $\{a^n b^n c^n \mid n \geq 1\} \in \mathbf{Typ\ 1} \setminus \mathbf{Typ\ 2}$ ,
- $K \in \mathbf{Typ\ 0} \setminus \mathbf{Typ\ 1}$ ,  
wobei  $K \subseteq \{0, 1\}^*$  das spezielle Halteproblem ist.

## Charakterisierungen der Sprachfamilien der Chomsky Hierarchie

Sprache	Grammatik	Automat	Andere
Regulär	Typ 3	Endlicher Automat (EA)	Regulärer Ausdruck
Deterministisch kontextfrei	$LR(k)$	Deterministischer Kellerautomat (DPDA)	
Kontextfrei	Typ 2	(Nichtdeterministischer) Kellerautomat (PDA)	
Kontextabhängig	Typ 1	(Nichtdeterministischer) Linear beschränkter Automat (LBA)	
Rekursiv aufzählbar	Typ 0	Turingmaschine (TM)	

# Determinismus vs. Nichtdeterminismus

Nichtdeterminismus	Determinismus	Äquivalenz
NEA	DEA	ja
PDA	DPDA	nein
LBA	DLBA	?
NTM	DTM	ja



# Abschlusseigenschaften

	Typ 3	Det. kf.	Typ 2	Typ 1	Typ 0
Vereinigung	ja	nein	ja	ja	ja
Durchschnitt	ja	nein	nein	ja	ja
Komplement	ja	ja	nein	ja	nein
Konkatenation	ja	nein	ja	ja	ja
Kleene-Stern	ja	nein	ja	ja	ja

# Entscheidbarkeitsprobleme

	Typ 3	Det. kf.	Typ 2	Typ 1	Typ 0
Wortproblem	ja	ja	ja	ja	nein
Leerheitsproblem	ja	ja	ja	nein	nein
Schnittproblem	ja	nein	nein	nein	nein
Äquivalenzproblem	ja	ja	nein	nein	nein