

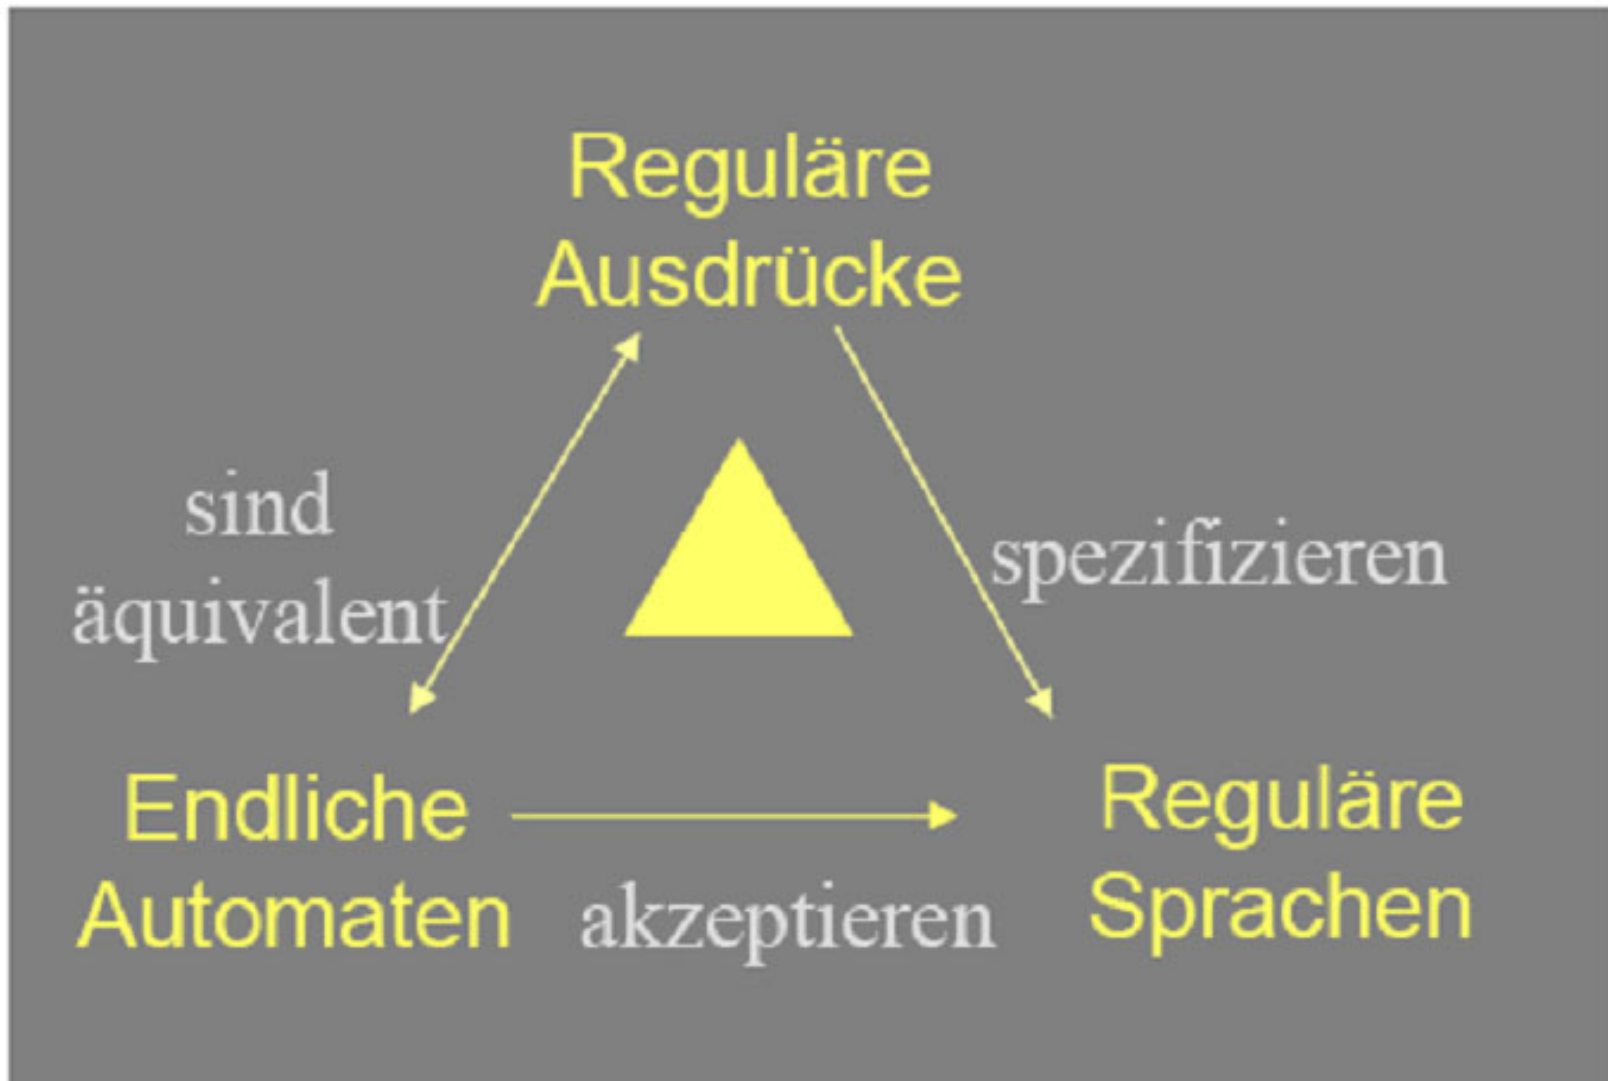
Einführung in die Computerlinguistik

Kontextfreie Sprachen und Pushdown-Automaten

Dozentin: Wiebke Petersen

WS 2004/2005

Wiederholung



©2004 Karin Haenelt

zu den Hausaufgaben

Welche Aussagen kann man mit Hilfe der Abschlußeigenschaften der regulären Sprachen und dem Pumping-Lemma über die Komplexität folgender formaler Sprachen machen:

1. $L_1 = \{w \in \{a, b\}^* : w \text{ enthält eine ungerade Anzahl von } b's\}$.
 L_1 ist regulär (L_1 akzeptierenden Automaten / L_1 erzeugende rechts-lineare Grammatik / regulärer Ausdruck)
2. $L_2 = \{w \in \{a, b\}^* : w \text{ enthält die gleiche Anzahl von } b's \text{ und } a's\}$.
 L_2 ist nicht regulär (Schnitt mit regulärer Sprache und Pumping-Lemma), obwohl für alle $v \in L_2$ auch $v^i \in L_2$
3. w^R ist das Wort w in umgekehrter Reihenfolge.
 $L_3 = \{ww^R : w \in \{a, b\}^*\}$.
 L_3 ist nicht regulär (Schnitt mit regulärer Sprache und Pumping-Lemma)

kontextfreie Sprachen

Definition 1. 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**.


Satz 2. 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 $a^n b^n$, die nicht regulär ist. ($S \rightarrow aSb, S \rightarrow \epsilon$)

Beispiel einer kontextfreien Sprache

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

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



weitere kontextfreie Sprachen

- $L_1 = \{ww^R : w \in \{a, b\}^*\}$
- $L_2 = \{a^i b^j : i \geq j\}$
- $L_3 = \{w \in \{a, b\}^* : \text{Zahl der } a's \text{ größer als Zahl der } b's\}$
- $L_4 = \{w \in \{a, b\}^* : \text{Zahl der } a's \text{ gleich Zahl der } b's\}$
$$\left\{ \begin{array}{lll} S \rightarrow aB & A \rightarrow a & B \rightarrow b \\ S \rightarrow bA & A \rightarrow aS & B \rightarrow bS \\ & A \rightarrow bAA & B \rightarrow aBB \end{array} \right\}$$

ambige Grammatiken und ambige Sprachen

Definition 3. Gegeben eine kontextfreie Grammatik G . Eine Ableitung bei der stets das am weitesten links stehende nichtterminale Symbol ersetzt wird, heißt **Linksableitung**

Definition 4. Eine kontextfreie Grammatik G heißt **ambig** genau dann, wenn es für ein $w \in L(G)$ mehrere Linksableitungen mit $S \rightarrow^* w$ gibt. Sonst heißt G **eindeutig**.

Definition 5. Eine kontextfreie Sprache L heißt **ambig** genau dann, wenn jede kontextfreie Grammatik mit $L(G) = L$ ambig ist.





Ableitungsbäume und Linksableitungen

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

Beispiel einer ambigen Grammatik



$G = (N, T, NP, P)$ mit $N = \{S, EN, NP, VP, PP, D, N, P\}$,
 $T = \{\text{Eva, sieht, den, Mann, mit, dem, Fernglas}\}$,

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



2. Beispiel einer ambigen Grammatik

$G = (N, T, NP, P)$ mit $N = \{D, N, P, NP, PP\}$, $T = \{\text{the, cat, hat, in}\}$,

$$P = \left\{ \begin{array}{lll} NP \rightarrow D N & D \rightarrow \text{the} & N \rightarrow \text{hat} \\ NP \rightarrow NP PP & N \rightarrow \text{cat} & P \rightarrow \text{in} \\ PP \rightarrow P NP \end{array} \right\}$$


Chomsky-Normalform

Definition 6. Eine Grammatik ist in **Chomsky-Normalform** (CNF), wenn alle Regeln die Gestalt

1. $A \rightarrow a$
2. $A \rightarrow BC$

mit $A, B, C \in T$ und $a \in \Sigma$ haben (und gegebenenfalls $S \rightarrow \epsilon$, dann aber ohne S auf den rechten Regelseiten).

Satz 7. Jede kontextfreie Sprache kann durch eine Grammatik in Chomsky-Normalform erzeugt werden.

$$\text{Beispiel: } \left\{ \begin{array}{lll} S \rightarrow aB & A \rightarrow a & B \rightarrow b \\ S \rightarrow bA & A \rightarrow aS & B \rightarrow bS \\ & A \rightarrow bAA & B \rightarrow aBB \end{array} \right\}$$

$$\left\{ \begin{array}{lll} S \rightarrow A'B & A \rightarrow a & A' \rightarrow a \\ S \rightarrow B'A & B \rightarrow b & B' \rightarrow b \\ A \rightarrow A'S & B \rightarrow B'S & \\ A \rightarrow B'A_2 & B \rightarrow A'B_2 & \\ A_2 \rightarrow AA & B_2 \rightarrow BB & \end{array} \right\}$$

13 Kellerautomaten (Pushdown-Automaten)

Ziel:

Einführung eines Automatenmodells, mit dem genau die kontextfreien Sprachen akzeptiert werden können.

Wir benötigen eine echte Erweiterung des Modells des endlichen Automaten.

Ansatz: Hinzunahme eines unbeschränkten Speichers.

Speicherinhalt ist jeweils ein Wort.

Zugriff auf Speicherinhalt über die Spitze: Der Wort**anfang** kann jeweils gelesen und modifiziert werden.

Wir sprechen von **Kellerspeicher** oder **Stack** oder **Pushdown Stack**.

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.

Kellerautomaten

Kellerautomaten entstehen aus endlichen Automaten durch

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

Kellerautomaten: Definition

Definition 8. Ein **Kellerautomat** ist ein 6-Tupel $\langle \Phi, \Sigma, \Gamma, \Delta, q_0, F \rangle$ bestehend aus:

1. einem **Zustandsalphabet** Φ
2. einem **Eingabealphabet** Σ
3. einem **Kelleralphabet** Γ
4. einer **Übergangsrelation / Transitionsrelation** $\Delta \subseteq \Phi \times \Sigma \cup \{\epsilon\} \times \Gamma \cup \{\epsilon\} \times \Gamma^* \times \Phi$
5. einem **Startzustand** q_0 und
6. einer Menge von **Endzuständen** $F \subset \Phi$.

Wirkung einer Transition

Bedeutung der Transition (p, a, Z, v, q) :

In Zustand p , bei Eingabebuchstabe a und Symbol Z auf Kellerspitze:

Ersetze Z an Kellerspitze durch das Wort v , gehe zum nächsten Eingabebuchstaben und in den Zustand q über.

Bei zweiter Komponente ε :

analog, ohne auf der Eingabe voranzuschreiten und ohne den Eingabebuchstaben zu lesen.

Transition

oberstes Symbol auf dem Stack
(wird entfernt)
- pop up -

neuer Zustand

(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, Z, v, q)

aktueller Zustand



zu lesendes Eingabesymbol

Wort, das auf den Stack gelegt wird
- push down -




aba**a**abbbabbbb

abaa**a**abbbabbbb




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



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 Grammatiken zu Kellerautomaten

Satz 9. *Zu einer kontextfreien Grammatik G kann man einen Kellerautomaten A konstruieren, der die von G generierte Sprache akzeptiert.*

Konstruktionsvorschrift:

Sei $G = (N, T, S, P)$ die gegebene Grammatik. Konstruiere den Automaten $A = \langle \Phi, \Sigma, \Gamma, \Delta, q_0, F \rangle$ wie folgt:

- $\Phi = \{q_0, q_1\}, \quad \Sigma = T, \quad \Gamma = T \cup N, \quad F = \{q_1\},$
- Δ enthält die folgenden Transitionen:
 - $(q_0, \epsilon, \epsilon, S, q_1)$
 - für jede Regel $B \rightarrow \beta$ der Grammatik eine Transition $(q_1, \epsilon, B, \beta, q_1)$
 - für jedes Symbol $a \in T$ eine Transition $(q_1, a, a, \epsilon, q_1)$.

Wirkungsweise der Konstruktion

- 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, 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 β
 - Leseschritte:
Lies ein $a \in T$ der Eingabekette und entferne a von der Kellerspitze.

Hausaufgaben

1. Beschreiben Sie die Sprache, die von der Grammatik auf Folie 4 generiert wird.
2. Geben Sie die Grammatik von Folie 4 in der Chomsky-Normalform wieder.
3. Zeichnen Sie alle Ableitungsbäume für das Wort $aababb$ der Sprache L_4 von Folie 5.
4. Gebe eine Grammatik an, die die Sprache der wohlgeformten arithmetischen Terme über dem Alphabet $\{0, 1, 2, 3, 4, 5, 6, 7, 8, 9, (,), +, -, \cdot, :\}$ generiert.
5. Geben Sie kontextfreie Grammatiken für die Sprachen L_1 , L_2 und L_3 von Folie 5 an.
6. w^R ist das Wort w in umgekehrter Reihenfolge. Geben Sie eine kontextfreie Grammatik für die Sprache $L = \{ww^R : w \in \{a, b\}^*\}$ an. Konstruieren Sie einen Kellerautomaten, der L akzeptiert.
7. Gegeben sei folgende Regelmenge einer Grammatik G :

$$\begin{array}{llll} S & \rightarrow & aB & S & \rightarrow & bA \\ A & \rightarrow & a & A & \rightarrow & aS & A & \rightarrow & bAA \\ B & \rightarrow & b & B & \rightarrow & bS & B & \rightarrow & aBB \end{array}$$

Welche Sprache wird von der Grammatik generiert?

Geben Sie einen Kellerautomaten an, der die Sprache akzeptiert.