

HA-Lösung

TA-Lösung

Einführung in die theoretische Informatik – Aufgabenblatt 7

Beachten Sie: Soweit nicht explizit angegeben, sind Ergebnisse stets zu begründen!

Hausaufgaben: Abgabe bis zum **08.06.2016** (Mittwoch) um 12:00

Aufgabe 7.1 Kontextfreie Sprachen

3P

Sei $L = \{w \in \Sigma^* : |w|_a = 2|w|_b\}$. Geben Sie eine CFG G über dem Alphabet $\Sigma = \{a, b\}$ mit $L(G) = L$ an und zeigen Sie die Korrektheit mittels Induktion.

Lösung: Die Grammatik $G = (\{S\}, \{a, b\}, P, S)$ mit den folgenden Produktionen P erfüllt die gewünschten Eigenschaften:

$$S \rightarrow \varepsilon \mid SS \mid aSaSb \mid aSbSa \mid bSaSa$$

Korrektheitsbeweis:

$L \subseteq L(G)$. Induktion über die Länge von $w \in L$.

- $|w| = 0$: Dann ist $w = \varepsilon$ und kann mit $S \rightarrow \varepsilon$ produziert werden. Deshalb $w \in L(G)$.
- $1 \leq |w| \leq 2$: Es gibt kein $w \in L$ mit Länge 1 oder 2.
- $|w| \geq 3$: Sei $w \in L$. Wir verwenden die Funktion h („Höhe“) um die gewichtete Differenz zwischen der Anzahl der a s und b s zu beschreiben:

$$h(w) = 2|w|_b - |w|_a$$

Offensichtlich gilt $h(w) = 0$ gdw. $w \in L$. Wir betrachten folgende Fälle:

- w hat eine Nullstelle. Es existiert somit eine nicht-triviale Zerlegung $w = uv$ mit $u \neq \varepsilon \neq v$ und $h(u) = h(v) = 0$. Da $|u| < |w| > |v|$ gilt, können wir die Induktionshypothese anwenden und erhalten $S \rightarrow SS \xrightarrow{*} uS \xrightarrow{*} uv$ und somit $uv \in L(G)$.
- w hat keine Nullstelle. Dann trifft einer der drei folgenden Fälle zu:
 - * $w = bu$ für ein $u \in \Sigma^*$ mit $h(u) = -2$. Da w keine Nullstellen hat und nur 1-Schritten fallen kann, ist h nicht-negativ für alle Präfixe von w . Weil $h(w) = 0$ gelten muss, kann u in $u = vaa$ mit $v \in \Sigma^*$ und $h(v) = 0$ zerlegt werden. Somit $S \rightarrow bSaSa \rightarrow bSaa \xrightarrow{*} bvaa = w$ und $w \in L(G)$.
 - * $w = aua$ für ein $u \in \Sigma^*$ mit $h(u) = 2$. Da w keine Nullstellen hat, kann u in $u = v_1bv_2$ mit $v_1, v_2 \in \Sigma^*$ und $h(v_1) = h(v_2) = 0$ zerlegt werden. Somit $S \rightarrow aSbSa \rightarrow bSaSa \xrightarrow{*} av_1bv_2a = w$ und $w \in L(G)$.
 - * $w = ub$ für ein $u \in \Sigma^*$ mit $h(u) = -2$. Analog.

$L \supseteq L(G)$. Induktion über die Länge der Ableitung von $w \in L(G)$.

- $S \rightarrow \varepsilon$: $\varepsilon \in L$
- $S \rightarrow SS \xrightarrow{*} w_1w_2$: Nach Induktion $w_1, w_2 \in L$ und somit auch $w_1w_2 \in L$.
- $S \rightarrow aSaSb \xrightarrow{*} aw_1aw_2b$: Nach Induktion $w_1, w_2 \in L$ und somit auch $aw_1aw_2b \in L$.
- Restliche Fälle analog.

Zeigen Sie mit Hilfe des Pumping-Lemmas für kontextfreie Sprachen, dass die Sprache $L = \{a^i b^{2^i} \mid i \geq 0\}$ nicht kontextfrei ist.

Lösung: Angenommen, L wäre kontextfrei. Dann sei n eine Pumping-Lemma-Zahl und betrachte das Wort $z = a^n b^{2^n}$. Es existiert eine Zerlegung $z = uvwxy$, so dass $vx \neq \epsilon$, $|vwx| \leq n$ und für alle $i \in \mathbb{N}_0$ gilt $uv^i wx^i y \in L$.

Wir unterscheiden vier Fälle:

- (a) $v = a^k$ und $x = a^l$ für $k + l > 0$. Dann ist $uv^0 wx^0 y = a^{n-(k+l)} b^{2^n} \notin L$.
- (b) $v = b^k$ und $x = b^l$ für $k + l > 0$. Dann ist $uv^0 wx^0 y = a^n b^{2^n-(k+l)} \notin L$.
- (c) $v = a^k b^l$ oder $x = a^k b^l$ für $k, l > 0$. Dann ist $v^2 = a^k b^l a^k b^l$, enthält also einen b - a -Übergang. Also ist $uv^2 wx^2 y \notin L$.
- (d) Sonst müssen $v = a^k$ und $x = b^l$ sein für $k, l > 0$. Also ist $uv^{i+1} wx^{i+1} y = a^{n+ik} b^{2^n+il}$ für ein beliebiges $i \in \mathbb{N}_0$. Dieses Wort ist genau dann in L , wenn gilt $2^{n+ik} = 2^n + il$. Eine lineare und eine exponentielle Funktion haben aber höchstens zwei Schnittpunkte; also gilt obige Gleichung höchstens für zwei i und damit insbesondere nicht für alle i .

Für das Wort $z \in L$ existiert also keine passende Zerlegung, was ein Widerspruch zur Annahme ist. Also ist L nicht kontextfrei.

Aufgabe 7.3 CNF Blow-Up

- (a) Geben Sie ein eine Familie von Grammatiken G_n der Größe $\mathcal{O}(n)$ an, so dass eine Übersetzung in eine Grammatik G'_n in CNF **entsprechend den Folien** exponentiell größer ist ($\mathcal{O}(2^n)$) und begründen Sie, warum es dieses Wachstum gibt.
- (b) Zeigen Sie: Überführt man eine CFG G in CNF, indem man die Schritte der Folien umordnet nach (3), (4), (1), (2), dann ist die erzeugte Grammatik G' ebenfalls in CNF, jedoch höchstens quadratisch größer als G .

Die Größe von G ist einfach die Länge des Wortes, das man erhält, indem man alle Produktionen zu einem Wort über $V \cup \Sigma$ konkateniert.

Lösung:

- (a) $S \rightarrow X_1 X_2 \dots X_n \quad X_i \rightarrow a \mid \epsilon$
- (b) Sei n die Größe von G . (3) (4) fügt $\mathcal{O}(n)$ neue Regeln ein (und löscht teilweise einige). (1) fügt jetzt aber nur $\mathcal{O}(n^2)$ neue Regeln ein, da die rechte Seite jeder Regel nur aus zwei Variablen besteht. (2) fügt nun aber auch nur $\mathcal{O}(n)$ Regeln ein.

Aufgabe 7.4 Chomsky-Normalform

Wir betrachten die Grammatik $G = (\{S, T, U, V\}, \{a, b, c\}, P, S)$ mit den folgenden Produktionen P :

$$\begin{aligned} S &\rightarrow TVS \mid U \\ T &\rightarrow aSb \mid TVT \mid c \\ U &\rightarrow cT \mid aV \\ V &\rightarrow \epsilon \mid VV \end{aligned}$$

Konstruieren Sie eine zu G äquivalente Grammatik G' in Chomsky-Normalform.

Hinweis: Es kann hilfreich sein nach jedem Schritt unproduktive und unerreichbare Variablen zu entfernen.

Lösung: Wir überführen G schrittweise in Chomsky-Normalform:

- (a) Elimination von ϵ -Produktionen und der dann unproduktiven Variable V :

$$\begin{aligned} S &\rightarrow TS \mid U \\ T &\rightarrow aSb \mid TT \mid c \\ U &\rightarrow cT \mid a \end{aligned}$$

- (b) Elimination von Kettenregeln ($S \rightarrow U$) und der dann unerreichbaren Variable U :

$$S \rightarrow TS \mid cT \mid a \quad T \rightarrow aSb \mid TT \mid c$$

- (c) Einführung von Nichtterminalen für Buchstaben: Für a, b und c werden Nichtterminale A, B und C eingeführt, da die rechte Seiten der Produktionen $S \rightarrow cT$ und $T \rightarrow aSb$ eine Länge ≥ 2 haben:

$$S \rightarrow TS \mid CT \mid a \quad T \rightarrow ASB \mid TT \mid c \quad A \rightarrow a \quad B \rightarrow b \quad C \rightarrow c$$

(d) Aufspalten langer Produktionen:

$$\begin{array}{ll} S \rightarrow TS \mid CT \mid a & A \rightarrow a \\ T \rightarrow AT' \mid TT \mid c & B \rightarrow b \\ T' \rightarrow SB & C \rightarrow c \end{array}$$

Das Ergebnis ist in Chomsky-Normalform.

Aufgabe 7.5 **Lineare Grammatiken**

1P+2P

Wir betrachten die *linearen* Grammatiken aus TA 6.3. Offensichtlich gilt „regulär \subseteq linear \subseteq kontextfrei“. Entscheiden Sie folgende Aussage und geben Sie einen passenden Beweis für Ihre Antwort an:

- (a) Gilt entweder „regulär \subset linear“ oder „regulär = linear“?
- (b) Gilt „linear = kontextfrei“? *Tipp:* TA 6.3 (b)

Lösung:

- (a) *regulär \subset linear:* Die Sprache $\{a^n b^n \mid n > 0\}$ ist bekanntermaßen nicht regulär. Sie ist aber linear, denn sie wird von der linearen Grammatik $(\{S\}, \{a, b\}, P, S)$ mit den Produktionen $S \rightarrow aSb \mid ab$ erzeugt.
- (b) *linear \subset kontextfrei:* Die Sprache $L = \{a^m b^m a^n b^n \mid m > 0, n > 0\}$ ist kontextfrei, denn sie wird von der kontextfreien Grammatik $(\{S, A\}, \{a, b\}, P, S)$ mit den Produktionen $S \rightarrow AA$ und $A \rightarrow aAb \mid ab$ erkannt. Aber diese Sprache ist nicht linear.

Angenommen, L wäre linear. Dann existiert eine Grammatik G mit $L = L(G)$ in der Form von TA 6.3 (a) und sei $n = |V| + 1$. Wir verwenden nun TA 6.3 (b), um einen Widerspruch abzuleiten. Wir betrachten das Wort $z = a^n b^n a^n b^n$. Laut TA 6.3 (b) existiert eine Zerlegung $z = uvwxy$, so dass

$$(1) \quad vx \neq \epsilon \quad (2) \quad |vwx| \leq n \quad (3) \quad \forall i \in \mathbb{N}_0. uv^i wx^i y \in L$$

Aufgrund von (2) gilt $w = a^{n-|uv|} b^n a^n b^{n-|xy|}$. Wir unterscheiden zwei Fälle:

- (i) $v = a^k$ für $k > 0$. Dann ist $uv^0 wx^0 y = a^{n-k} b^n \dots \notin L$.
- (ii) $x = b^k$ für $k > 0$. Dann ist $uv^0 wx^0 y = \dots a^n b^{n-k} \notin L$.

Für das Wort $z \in L$ existiert also keine passende Zerlegung, was ein Widerspruch zur Annahme ist. Also ist L nicht linear.

Tutoraufgaben: Besprechung in KW23

Aufgabe 7.1 Abschlusseigenschaften kontextfreier Sprachen

- (a) Zeigen Sie, dass CFL unter Schnitt mit regulären Sprachen abgeschlossen sind.
(b) Zeigen Sie, dass auch der Präfixabschluss $\{u \mid \exists v: uv \in L\}$ einer CFL L kontextfrei ist.

Lösung:

- (a) Sei L kontextfrei und L' regulär. Ohne Einschränkung gibt es $G = (V, \Sigma, P, S)$ CFG in CNF und $A = (Q, \Sigma, \delta, q_I, F)$ DFA mit $L = L(G)$ und $L' = L(A)$.

Idee: Wir erweitern G so, dass eine akzeptierende Berechnung von A geraten wird.

Definiere $G' = (V', \Sigma, P', S')$ wie folgt:

- $V' = Q \times V \times Q$
- $P' = P'_{X \rightarrow YZ} \uplus P'_{X \rightarrow a} \uplus P'_{S'}$ mit

$$\begin{aligned} P'_{X \rightarrow YZ} &:= \{(q, X, q') \rightarrow (q, Y, q'')(q'', Z, q') \mid X \rightarrow YZ \in P\} \\ P'_{X \rightarrow a} &:= \{(q, X, q') \rightarrow a \mid X \rightarrow a \in P \wedge \delta(q, a) = q'\} \\ P'_{S'} &:= \{S' \rightarrow (q_I, S, q_F) \mid q_F \in F\} \cup \{S' \rightarrow \varepsilon \mid \varepsilon \in L(G) \cap L(A)\} \end{aligned}$$

Behauptung: $L(G') = L(G) \cap L(A)$

Sei $w = a_1 a_2 \dots a_l \in L(G')$. Dann gibt es eine Ableitung der Form

$$S' \rightarrow (q_I, S, q_F) \rightarrow^* (q_0, X_1, q_1)(q_1, X_2, q_2) \dots (q_{l-1}, X_l, q_l)$$

mit $(q_{i-1}, X_i, q_i) \rightarrow a_i$.

Nach Def. von $P_{X \rightarrow YZ}$ muss $q_0 = q_I$ und $q_l = q_F$ gelten.

Nach Def. von $P_{X \rightarrow a}$ muss $q_i = \delta(q_{i-1}, a)$ gelten.

Damit existiert eine akzeptierende Berechnung von A zu w , also $w \in L(A)$.

Nach Definition erhält man durch Vergessen der q, q' , also durch Übergang von (q, X, q') zu X aus der obigen Ableitung auch eine Ableitung in G , womit auch $w \in L(G)$ folgt.

Insgesamt $w \in L(A) \cap L(G)$.

Sei $w \in L(A) \cap L(G)$. Dann existiert eine akzeptierende Berechnung $q_i = \delta(q_{i-1}, a_i)$ von A zu w und ein Ableitungsbaum zu w bzgl. G . Letzteren erweitert man induktiv zu einem Ableitungsbaum von G' : Den inneren Knoten, an dem das Blatt zu a_i hängt, schreibt man von X auf (q_{i-1}, X, q_i) um. Bottom-up/induktiv schreibt man dann X nach (q_i, X, q_k) um, falls seine beiden Kinder (da CNF) gerade $(q_i, Y, q_j), (q_j, Z, q_k)$ sind. Alternativ: aus X wird (q_i, X, q_k) , falls X das Teilwort $a_{i+1} \dots a_k$ erzeugt. Da G' die Zwischenzustände q'' frei mittels $P_{X \rightarrow YZ}$ raten kann, handelt es sich tatsächlich um einen Ableitungsbaum von w bzgl. P' , also $w \in L(G')$.

- (b) Sei $G = (V, \Sigma, P, S)$ CFG in CNF mit $L = L(G)$ und $L' := \{u \in \Sigma^* \mid \exists v \in \Sigma^*: uv \in L(G)\}$.

Idee:

Es gilt: $u \in L'$ gdw. es gibt einen Ableitungsbaum zu uv bzgl. G für ein $v \in \Sigma^*$.

Betrachte in diesem Ableitungsbaum zu uv den eindeutigen Pfad vom letzten Zeichen von u zur Wurzel. Wir erweitern G so zu G' , dass G' diesen Pfad raten kann und die Teilbäume, die Zeichen von v erzeugen, weglassen kann.

Konstruiere $G' = (V \uplus V' \uplus \{S''\}, \Sigma, P \uplus P', S'')$ hierzu wie folgt:

- $V' = \{X' \mid X \in V\}$ – die Markierung rät den Pfad von der Wurzel zum letzten Zeichen von u und steht immer am rechten NT einer Ableitung bzgl. G'
- $P' = \{X' \rightarrow YZ', X' \rightarrow Y' \mid X \rightarrow YZ\} \cup \{X' \rightarrow a \mid X \rightarrow a \in P\} \cup \{S'' \rightarrow S' \mid \varepsilon\}$ – P' erlaubt G' zu raten, ob das letzte Zeichen von u durch Y oder Z erzeugt wird. Falls es durch Y erzeugt wird, wird der durch Z erzeugte Suffix fallengelassen (Fall $X' \rightarrow Y'$).

Behauptung:

$$L(G') = L' := \{u \in \Sigma^* \mid \exists v \in \Sigma^*: uv \in L(G)\}.$$

Beweis:

Sei $u \in L'$. Betrachte entsprechend der obigen Beschreibung einen Ableitungsbaum zu $uv \in L(G)$ bzgl. G . Markiere die Knoten entlang des Pfades vom letzten Zeichen von u bis zur Wurzel. Schneide die Teilbäume zu v ab. Nach Konstruktion erhält man einen Ableitungsbaum zu u bzgl. G' .

Sei $u \in L(G')$. Betrachte Ableitungsbaum zu u bzgl. G' . Für jeden inneren Knoten, der (1) kein Terminal erzeugt, (2) einem markierten NT X' entspricht und (3) nur ein Kind hat, das nach Definition von P' damit auch einem markierten NT Y' entsprechen muss, gibt es eine Regel $X \rightarrow YZ \in P$ bzgl. der originalen Grammatik G . OBdA. ist G auf die nützlichen Symbole reduziert, womit es mindestens einen Ableitungsbaum zu Z gibt. Füge diesen als rechten Teilbaum bei dem inneren Knoten an. Ersetze dann X' durch X im Baum, um einen Ableitungsbaum bzgl. G zu erhalten, der ein Wort der Form uv erzeugt.

Aufgabe 7.2 CYK-Algorithmus

(a) Sei G durch folgende Produktionen gegeben:

$$S \rightarrow AB \mid CD \mid AT \mid CU \mid SS \quad T \rightarrow SB \quad U \rightarrow SD \quad A \rightarrow (\quad B \rightarrow) \quad C \rightarrow \{ \quad D \rightarrow \}$$

Wenden Sie den CYK-Algorithmus auf folgende Wörter an:

$$w_1 = ()\{\}\quad w_2 = ()\{(\quad w_3 = ()\}$$

(b) Wir möchten den CYK-Algorithmus so abändern, dass er Eingabefehler (z.B. eine schließende Klammer ohne passende öffnende Klammer) erkennt und die Position des Fehlers bestimmt. Passen Sie hierzu den CYK-Algorithmus so an, dass er für gegebenes $w \in \Sigma^*$ den längsten Präfix u bestimmt, so dass sich u zu einem Wort in $L(G)$ ergänzen lässt.

Beispiel:

$$G: S \rightarrow AB \mid SS \quad A \rightarrow a \quad B \rightarrow b$$

Dann gilt $w = ababb \notin L(G)$, aber $ab, abab \in L(G)$; weiterhin gibt es kein $v \in \Sigma^*$, so dass $wv \in L(G)$ gilt, womit $abab$ der gesuchte Präfix ist. Im Fall $w = aba$ wäre aba der gesuchte Präfix, da $wb \in L(G)$ gilt.

(c) Wenden Sie den Algorithmus aus (b) auf die Wörter aus (a) an, um den maximalen Präfix zu bestimmen, der sich noch zu einem Wort in $L(G)$ ergänzen lässt.

Lösung:

(a) Berechnen der CYK-Tabelle:

16 S					
15	26				
14	25	36 S			
13	24	35	46 U		
12 S	23	34	45 S	56	
11 A	22 B	33 C	44 A	55 B	66 D
()	{	()	}

Ablezen: $w_1 \in L(G)$, da $S \in V_{16}$. $w_2 \notin L(G)$, da $S \notin V_{14}$. $w_3 \notin L(G)$, da $S \notin V_{46}$.

(b) Gegeben G konstruiere G' mit $L(G') = \{u \mid uv \in L(G)\}$ entsprechend TA 7.1(b) zzgl. Zusammenziehen von Kettenproduktionen $X' \rightarrow Y'$.

Sei $w = a_1 \dots a_l$ gegeben und $u = a_1 \dots a_k$ ein Präfix von w .

u lässt sich zu einem Wort aus $L(G)$ ergänzen gdw. $u \in L(G')$ gdw. $S' \in V_{1,k}$ wenn man den CYK bzgl. G' auf w anwendet.

Suche daher nach dem maximalen k , so dass $S' \in V_{1,k}$ gilt, um den maximalen Präfix von w zu bestimmen, der sich zu einem Wort auf $L(G)$ ergänzt lässt.

(c) Berechnete Grammatik für Präfixsprache ohne Start- ε -Produktion:

$$\begin{aligned} S' &\rightarrow SS' \mid AT' \mid CU' \mid AB \mid CD \mid (\mid \{ \\ S &\rightarrow AB \mid CD \mid AT \mid CU \mid SS \\ T' &\rightarrow SS' \mid AT' \mid CU' \mid AB \mid CD \mid SB \mid (\mid \{ \\ T &\rightarrow SB \\ U' &\rightarrow SD \mid SS' \mid AT' \mid CD \mid CU' \mid AB \mid (\mid \{ \\ U &\rightarrow SD \\ A &\rightarrow (\quad B \rightarrow) \quad C \rightarrow \{ \quad D \rightarrow \} \end{aligned}$$

Berechnen der CYK-Tabelle:

