

Theoretische Informatik 1

Große Übung 5

René Maseli
Prof. Dr. Roland Meyer

TU Braunschweig
Wintersemester 2024/25

Übungsaufgabe 9.7:

Sei Σ ein Alphabet. Wir definieren $\text{rev} : \Sigma^* \rightarrow \Sigma^*$ mit $\text{rev}(w_1 w_2 \dots w_{n-1} w_n) = w_n w_{n-1} \dots w_2 w_1$ und $\text{rev}(L) := \{ \text{rev}(w) \mid w \in L \}$. Zeigen Sie, dass sowohl die Klasse der regulären, als auch die der kontextfreien Sprachen unter rev abgeschlossen sind.

Zwei Fliegen, eine Klappe: Für eine formale Grammatik $G = \langle \Sigma, N, S, P \rangle$ definiere die formale Grammatik $\text{rev}(G) := \langle \Sigma, N, S, P' \rangle$ mit $P' := \{ \text{rev}(a) \rightarrow \text{rev}(b) \mid a \rightarrow b \in P \}$.

Lemma

Es gilt $\mathcal{L}(\text{rev}(G)) = \text{rev}(\mathcal{L}(G))$.

Beweis

Sei $w \in \mathcal{L}(G)$ und $S = a_0 \Rightarrow a_1 \Rightarrow \dots \Rightarrow a_m = w$ eine Ableitung von G . Dann ist $S = \text{rev}(a_0) \Rightarrow \text{rev}(a_1) \Rightarrow \dots \Rightarrow \text{rev}(a_m) = \text{rev}(w)$ eine Ableitung von $\text{rev}(G)$. Es folgt also $\text{rev}(w) \in \mathcal{L}(\text{rev}(G))$ und, da dies für alle $w \in \mathcal{L}(G)$ gilt, folgt $\text{rev}(\mathcal{L}(G)) \subseteq \mathcal{L}(\text{rev}(G))$.

Da für alle $w \in \Sigma^*$ auch $\text{rev}(\text{rev}(w)) = w$ gilt, kann man analog auch $\mathcal{L}(\text{rev}(G)) \subseteq \text{rev}(\mathcal{L}(G))$ zeigen. □

Korollar

Falls L kontextsensitiv ist, ist $\text{rev}(G)$ kontextsensitiv.

Falls G linkslinear ist, ist $\text{rev}(G)$ rechtslinear.

Falls G rechtslinear ist, ist $\text{rev}(G)$ linkslinear.

Beweis

Sei L kontextfrei. Dann gibt es eine kontextfreie Grammatik G mit $\mathcal{L}(G) = L$. Wie erwähnt, ist $\text{rev}(G)$ eine kontextfreie Grammatik, also ist $\mathcal{L}(\text{rev}(G)) = \text{rev}(L)$ kontextfrei.

Sei weiterhin L regulär. Dann gibt es eine linkslineare Grammatik G mit $\mathcal{L}(G) = L$. $\text{rev}(G)$ ist dann rechtslinear und damit ist $\mathcal{L}(\text{rev}(G)) = \text{rev}(L)$ wieder regulär. □

Übungsaufgabe 9.8:

Es sei die folgende kontextfreie Grammatik G gegeben über $\Sigma = \{c, d\}$.

$$S \rightarrow A \mid ABB$$

$$A \rightarrow Sc \mid \varepsilon$$

$$B \rightarrow dB \mid c$$

Finden Sie eine äquivalente Grammatik G' in Chomsky-Normalform.

Finden Sie anschließend eine äquivalente Grammatik G'' in Greibach-Normalform.

Zur Erinnerung: Eine Grammatik ist in Chomsky-Normalform (CNF), falls alle Produktionen die Form $X \rightarrow YZ$ oder $X \rightarrow s$ haben. Die Greibach-Normalform (GNF) benötigt alle Produktionen in der Form $X \rightarrow sX_1 \dots X_n$ (mit $X, Y, Z, X_1, \dots, X_n \in N$ und $s \in \Sigma$).

Chomsky-Normalform

Für die CNF eliminiert man zuerst die ε -Produktionen (sowohl A als auch S können zu ε übersetzt werden). Die resultierende Grammatik G_1 erfüllt $\mathcal{L}(G_1) = \mathcal{L}(G) \setminus \{\varepsilon\}$.


$$G_1 : \quad S \rightarrow A \mid ABB \mid BB \quad A \rightarrow ScC \mid cC \quad B \rightarrow dB \mid c$$

Nur $S \rightarrow BB$ und $B \rightarrow c$ haben schon CNF, der Rest muss angepasst werden, notfalls mit neuen Nichtterminalen. Dadurch erhalten wir eine Grammatik G' in CNF mit $\mathcal{L}(G') = \mathcal{L}(G_1)$.

$$G' : \quad S \rightarrow SE \mid CC \mid AF \mid BB \quad A \rightarrow SE \mid CC \quad B \rightarrow DB \mid c \quad C \rightarrow c \quad D \rightarrow d \quad E \rightarrow CC \quad F \rightarrow BB$$

Greibach-Normalform, Schritt 1

Für die GNF simuliert man die starke Linksableitung: für jedes $X \in N$ und $s \in \Sigma$ ist die Sprache $L_{X,s} = \{\alpha \in N^* \mid X \Rightarrow_{SL}^* s.\alpha\}$ regulär. Um nah an dem zu bleiben, das wir kennen, kann man aus der Grammatik die Transitionen von NFAs ablesen. Lediglich die Start- und Endzustände variieren je nach $X \in N$ und $s \in \Sigma$. Beachtet, dass das Alphabet hier $N = \{S, A, B, C, D, E, F\}$ ist.



z.B. für $X = S$ und $s = c$ ist $q_0 = S'$ und $Q_F = \{B', C'\}$.

In dieser Richtung beschreibt der Automat allerdings das Reverse der gesuchten Sprache.

Die Nebenprodukt-Sprachen lassen sich nun mit Arden's Lemma errechnen und tabellarisch auflisten.

rev($L_{X,s}$)	X	S	A	B	C	D	E	F
s	$Q_F \setminus q_0$	S'	A'	B'	C'	D'	E'	F'
c	$\{B', C'\}$	$(E+FE)^*(B+C+FC)$	$C + E(E+FE)^*(B+C+FC)$	ε	ε	\emptyset	C	B
d	$\{D'\}$	$(E+FE)^*BB$	$E(E+FE)^*BB$	B	\emptyset	ε	\emptyset	BB

Diese Sprachen muss man nur noch reversen, was mit regulären Ausdrücken ganz leicht geht.

$L_{X,s}$	X	S	A	B	C	D	E	F
s	$Q_F \setminus q_0$	S'	A'	B'	C'	D'	E'	F'
c	$\{B', C'\}$	$(B+C+CF)(E+EF)^*$	$C + (B+C+CF)(E+EF)^*E$	ε	ε	\emptyset	C	B
d	$\{D'\}$	$BB(E+EF)^*$	$BB(E+EF)^*E$	B	\emptyset	ε	\emptyset	BB

Alternative

Die links-linearen Grammatiken liefern für jedes Terminal direkt ein Gleichungssystem, das man mit dem *reversen* Ardens Lemma lösen kann, um reguläre Ausdrücke für alle $L_{X,s}$ zu bekommen.

Seien $L, U, V \subseteq \Sigma^*$ Sprachen mit $\varepsilon \notin U$. Nach Ardens Lemma gilt $L = UL \cup V$ gdw. $L = U^*V$. Das Reverse von Ardens Lemma lautet $L = LU \cup V$ gdw. $L = VU^*$ und gilt genauso.

$L_{X,S}$	S	A	B	C	D	E	F
c	$L_{S,c}E + L_{C,c}C + L_{A,c}F + L_{B,c}B$ $= (C+CF+B)(E+EF)^*$	$L_{S,c}E + L_{C,c}C$ $= C + (C+CF+B)(E+EF)^*E$	$L_{D,c}B + \varepsilon$ $= \varepsilon$	ε	\emptyset	$L_{C,c}C$ $= C$	$L_{B,c}B$ $= B$
d	$L_{S,d}E + L_{C,d}C + L_{A,d}F + L_{B,d}B$ $= BB(E+EF)^*$	$L_{S,d}E + L_{C,d}C$ $= BB(E+EF)^*E$	$L_{D,d}B + \emptyset$ $= B$	\emptyset	ε	$L_{C,d}C$ $= \emptyset$	$L_{B,d}B$ $= BB$

Greibach-Normalform, Schritt 2

Für alle Ausdrücke mit Kleene-Stern sollte man **rechtslineare** Grammatiken erzeugen. Viele der Sprachen teilen sich reguläre Teilausdrücke, was einem die Arbeit erleichtert. Hier ist es nur ein Ausdruck $(E + EF)^*$. Die Grammatik kann wieder ε -Produktionen enthalten, aber die werden wir später eliminieren.

$$H \rightarrow \varepsilon \mid EH \mid EFH$$

Jetzt kann man den Teilausdruck mit H ersetzen. Jetzt produzieren wir die GNF-Produktionen für die originalen Nichtterminale. Die Idee: man produziert vorne ein Terminal und hinten die Sprache der zugehörigen Nebenprodukte. Dazu helfen Umformungen der regulären Ausdrücke, wie $C + (B + C + CF)HE = C + BHE + CHE + CFHE$.

$$S \rightarrow cBH \mid cCH \mid cCFH \mid dBBH$$

$$A \rightarrow cC \mid cBHE \mid cCHE \mid cCFHE \mid dBBHE$$

$$B \rightarrow c \mid dB \quad C \rightarrow c \quad D \rightarrow d \quad E \rightarrow cC \quad F \rightarrow cB \mid dBB \quad H \rightarrow \underline{\varepsilon} \mid \underline{E}H \mid \underline{E}FH$$

Der letzte Schritt besteht nur noch aus Einsetzen und ε -Elimination:

$$S \rightarrow cB \mid cBH \mid cC \mid cCH \mid cCF \mid cCFH \mid dBB \mid dBBH$$

$$A \rightarrow cC \mid cBE \mid cBHE \mid cCE \mid cCHE \mid cCFE \mid cCFHE \mid dBBE \mid dBBHE$$

$$B \rightarrow c \mid dB \quad C \rightarrow c \quad D \rightarrow d \quad E \rightarrow cC \quad F \rightarrow cB \mid dBB \quad H \rightarrow cC \mid cCH \mid cCF \mid cCFH$$

Alternative Für alle Sprachen generiert man eigene rechts-lineare Grammatiken.

$G_{X,S}$	S	A	B	C	D	E	F
c	$T_{S,c} \rightarrow CX \mid CFX \mid BX$ $X \rightarrow \varepsilon \mid EX \mid EFX$	$T_{A,c} \rightarrow CY \mid CFY \mid BY$ $Y \rightarrow E \mid EY \mid EFY$	$T_{B,c} \rightarrow \varepsilon$	$T_{C,c} \rightarrow \varepsilon$		$T_{E,c} \rightarrow C$	$T_{F,c} \rightarrow B$
d	$T_{S,d} \rightarrow BBX$ $X \rightarrow \varepsilon \mid EX \mid EFX$	$T_{A,d} \rightarrow BBX$ $X \rightarrow \varepsilon \mid EX \mid EFX$	$T_{B,d} \rightarrow B$		$T_{D,d} \rightarrow \varepsilon$		$T_{F,d} \rightarrow BB$

Nun vereinigen wir alle Grammatiken und erzwingen das Terminal-Symbol in jede Produktion. Ab hier behandeln wir N wieder als Nichtterminale. Dabei beschränken wir uns auf die nützlichen Nichtterminale, also starten mit S und vermeiden $T_{D,c}$, $T_{C,d}$ und $T_{E,d}$.

Iteration 0: $S \rightarrow cT_{S,c} \mid dT_{S,d}$

Iteration 1: $T_{S,c} \rightarrow cT_{C,c}X \mid cT_{C,c}FX \mid cT_{B,c}X \mid dT_{B,d}X$ $T_{S,d} \rightarrow cT_{B,c}BX \mid dT_{B,d}BX$

Iteration 2: $T_{C,c} \rightarrow \varepsilon$ $X \rightarrow \varepsilon \mid cT_{E,c}X \mid cT_{E,c}FX$ $F \rightarrow cT_{F,c} \mid dT_{F,d}$ $T_{B,c} \rightarrow \varepsilon$
 $T_{B,d} \rightarrow cT_{B,c} \mid dT_{B,d}$ $B \rightarrow cT_{B,c} \mid dT_{B,d}$

Iteration 3: $T_{E,c} \rightarrow cT_{C,c}$ $T_{F,c} \rightarrow cT_{B,c} \mid dT_{B,d}$ $T_{F,d} \rightarrow cT_{B,c}B \mid dT_{B,d}B$

Zuletzt müssen nochmal die ε -Produktionen eliminiert werden. Betroffen sind $T_{C,c}$, X und $T_{B,c}$.
 Diese Grammatik G''' ist in GNF und erfüllt $\mathcal{L}(G''') = \mathcal{L}(G'') \setminus \{\varepsilon\} = \mathcal{L}(G) \setminus \{\varepsilon\}$.

$$\begin{aligned} S &\rightarrow cT_{S,c} \mid dT_{S,d} & T_{S,c} &\rightarrow c \mid cX \mid cF \mid cFX \mid dT_{B,d} \mid dT_{B,d}X & T_{S,d} &\rightarrow cB \mid cBX \mid dT_{B,d}B \mid dT_{B,d}BX \\ X &\rightarrow cT_{E,c} \mid cT_{E,c}X \mid cT_{E,c}F \mid cT_{E,c}FX & F &\rightarrow cT_{F,c} \mid dT_{F,d} & T_{B,d} &\rightarrow c \mid dT_{B,d} \\ B &\rightarrow c \mid dT_{B,d} & T_{E,c} &\rightarrow c & T_{F,c} &\rightarrow c \mid dT_{B,d} & T_{F,d} &\rightarrow cB \mid dT_{B,d}B \end{aligned}$$

Übungsaufgabe 9.9:

Betrachten Sie die Sprache $L = \{ ww \mid w \in \{a, b\}^* \}$. Zeigen Sie, dass L nicht kontextfrei ist.

Zur Erinnerung: Das Pumping-Lemma nach Bar-Hillel, Perles & Shamir gibt jeder kontextfreien Sprache L eine Pumping-Konstante p_L , sodass jedes längere Wort $z \in L$ innerhalb der Sprache mindestens eine Zerlegung $z = uvwxy$ hat, mit einem kurzen Infix $|vwx| \leq p_L$, echten zu pumpenden Elementen $|vw| \geq 1$ und ohne Möglichkeit, durch Pumpen die Sprache zu verlassen: $\forall i \in \mathcal{N} : uv^iwx^iy \in L$.

Beweis

Nehme an, L sei kontextfrei. Dann gibt es eine Pumping-Konstante $p_L \in \mathbb{N}$.

Betrachte das Wort $z = a^{p_L} b^{p_L} a^{p_L} b^{p_L}$. Es gilt $z \in L$.

Sei $z = uvwxy$ eine Zerlegung mit (1) $|vwx| \leq p_L$ und (2) $vx \neq \varepsilon$. (Nach dem Pumping-Lemma gibt es mindestens eine pumpbare Zerlegung.)

Wichtige Beobachtung: Entweder befindet sich das Infix vwx komplett in einer der beiden Hälften von z , oder es enthält einen Suffix der vorderen Hälfte und einen Präfix der hinteren Hälfte.

Im ersten Fall betrachte $z' = uv^iwx^iy$ mit $i = 0$ ($i \neq 1$ kann hier sogar beliebig gewählt werden).

Wegen (2) wird die betroffene Hälfte verändert und stimmt nicht länger mit der anderen Hälfte überein. Es folgt $z' \notin L$. (Detailliertere Rechnung für Infix in vorderer Hälfte: Es gilt $|vx|_a > 0$ oder $|vx|_b > 0$ und daher $z' = a^{p_L+(i-1)\cdot|vx|_a} b^{p_L+(i-1)\cdot|vx|_b} a^{p_L} b^{p_L} \notin L$.)

Anderenfalls beachte, dass der Infix wegen (1) weder ein vorderes a , noch ein hinteres b enthalten kann. Betrachte wieder $i = 0$ (oder ein beliebig anderes $i \neq 1$) und $z' = uv^0wx^0y$. Wegen (2) fehlt mindestens ein b der vorderen Hälfte oder ein a der hinteren Hälfte.

Da es keine weiteren Fälle mehr gibt, ist $z \in L$ nicht pumpbar.

Da dies aber dem Pumping-Lemma widerspricht, ist die Annahme falsch, also L nicht kontextfrei. □

Bemerkung: Tatsächlich sind diese z jeweils kürzeste Worte, die sich für diesen Beweis eignen.