

Poznámky k cvičeniu č. 8

Peter Kostolányi
15. novembra 2017

Regulárne jazyky

Ako bolo dokázané na prednáške, deterministické konečné automaty, nedeterministické konečné automaty a regulárne gramatiky sú rovnako silné modely opisujúce rovnakú triedu jazykov. Jazyky z tejto triedy nazývame *regulárne*.

Definícia 1. *Regulárny jazyk* je jazyk L , pre ktorý existuje deterministický konečný automat A taký, že $L(A) = L$. Triedu všetkých regulárnych jazykov označujeme symbolom \mathcal{R} .

Veta 1. *Nech L je jazyk. Nasledujúce tvrdenia sú ekvivalentné:*

- (i) *Jazyk L je regulárny.*
- (ii) *Existuje nedeterministický konečný automat A taký, že $L(A) = L$.*
- (iii) *Existuje regulárna gramatika G taká, že $L(G) = L$.*

Pumpovacia lema pre regulárne jazyky

Nech $L \in \mathcal{R}$ je ľubovoľný regulárny jazyk. V takom prípade *existuje* deterministický konečný automat $A = (K, \Sigma, \delta, q_0, F)$ taký, že $L(A) = L$. Ten má nejaký počet stavov $|K| =: p = q$.¹ Nech $w \in L$ je ľubovoľné slovo z jazyka L také, že $|w| \geq p$. Z Dirichletovho princípu vyplýva, že počas výpočtu automatu A na tomto slove sa niektorý jeho stav q_{op} musí „vyskytnúť“ aspoň dvakrát. *Existujú* teda slová $u, v \in \Sigma^*$ a $x \in \Sigma^+$ také, že $w = uxv$ a

$$(q_0, uxv) \vdash^* (q_{op}, xv) \vdash^+ (q_{op}, v) \vdash^* (q_{fin}, \varepsilon),$$

kde $q_{fin} \in F$ je akceptačný stav. Nech teraz $i \in \mathbb{N}$ je ľubovoľné prirodzené číslo. Ľahko možno vidieť, že existuje akceptačný výpočet automatu A na slove $ux^i v$: stačí namiesto jedného „cyklu“ $(q_{op}, x) \vdash^+ (q_{op}, \varepsilon)$ vykonať takýchto „cyklov“ niekoľko. Inými slovami: platí

$$(q_0, ux^i v) \vdash^* (q_{op}, x^i v) \vdash^+ (q_{op}, x^{i-1} v) \vdash^+ \dots \vdash^+ (q_{op}, v) \vdash^* (q_{fin}, \varepsilon).$$

V prípade, že $i = 0$, zodpovedá uvedený zápis „vynechaniu cyklu“. Je navyše zrejmé, že prvý opakovaný výskyt nejakého stavu musí prísť po najviac q krokoch výpočtu, takže možno pridať obmedzenie $|ux| \leq q$.

Pomocou takýchto jednoduchých úvah možno odvodiť pumpovaciu lemu pre regulárne jazyky, pričom správne poradie kvantifikátorov je dané poradím slov, ktoré sme zvýrazňovali italicou.

Veta 2. *Nech $L \in \mathcal{R}$ je regulárny jazyk. Potom existujú $p, q \in \mathbb{N}$ také, že pre všetky $w \in L$, $|w| \geq p$, existujú slová $u, x, v \in \Sigma_L^*$ také, že platí:*

- (i) $w = uxv$,
- (ii) $|ux| \leq q$,
- (iii) $|x| \geq 1$,
- (iv) $\forall i \in \mathbb{N} : ux^i v \in L$.

Je odporúčané pumpovacej leme skutočne porozumieť a namiesto učenia sa jej naspamäť ju radšej vždy „na počkanie“ odvodiť. Priestor na chyby (predovšetkým v poradí kvantifikátorov) je v takom prípade omnoho menší.

¹V pumpovacej leme sa táto hodnota zvykne označovať p resp. q . Ide tu o tradičné označenie, ktoré občas môže narobiť jemné problémy so zaužívanými konvenciami označovania stavov.

Dokazovanie negatívnych výsledkov o regularite jazykov

Keďže je pumpovacia lema sformulovaná ako tvrdenie platné pre každý regulárny jazyk, platnosť podmienok z nej vyplývajúcich je pre jazyk L *nutnou podmienkou* jeho regularity. Ak teda nejaký jazyk nespĺňa podmienky vyplývajúce z pumpovacej lemy, nemôže byť regulárny. Táto skutočnosť je základom jednej z najefektívnejších metód dokazovania negatívnych výsledkov o regularite jazykov, ktorú v nasledujúcom demonštrujeme na príklade jazyka všetkých palindrómov nad abecedou $\{a, b\}$, o ktorom je intuitívne zrejmé, že nie je regulárny.

Úloha 1. Dokážte, že jazyk $L = \{w \in \{a, b\}^* \mid w = w^R\}$ nie je regulárny.

Riešenie. Sporom, nech $L \in \mathcal{R}$. Jazyku L potom podľa pumpovacej lemy prislúchajú čísla $p, q \in \mathbb{N}$. Vezmime slovo $w = a^{p+q}ba^{p+q}$ – zjavne platí $w \in L$ a $|w| \geq p$. Preto existujú slová $u, x, v \in \{a, b\}^*$, pre ktoré sú splnené podmienky (i) až (iv) pumpovacej lemy.

Z podmienky (i) máme $w = uxv$. Z podmienok (ii) a (iii) vyplýva, že existujú $r, s \in \mathbb{N}$ také, že $s \geq 1$, $u = a^r$, $x = a^s$, a $v = a^{p+q-s-r}ba^{p+q}$.

Nakoniec, z podmienky (iv) pumpovacej lemy pre $i = 2$ vyplýva, že slovo

$$ux^2v = a^r a^{2s} a^{p+q-s-r} ba^{p+q} = a^{p+q+s} ba^{p+q}$$

patrí do jazyka L . To je ale spor, pretože $s \geq 1$. □

Pri nasledujúcej „písomkovej“ úlohe uvádzame okrem jej správneho riešenia aj nesprávne riešenie, ktorého variácie sa vyskytovali pomerne často.

Úloha 2. Zistite, či je jazyk $L = \{a^{2^n} \mid n \in \mathbb{N}\}$ regulárny. Svoje tvrdenie dokážte.

Nesprávne riešenie. Dokážeme, že jazyk L nie je regulárny. Sporom, nech $L \in \mathcal{R}$. Nech $p, q \in \mathbb{N}$ sú konštanty zodpovedajúce jazyku L podľa pumpovacej lemy. Bez ujmy na všeobecnosti môžeme predpokladať, že $p + q \geq 1$. Vezmime slovo $w = a^{2^{p+q}}$. Potom $w = uxv$, kde $u = a$, $x = a$ a $v = a^{2^{p+q}-2}$. Nech $i = 2$. Potom z podmienky (iv) pumpovacej lemy vyplýva $ux^2v = a^{2^{p+q}+1} \in L$, čo je spor, pretože $2^{p+q} + 1$ nemôže byť mocninou čísla 2.

Toto riešenie je **chybné**, pretože pumpovacia lema nám nedovoľuje zvoliť si slová u, x, v úplne ľubovoľne. Jediné, čo nám dovoľuje o týchto slovách predpokladať, sú podmienky (i) až (iii). □

Správne riešenie. Dokážeme, že jazyk L nie je regulárny. Sporom, nech $L \in \mathcal{R}$. Nech $p, q \in \mathbb{N}$ sú konštanty zodpovedajúce jazyku L podľa pumpovacej lemy. Vezmime teraz ľubovoľné slovo $w = a^{2^m}$ také, že $2^m > p + q$ – očividne $w \in L$ a $|w| \geq p$. Potom existujú slová u, x, v , pre ktoré sú splnené podmienky (i) až (iv) pumpovacej lemy.

Z podmienky (i) máme $w = uxv$. Z podmienok (ii) a (iii) vyplýva, že existujú čísla $r, s \in \mathbb{N}$ také, že $s \geq 1$, $r + s \leq q$, $u = a^r$, $x = a^s$ a $v = a^{2^m-r-s}$. Z podmienky (iv) pumpovacej lemy potom vyplýva $ux^2v = a^{2^m+s} \in L$. Keďže ale $s \geq 1$ a $s \leq r + s \leq q < 2^m$, platí $2^m < 2^m + s < 2^{m+1}$, a teda $2^m + s$ nie je mocnina dvoch, čo je spor. □

Poznámka 1. Vyvarovať sa chýb podobných tej vyššie je možné len pri správnom pochopení toho, čo sa pri dôkazoch s použitím pumpovacej lemy deje.

Typický takýto dôkaz je dôkazom sporom – za účelom sporu predpokladáme, že jazyk L , o ktorom chceme ukázať, že nie je regulárny, regulárny je. Pumpovacia lema je zárukou, že za tohto predpokladu platí pre L určité tvrdenie. K sporu chceme prísť tak, že dokážeme negáciu tohto tvrdenia – teda, že *pre všetky* $p, q \in \mathbb{N}$ *existuje* $w \in L$ s $|w| \geq p$ také, že *pre žiadne* $u, x, v \in \Sigma_L^*$ nemôže súčasne platiť (i) až (iv).

To znamená, že kým s konštantami p, q musíme pracovať *vo všeobecnosti*, slovo w si môžeme zvoliť ako *ľubovoľné* slovo z jazyka L dĺžky aspoň p . Slová u, x, v ale opäť musíme uvažovať vo všeobecnosti – potrebujeme totiž ukázať, že pre žiadne prípustné u, x, v nemôžu byť súčasne splnené všetky podmienky (i) až (iv). To ale väčšinou dokazujeme tak, že predpokladáme platnosť podmienok (i) až (iii) a dokazujeme, že neplatí (iv). Slová u, x, v teda predsa len nemusíme uvažovať úplne ľubovoľne – môžeme predpokladať, že sú pre ne splnené podmienky (i) až (iii). Nič viac ale predpokladať nemôžeme.

Uzáverové vlastnosti triedy regulárnych jazykov

Trieda jazykov \mathcal{L} je uzavretá na nejakú k -árnu operáciu Op , ak $Op(L_1, \dots, L_k) \in \mathcal{L}$ kedykoľvek $L_1, \dots, L_k \in \mathcal{L}$. Teda napríklad trieda regulárnych jazykov \mathcal{R} je uzavretá na zjednotenie, pretože pre všetky $L_1, L_2 \in \mathcal{R}$ platí $L_1 \cup L_2 \in \mathcal{R}$.

Dokázať uzavretosť triedy regulárnych jazykov na k -árnu operáciu operáciu Op teda znamená pre všetky regulárne jazyky L_1, \dots, L_k dokázať, že aj jazyk $Op(L_1, \dots, L_k)$ je regulárny. Regulárnosť jazyka $Op(L_1, \dots, L_k)$ sa dá dokázať napríklad všeobecnou konštrukciou DKA, NKA alebo regulárnej gramatiky na základe DKA, NKA alebo regulárnych gramatík, ktorých existenciu predpokladáme pre jazyky L_1, \dots, L_k . Vyvrátiť uzavretosť triedy \mathcal{R} na operáciu Op naopak znamená nájsť konkrétny príklad jazykov $L_1, \dots, L_k \in \mathcal{R}$ takých, že $Op(L_1, \dots, L_k) \notin \mathcal{R}$.

Úloha 3. Zistite, či je trieda \mathcal{R} uzavretá na unárnu operáciu *rotácie*, definovanú pre všetky jazyky L nasledovne:

$$\text{rot}(L) = \{vu \mid u, v \in \Sigma_L^*; uv \in L\}.$$

Svoje tvrdenie dokážte.

Riešenie. Dokážeme, že trieda \mathcal{R} je uzavretá na rotáciu. Nech $L \in \mathcal{R}$ je regulárny jazyk. Potom existuje deterministický konečný automat A taký, že $L(A) = L$. Zostrojíme nedeterministický konečný automat A' taký, že $L(A') = \text{rot}(L)$.

Automat A' dostane vstup w , ktorý má akceptovať v prípade, že existujú slová u, v , pre ktoré platí $w = vu$ a zároveň $uv \in L$. Ak $uv \in L$, musí existovať akceptačný výpočet automatu A na slove uv – tento výpočet bude „základom“ pre výpočet automatu A' . Automat A' teda najprv „nedeterministicky uhádne“ stav q , v ktorom automat A dočíta slovo u – správnosť tohto „tipu“ overí na konci výpočtu. Následne spustí simuláciu automatu A na vstupe w – ktoré má v prípade akceptácie zodpovedať slovu vu – so začiatkom simulácie v stave q . Automat A' bude simulovať automat A , až kým sa „nedeterministicky rozhodne“, že prečítal slovo v .

Ak táto simulácia skončila v neakceptačnom stave automatu A , buď na začiatku nešlo o správny „nedeterministický tip“ stavu q , alebo automat A slovo uv neakceptuje. V oboch prípadoch automat A' svoj vstup zamietne. Ak simulácia naopak skončila v akceptačnom stave, automat A' overí svoj „nedeterministický tip“ stavu q . To znamená, že na zvyšku svojho vstupu – ten má zodpovedať slovu u – spustí simuláciu automatu A so začiatkom simulácie v stave q_0 a overí, či po jeho dočítaní bude automat A naozaj v stave q . Ak áno, automat A' svoj vstup akceptuje.

Nech teda $A = (K, \Sigma, \delta, q_0, F)$. Potom $A' = (K', \Sigma', \delta', q'_0, F')$, kde $K' = \{q'_0\} \cup K \times \{1, 2\} \times K$, $\Sigma' = \Sigma$, pre prechodovú funkciu δ' platí

$$\begin{aligned} \delta'(q_0, \varepsilon) &= \{(q, 1, q) \mid q \in K\}, \\ \forall p, q \in K \forall c \in \Sigma : \delta'((p, 1, q), c) &= \{(\delta(p, c), 1, q)\}, \\ \forall p \in F \forall q \in K : \delta'((p, 1, q), \varepsilon) &= \{(q_0, 2, q)\}, \\ \forall p, q \in K \forall c \in \Sigma : \delta'((p, 2, q), c) &= \{(\delta(p, c), 2, q)\} \end{aligned}$$

(ostatné výstupy prechodovej funkcie sú prázdne množiny) a množina akceptačných stavov F' je

$$F' = \{(q, 2, q) \mid q \in K\}.$$

Dôkaz správnosti tejto konštrukcie robiť nebudeme. □

Úloha 4. Zistite, či je trieda \mathcal{R} uzavretá na (vymyslenú) binárnu operáciu „zdvojenej“ iterácie, definovanú pre všetky jazyky L_1, L_2 nasledovne:

$$2\text{-it}(L_1, L_2) = \bigcup_{i=0}^{\infty} (L_1^i \cdot L_2^i).$$

Svoje tvrdenie dokážte.

Riešenie. Dokážeme, že trieda \mathcal{R} nie je uzavretá na túto operáciu. Uvažujme napríklad regulárne jazyky $L_1 = \{a\}$ a $L_2 = \{b\}$. Potom zrejme $2\text{-it}(L_1, L_2) = \{a^n b^n \mid n \in \mathbb{N}\}$, čo je jazyk, o ktorom vieme, že nie je regulárny. □