

# Poznámky k cvičeniu č. 7

Peter Kostolányi

2. novembra 2016

## 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  $|K| =: p = q$ .<sup>1</sup> 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.

<sup>1</sup>V 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  $s \geq 1$ .  $\square$

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. 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).  $\square$

*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.  $\square$

*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  $\delta'$  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. □