

# Cvičenie č. 1

## Formálne jazyky a operácie na nich

Peter Kostolányi

21. septembra 2022

### Označenia

- Symbolom  $\mathbb{N}$  označujeme množinu všetkých prirodzených čísel *s nulou*, t.j.  $\mathbb{N} = \{0, 1, 2, \dots\}$ .
- Pre každé  $n \in \mathbb{N}$  označujeme symbolom  $[n]$  množinu  $[n] = \{1, \dots, n\}$ .
- Symboly  $\subseteq, \supseteq$  označujú reláciu *neostrej* inklúzie medzi množinami.
- Symboly  $\subsetneq, \supsetneq$  označujú *ostrú* množinovú inklúziu.
- Symboly  $\not\subseteq, \not\supseteq$  označujú *komplement neostrej* inklúzie. Pre množiny  $X, Y$  je teda  $X \not\subseteq Y$  práve vtedy, keď neplatí  $X \subseteq Y$ .
- Symboly  $\subset, \supset$  *nebudeme používať*. V literatúre môžu v závislosti od autora a oblasti označovať ako ostré, tak aj neostré inklúzie.
- *Rozdiel množín*  $X$  a  $Y$  na tomto predmete zapisujeme ako  $X - Y$ .
- *Komplement* – čiže doplnok – množiny  $X$  v rámci daného univerza označujeme  $X^C$ .
- *Potenčnú množinu* – čiže množinu všetkých podmnožín – množiny  $X$  označujeme  $2^X$ .

### 1 Slová a operácie na slovách

**Abeceda** je ľubovoľná neprázdna konečná množina. Jej prvky, ktorými môžu byť ľubovoľné objekty, nazývame *symboly* (*znaky*) alebo *písmená*. Symboly tak definujeme výhradne vo vzťahu k abecede – ak nie je daná abeceda, nemá zmysel ani pojem symbolu.

**Slovo** nad abecedou  $\Sigma$  je *konečná* postupnosť symbolov z abecedy  $\Sigma$ . Pri zápise takýchto postupností nepoužívame čiarky ani zátvorky a namiesto  $(a_1, a_2, \dots, a_n)$  píšeme iba  $a_1 a_2 \dots a_n$ . Príkladom slova nad dvojprvkovou abecedou  $\{a, b\}$  tak môže byť napríklad  $w = ababb$ .

**Prázdne slovo** nad abecedou  $\Sigma$  – špeciálny prípad slova – je prázdna postupnosť prvkov abecedy  $\Sigma$ . V rámci tohto predmetu budeme prázdne slovo vždy označovať  $\varepsilon$ . V literatúre možno natrafiť aj na iné označenia, napríklad  $\lambda$ ,  $1$ ,  $1_{\Sigma^*}$  alebo  $e$ .

Ak pre dvojicu abecied  $\Sigma, \Gamma$  platí  $\Sigma \subseteq \Gamma$ , považujeme každé slovo nad abecedou  $\Sigma$  súčasne aj za slovo nad abecedou  $\Gamma$ .<sup>1</sup> To nám napríklad umožňuje hovoriť len o slove  $abab$  bez upresnenia, či ho chápeme ako slovo nad abecedou  $\{a, b\}$  alebo, povedzme, ako slovo nad abecedou  $\{a, b, c\}$ . Podobne pre nás existuje iba jedno prázdne slovo  $\varepsilon$ , ktoré považujeme za slovo *nad ľubovoľnou abecedou*.

*Symboly abecedy  $\Sigma$  a jednopísmenové slová nad  $\Sigma$  stotožňujeme* – to je v skutočnosti dané už naším spôsobom zápisu slov, v ktorom napríklad symbol  $a$  a slovo  $a$  nemožno odlíšiť.

**Poznámka 1.** Častou chybou u študentov býva zahrnutie prázdneho slova  $\varepsilon$  do abecedy. Treba si uvedomiť, že  $\varepsilon$  slúži iba ako naše označenie pre prázdnu *postupnosť* symbolov z abecedy, ktorá sama o sebe *symbolom nie je*, a teda *nie je ani prvkom abecedy*. Zdrojom tohto nedorozumenia je drobný nesúlad medzi pojmom „symbol“ v zmysle definovanom vyššie a pojmom „symbol“ používaným v bežnej reči, ktorému sa ani v nasledujúcom nevyhneme.

<sup>1</sup>Každú postupnosť prvkov  $\Sigma$  totiž v takom prípade bežne považujeme aj za postupnosť prvkov  $\Gamma$  – napriek tomu, že sa obe postupnosti líšia v koobore.

**Dĺžka slova**  $w$ , označovaná  $|w|$ , je definovaná ako dĺžka príslušnej postupnosti znakov. Ak teda  $w = a_1 a_2 \dots a_n$ , kde  $a_1, a_2, \dots, a_n$  sú symboly<sup>2</sup> z nejakej abecedy  $\Sigma$ , je  $|w| = n$ .

Okamžite vidieť, že pre všetky slová  $w$  je  $|w| \geq 0$ , pričom  $|w| = 0$  práve vtedy, keď  $w = \varepsilon$ .

**Počet výskytov symbolu  $c$  v slove  $w$**  označujeme  $\#_c(w)$ ; v literatúre sa možno stretnúť aj s notáciou  $|w|_c$ . *Formálne*: pre každú abecedu  $\Sigma$ , všetky slová  $w = a_1 a_2 \dots a_n$  s  $a_1, a_2, \dots, a_n \in \Sigma$  a ľubovoľné  $c \in \Sigma$  kladieme  $\#_c(w) = |\{i \in [n] \mid a_i = c\}|$ .

**Množinu všetkých slov** – alebo v terminológii, ktorú zavedieme neskôr: **jazyk všetkých slov** – nad abecedou  $\Sigma$  označujeme  $\Sigma^*$ . Množinu všetkých *neprázdnych* slov nad  $\Sigma$  – slovo je neprázdne, ak nie je prázdne – označujeme  $\Sigma^+$  a množinu všetkých slov nad  $\Sigma$  dĺžky  $k \in \mathbb{N}$  označujeme  $\Sigma^k$ . Neskôr uvidíme, že abeceda je špeciálnym prípadom jazyka a uvedené označenia možno chápať aj ako aplikácie určitých operácií na jazykoch.

Môžeme teraz definovať prvú, asi najprirodzenejšiu a zďaleka najvýznamnejšiu spomedzi operácií na slovách, ktorou je ich *zreťazenie*.

**Zreťazenie** slov  $u = a_1 \dots a_n$  a  $v = b_1 \dots b_m$ , kde  $a_1, \dots, a_n$  a  $b_1, \dots, b_m$  sú písmená, je slovo  $u \cdot v = a_1 \dots a_n b_1 \dots b_m$ . Namiesto  $u \cdot v$  často píšeme len  $uv$ .

Ak je  $u$  slovom nad abecedou  $\Sigma_1$  a  $v$  slovom nad abecedou  $\Sigma_2$ , je  $uv$  slovom nad abecedou  $\Sigma_1 \cup \Sigma_2$ . V prípade, že obidve slová  $u, v$  uvažujeme nad rovnakou abecedou  $\Sigma$ , je aj  $uv$  slovom nad tou istou abecedou. Zreťazenie je teda pre ľubovoľnú abecedu  $\Sigma$  *binárnou operáciou* na  $\Sigma^*$ . Ľahko možno nahliadnuť, že je táto operácia asociatívna a prázdne slovo  $\varepsilon$  je vzhľadom na ňu neutrálne. To možno vyjadriť konštatovaním, že  $(\Sigma^*, \cdot, \varepsilon)$  je *monoid*, čiže niečo ako „grupa bez inverzných prvkov“.

Pre všetky dvojice slov  $u, v$  ďalej zrejme  $|uv| = |u| + |v|$ .

**Mocnina slova** nad abecedou  $\Sigma$  je definovaná na základe operácie zreťazenia rovnako, ako býva zvykom pri ľubovoľnej multiplikatívnej operácii. Pre  $w \in \Sigma^*$  teda kladieme  $w^0 = \varepsilon$  a  $w^{n+1} = w^n w$  pre všetky  $n \in \mathbb{N}$ . Všimnime si, že nultá mocnina je definovaná prirodzeným spôsobom ako neutrálny prvok vzhľadom na operáciu zreťazenia, aj vďaka čomu pre všetky  $m, n \in \mathbb{N}$  platí  $w^m w^n = w^{m+n}$ .

**Reverz** alebo **zrkadlový obraz** slova  $w$  nad abecedou  $\Sigma$  definujeme ako slovo  $w^R$  získané zo slova  $w$  jeho „čítaním sprava doľava“. Ak je teda  $w = a_1 a_2 \dots a_n$  pre  $a_1, a_2, \dots, a_n \in \Sigma$ , je reverzom slova  $w$  slovo  $w^R = a_n a_{n-1} \dots a_1$ . Napríklad  $(ab)^R = ba$ ,  $(abba)^R = abba$ ,  $(aababb)^R = bbabaa$  a  $\varepsilon^R = \varepsilon$ . Slová  $w$  spĺňajúce  $w = w^R$ , napríklad  $abba$  alebo  $\varepsilon$ , nazývame **palindrómy**.

Operácie mocniny a reverzu majú, pomerne prirodzene, vyššiu precedenciu, než operácia zreťazenia. Napríklad teda  $aab^2 = aabb$  a  $aab^R = aab$ , kým  $(aab)^2 = aabaab$  a  $(aab)^R = baa$ .

**Podslovo** – alebo **faktor** – slova  $w = a_1 a_2 \dots a_n$  nad abecedou  $\Sigma$  je ľubovoľná *súvislá* podpostupnosť postupnosti  $a_1 a_2 \dots a_n$ . Presnejšie ide o slovo  $x \in \Sigma^*$  také, že pre nejaké  $u, v \in \Sigma^*$  je  $uxv = w$ . Všimnime si, že *prázdne slovo je podslovom ľubovoľného slova*.

**Prefix** slova  $w$  je podslovo „začínajúce na začiatku slova  $w$ “ a **suffix** je podslovo „končiace na konci slova  $w$ “. To exaktne sformulujeme tak, že *prefixom* slova  $w \in \Sigma^*$  nazveme slovo  $x$  také, že pre nejaké  $v \in \Sigma^*$  je  $xv = w$  a *suffixom* slova  $w \in \Sigma^*$  slovo  $x$  také, že pre nejaké  $u \in \Sigma^*$  je  $ux = w$ . *Prázdne slovo je tak prefixom aj suffixom ľubovoľného slova*.

<sup>2</sup>Takýto predpoklad znamená, že  $a_1, \dots, a_n$  nadobúdajú hodnoty v  $\Sigma$ , pričom tieto hodnoty *nemusia* byť po dvoch rôzne. Ak napríklad  $\Sigma = \{a, b\}$ , tak pre  $i = 1, \dots, n$  môže byť  $a_i = a$  alebo  $a_i = b$ .

Všetky podslová slova *abb* teda napríklad sú  $\varepsilon$ ,  $a$ ,  $b$ ,  $ab$ ,  $bb$  a  $abb$ . Prefixmi tohto slova sú  $\varepsilon$ ,  $a$ ,  $ab$  a  $abb$  a jeho sufixmi sú slová  $\varepsilon$ ,  $b$ ,  $bb$  a  $abb$ .

**Poznámka 2.** Niektoré z uvedených definícií nie sú v literatúre úplne ustálené. Tak je tomu napríklad pri pojme abecedy, kde sa občas možno stretnúť aj s definíciami nevyžadujúcimi jej konečnosť alebo neprázdnosť. U niektorých autorov sa tiež možno stretnúť s pojmom „podslovo“ chápaným ako ľubovoľná (nie nutne súvislá) podpostupnosť, pričom pre súvislú podpostupnosť sa používa výhradne termín „faktor“. Podobne aj viaceré ďalšie pojmy, s ktorými na tomto predmete budeme pracovať neskôr, bývajú často definované v rôznych – väčšinou v určitom zmysle ekvivalentných – obmenách, ktoré sú predovšetkým otázkou zamýšľaného použitia a v neposlednom rade aj vkusu autora.

V rámci tohto predmetu sa, prirodzene, budeme držať výhradne definícií z prednášky. Pri štúdiu literatúry je však nutné s podobnými drobnými rozdielmi v definíciách počítat.

## 2 Jazyky

**Jazyk** nad abecedou  $\Sigma$  je ľubovoľná množina slov nad abecedou  $\Sigma$ . To znamená, že ide o ľubovoľnú množinu  $L \subseteq \Sigma^*$ . Jazyk je *konečný*, ak ide o konečnú množinu; v opačnom prípade hovoríme o *nekonečnom* jazyku. Zaujímavé pre nás budú predovšetkým nekonečné jazyky.

**Množina všetkých jazykov** nad abecedou  $\Sigma$  je evidentne daná ako  $2^{\Sigma^*}$ .

*Príklad 1.* Uvedme zopár príkladov jazykov:

- *Prázdny jazyk* je z definície prázdna množina  $\emptyset$  neobsahujúca žiadne slovo. Je dôležité si uvedomiť, že ide o *iný objekt*, než jazyk  $\{\varepsilon\}$ , ktorý obsahuje práve jedno – prázdne – slovo.
- $L_1 = \{\varepsilon, a, abb, baa\}$  je konečný jazyk nad abecedou  $\{a, b\}$ .
- $L_2 = \{a, b\}^*$  je jazyk všetkých slov nad abecedou  $\{a, b\}$ .
- $L_3 = \{w \in \{a, b\}^* \mid w = w^R\}$  je jazyk všetkých palindrómov nad abecedou  $\{a, b\}$ .
- $L_4 = \{w \in \{a, b\}^* \mid \#_a(w) = \#_b(w)\}$  je jazyk tých slov nad abecedou  $\{a, b\}$ , ktoré obsahujú rovnaký počet výskytov oboch symbolov.
- $L_5 = \{a^n b^n \mid n \in \mathbb{N}\}$  je ďalším príkladom jazyka nad abecedou  $\{a, b\}$ .
- Každá abeceda je konečný jazyk nad sebou samým.
- Množina všetkých dekadických zápisov prvočísel je jazykom nad abecedou  $\{0, 1, \dots, 9\}$ .
- Všetky korektné programy v jazyku Java tvoria jazyk nad „abecedou Unicode“.
- Všetky PDF dokumenty, chápané ako binárne súbory, tvoria jazyk nad abecedou  $\{0, 1\}$ .

Podobne ako pri slovách možno každý jazyk nad abecedou  $\Sigma$  chápať aj ako jazyk nad ľubovoľnou abecedou  $\Gamma$  takou, že  $\Gamma \supseteq \Sigma$ ; napríklad jazyk  $L_1$  z uvedeného príkladu môžeme súčasne chápať aj ako jazyk nad abecedou  $\{a, b, c\}$ . To motivuje nasledujúce označenie.

**Abecedu**  $\Sigma_L$  definujeme pre každý jazyk  $L$  rôznyi od  $\emptyset$  a  $\{\varepsilon\}$  ako *najmenšiu abecedu*  $\Sigma$  takú, že  $L$  je jazykom nad  $\Sigma$ . Pre neprázdne slovo  $w$  píšeme namiesto  $\Sigma_{\{w\}}$  len  $\Sigma_w$  – ide potom o množinu všetkých písmen vyskytujúcich sa v slove  $w$ . Abecedy  $\Sigma_\emptyset$  a  $\Sigma_\varepsilon$  nemožno definovať, pretože abeceda musí byť podľa našej definície neprázdna. V literatúre sa namiesto  $\Sigma_L$  a  $\Sigma_w$  často používajú označenia  $\text{alph}(L)$  resp.  $\text{alph}(w)$ , ktoré sú však občas používané aj v inom význame.

**Poznámka 3.** Skutočnosť, že slovo  $w$  obsahuje aspoň jeden výskyt písmena  $c$ , teda správne vyjadríme ako  $c \in \Sigma_w$ . Zápis  $c \in w$ , často používaný niektorými študentmi, je *vonkoncom nekorektný*.

### 3 Operácie na jazykoch

**Množinové operácie.** Keďže je jazyk definovaný ako množina, má zmysel zaoberať sa množinovými operáciami aplikovanými na jazyky. Možno teda uvažovať predovšetkým:

- Zjednotenie  $L_1 \cup L_2$ , prienik  $L_1 \cap L_2$  a rozdiel  $L_1 - L_2$  jazykov  $L_1$  a  $L_2$ .<sup>3</sup>
- Komplement  $L^C$  jazyka  $L$ . Podobne ako aj inde v matematike je komplement nutné uvažovať v rámci nejakého univerza. To v teórii formálnych jazykov znamená, že pri práci s komplementom je, prísne vzaté, vždy potrebné uviesť abecedu  $\Sigma$ , nad ktorou komplementovaný jazyk  $L$  uvažujeme – potom je  $L^C = \Sigma^* - L$ . Použitie notácie  $L^C$  bez uvedenia univerza v literatúre väčšinou znamená, že univerzum je pre dané účely buď nepodstatné, alebo zrejmé z kontextu.

**Zreťazenie jazykov**  $L_1$  a  $L_2$  je jazyk  $L_1 \cdot L_2 = \{uv \mid u \in L_1; v \in L_2\}$ . Ide teda o jazyk zretezení  $uv$  všetkých dvojíc slov  $u, v$  takých, že  $u \in L_1$  a  $v \in L_2$ .

*Príklad 2.* Uvažujme konečné jazyky  $L_1 = \{\varepsilon, a, ab, abb\}$  a  $L_2 = \{b, ab, bb\}$ . Jazyk  $L_1 \cdot L_2$  potom možno získať nasledujúcim postupom:

- Zretezenia jednotlivých dvojíc slov zapíšeme do tabuľky.

	$b$	$ab$	$bb$
$\varepsilon$	$b$	$ab$	$bb$
$a$	$ab$	$aab$	$abb$
$ab$	$abb$	$abab$	$abbb$
$abb$	$abbb$	$abbab$	$abbbb$

- Po odstránení duplikátov dostávame  $L_1 \cdot L_2 = \{b, ab, bb, aab, abb, abab, abbb, abbab, abbbb\}$ .

Zretezenie má vyššiu precedenciu ako zjednotenie a prienik – napríklad výraz  $L_1 \cup L_2 \cdot L_3$  teda treba čítať ako  $L_1 \cup (L_2 \cdot L_3)$ .

**Poznámka 4.** Na množine všetkých jazykov nad danou abecedou  $\Sigma$  zohráva zjednotenie úlohu aditívnej operácie a zretezenie zohráva úlohu multiplikatívnej operácie. Prázdny jazyk  $\emptyset$  je evidentne neutrálny vzhľadom na zjednotenie – pre všetky jazyky  $L$  je  $L \cup \emptyset = \emptyset \cup L = L$  – a agresívny vzhľadom na zretezenie – pre všetky  $L$  je  $L \cdot \emptyset = \emptyset \cdot L = \emptyset$ . Jazyk  $\{\varepsilon\}$  je naopak neutrálny vzhľadom na zretezenie – pre všetky  $L$  je  $L \cdot \{\varepsilon\} = \{\varepsilon\} \cdot L = L$ . Tieto dva jazyky sú teda *fundamentálne* odlišné: kým prázdny jazyk  $\emptyset$  zohráva úlohu nuly, jazyk  $\{\varepsilon\}$  zohráva úlohu jednotky.

**Mocnina jazyka**  $L$  je, podobne ako mocnina slova, definovaná prirodzeným indukčným predpisom:  $L^0 = \{\varepsilon\}$  a  $L^{n+1} = L^n \cdot L$  pre všetky  $n \in \mathbb{N}$ . Dôležitá je nasledujúca charakterizácia jazyka  $L^n$ , podľa ktorej tento jazyk pozostáva z práve všetkých zretezení  $n$ -tíc slov z jazyka  $L$ .

**Tvrdenie 1.** *Nech  $L$  je jazyk a  $n \in \mathbb{N}$ . Potom  $L^n = \{w_1 \dots w_n \mid w_1, \dots, w_n \in L\}$ .*

*Dôkaz.* Indukciou vzhľadom na  $n$ .

- Pre  $n = 0$  je z definície  $L^0 = \{\varepsilon\} = \{w_1 \dots w_0 \mid w_1, \dots, w_0 \in L\}$ .
- Predpokladajme platnosť tvrdenia pre  $n = k$ . Dokážeme jeho platnosť aj pre  $n = k + 1$ . Skutočne:

$$L^{k+1} = L^k \cdot L = \{w_1 \dots w_k \mid w_1, \dots, w_k \in L\} \cdot L = \{w_1 \dots w_{k+1} \mid w_1, \dots, w_{k+1} \in L\},$$

kde prvá rovnosť je z definície mocniny jazyka, druhá z indukčného predpokladu a posledná z definície zretezenia. □

<sup>3</sup>Pri množinovom rozdiel má uprednostňovanie notácie  $L_1 - L_2$  pred  $L_1 \setminus L_2$  korene u tých autorov, ktorí druhé z označení používajú pre tzv. ľavý kvocient – čo je operácia, s ktorou sa v rámci týchto cvičení stretne neskôr. Iná skupina autorov zas ľavý kvocient označuje ako  $L_1^{-1}L_2$ ; pre množinový rozdiel je potom možné „bezpečne“ používať zvyčajný operátor „\“.

**Poznámka 5.** Častou chybou u študentov býva zamieňanie si  $n$ -tej mocniny jazyka  $L$  s jazykom  $n$ -tých mocnín slov z jazyka  $L$ . Čitateľ určite ľahko dokáže, že vo všeobecnosti  $L^n \neq \{w^n \mid w \in L\}$ .

**Poznámka 6.** Bezprostredne z definície mocniny jazyka vyplýva aj rovnosť  $\emptyset^0 = \{\varepsilon\}$ . Ide tu o určitú analógiu (dobře odôvodnenej) konvencie  $0^0 = 1$ , ktorá sa používa v niektorých oblastiach matematiky.

**Iterácia** – alebo **(Kleeneho) uzáver**, či hovorovo **(Kleeneho) hviezdička** – jazyka  $L$  je jazyk

$$L^* = \bigcup_{k=0}^{\infty} L^k$$

**Kladná iterácia** – alebo **kladný (Kleeneho) uzáver**, či hovorovo **(Kleeneho) plus** – jazyka  $L$  je jazyk

$$L^+ = \bigcup_{k=1}^{\infty} L^k.$$

Nasledujúca dôležitá charakterizácia jazykov  $L^*$  a  $L^+$  je dôsledkom tvrdenia 1.

**Tvrdenie 2.** Uvažujme ľubovoľný jazyk  $L$ . Potom je  $L^* = \{w_1 \dots w_k \mid k \in \mathbb{N}; w_1, \dots, w_k \in L\}$  a  $L^+ = \{w_1 \dots w_k \mid k \in \mathbb{N} - \{0\}; w_1, \dots, w_k \in L\}$ .

*Dôkaz.* Rozpísaním jazykov  $L^k$  podľa tvrdenia 1 dostávame pre iteráciu

$$L^* = \bigcup_{k=0}^{\infty} L^k = \bigcup_{k=0}^{\infty} \{w_1 \dots w_k \mid w_1, \dots, w_k \in L\} = \{w_1 \dots w_k \mid k \in \mathbb{N}; w_1, \dots, w_k \in L\}$$

a pre kladnú iteráciu

$$L^+ = \bigcup_{k=1}^{\infty} L^k = \bigcup_{k=1}^{\infty} \{w_1 \dots w_k \mid w_1, \dots, w_k \in L\} = \{w_1 \dots w_k \mid k \in \mathbb{N} - \{0\}; w_1, \dots, w_k \in L\},$$

čo bolo treba dokázať. □

**Poznámka 7.** Nech  $\Sigma$  je abeceda. Z tvrdení 1 a 2 vyplýva konzistentnosť označení  $\Sigma^k$  (pre  $k \in \mathbb{N}$ ),  $\Sigma^*$  a  $\Sigma^+$  z oddielu 1 s operáciami mocniny, iterácie a kladnej iterácie jazyka.

**Reverz jazyka**  $L$  je jazyk  $L^R = \{w^R \mid w \in L\}$ . Platí teda napríklad  $\{\varepsilon, abb, bab\}^R = \{\varepsilon, bba, bab\}$ , či  $\{a^n b^n \mid n \in \mathbb{N}\}^R = \{b^n a^n \mid n \in \mathbb{N}\}$ .

Operácie mocniny, iterácie, kladnej iterácie a reverzu jazyka majú vyššiu precedenciu, než zretáženie. Napríklad teda  $L_1 \cdot L_2^* = L_1 \cdot (L_2^*)$  a podobne pre zvyšné spomenuté operácie.

**Niektoré notačné skratky.** Za účelom uľahčenia zápisu sa obyčajne používa konvencia, podľa ktorej slovo  $w$ , použité ako argument zretáženia s jazykom, iterácie, či kladnej iterácie, interpretujeme ako jednoprvkový jazyk  $\{w\}$ . Namiesto  $\{w\} \cdot L$  tak napríklad môžeme písať iba  $wL$ . Namiesto  $\{w\}^*$  a  $\{w\}^+$  píšeme obvykle iba  $w^*$  a  $w^+$  – treba si však uvedomiť, že použitím týchto operátorov získame *jazyk*. Napríklad teda  $a^*cb^* = \{a^m cb^n \mid m, n \in \mathbb{N}\}$ .

## 4 Riešené úlohy

Dokazovanie rovnosti  $L_1 = L_2$  dvoch jazykov je často najvýhodnejšie rozdeliť na dve časti a postupne dokázať obidve inklúzie  $L_1 \subseteq L_2$  a  $L_1 \supseteq L_2$ . Pri dokazovaní inklúzie  $L_1 \subseteq L_2$  potom obyčajne uvažujeme ľubovoľné slovo  $w \in L_1$  a snažíme sa ukázať, že toto slovo musí patriť aj do jazyka  $L_2$ ; pri inklúzii  $L_1 \supseteq L_2$  postupujeme opačne. (Takýto postup, hoci je spravidla najspoľahlivejší, samozrejme nemusí byť vždy najjednoduchší alebo najelegantnejší.)

**Úloha 1.** Nech  $\Sigma$  je ľubovoľná abeceda. Dokážte, že  $\Sigma \cdot \Sigma^* = \Sigma^+$ .

*Riešenie.* Dokážeme postupne obe inklúzie medzi jazykmi  $\Sigma \cdot \Sigma^*$  a  $\Sigma^+$ .

$\subseteq$ : Nech  $w \in \Sigma \cdot \Sigma^*$ . Potom  $w = av$ , kde  $a \in \Sigma \subseteq \Sigma^*$  a  $v \in \Sigma^*$ . V dôsledku toho  $w \in \Sigma^*$ . Keďže  $a \in \Sigma$ , je  $|w| = |av| \geq |a| = 1$ . Slovo  $w$  je teda neprázdne, takže musí patriť do  $\Sigma^+$ .

$\supseteq$ : Nech  $w \in \Sigma^+$ . Vďaka tvrdeniu 2 existuje  $k \in \mathbb{N} - \{0\}$  také, že  $w = a_1 a_2 \dots a_k$  pre nejaké  $a_1, a_2, \dots, a_k \in \Sigma$ . Z toho  $w = a_1 v$  pre  $a_1 \in \Sigma$  a  $v = a_2 \dots a_k \in \Sigma^*$ , takže  $w \in \Sigma \cdot \Sigma^*$ .  $\square$

**Úloha 2.** Nech  $L$  je ľubovoľný jazyk. Dokážte, že  $L \cdot L^* = L^+$ .

*Riešenie.* Dokážeme postupne obe inklúzie medzi jazykmi  $L \cdot L^*$  a  $L^+$ .

$\subseteq$ : Nech  $w \in L \cdot L^*$ . Potom  $w = uv$  pre nejaké  $u \in L$  a  $v \in L^*$ . Z tvrdenia 2 navyše  $v = v_1 \dots v_k$  pre nejaké  $k \in \mathbb{N}$  a  $v_1, \dots, v_k \in L$ . Preto je slovo  $w = uv_1 \dots v_k$  zretiazčením nenulového počtu slov  $u, v_1, \dots, v_k \in L$ , a teda  $w \in L^+$  podľa tvrdenia 2.

$\supseteq$ : Nech  $w \in L^+$ . Vďaka tvrdeniu 2 existuje  $k \in \mathbb{N} - \{0\}$  také, že  $w = w_1 w_2 \dots w_k$  pre nejaké  $w_1, w_2, \dots, w_k \in L$ . To znamená, že  $w = w_1 (w_2 \dots w_k)$ , kde  $w_1 \in L$  a  $w_2 \dots w_k \in L^*$  podľa tvrdenia 2. Preto  $w \in L \cdot L^*$ .  $\square$

**Úloha 3.** Uvažujme dvojicu jazykov

$$L_1 = \{w \in \{a, b\}^* \mid \#_a(w) \leq \#_b(w)\},$$

$$L_2 = \{w \in \{a, b\}^* \mid \#_a(w) \geq \#_b(w)\}.$$

Nájdite jazyk  $L_1 \cdot L_2$ .

*Riešenie.* Dokážeme, že  $L_1 \cdot L_2 = \{a, b\}^*$ .

$\subseteq$ : Nech  $w \in L_1 \cdot L_2$ . Potom  $w = uv$ , kde  $u \in L_1 \subseteq \{a, b\}^*$  a  $v \in L_2 \subseteq \{a, b\}^*$ . Preto aj  $w = uv \in \{a, b\}^*$ .

$\supseteq$ : Nech  $w \in \{a, b\}^*$ . Potom buď  $\#_a(w) \leq \#_b(w)$ , alebo  $\#_a(w) \geq \#_b(w)$ . Ak  $\#_a(w) \leq \#_b(w)$ , tak  $w = w\varepsilon$ , pričom  $w \in L_1$  a  $\varepsilon \in L_2$ . Ak  $\#_a(w) \geq \#_b(w)$ , tak  $w = \varepsilon w$ , pričom  $\varepsilon \in L_1$  a  $w \in L_2$ . V oboch prípadoch tak dostávame  $w \in L_1 \cdot L_2$ .  $\square$

**Úloha 4.** Uvažujme jazyk  $L = \{w \in \{a, b\}^* \mid |w| \geq 4\}$ . Nájdite jazyk  $L^*$ .

*Riešenie.* Dokážeme, že  $L^* = L \cup \{\varepsilon\}$ .

$\subseteq$ : Nech  $w \in L^*$ . Potom existuje  $k \in \mathbb{N}$  a slová  $w_1, \dots, w_k \in L$  tak, že  $w = w_1 \dots w_k$ . Ak  $k = 0$ , tak  $w = \varepsilon \in L \cup \{\varepsilon\}$ . Ak  $k > 0$ , tak  $|w| \geq |w_1| \geq 4$ , keďže  $w_1 \in L$ . Preto  $w \in L \subseteq L \cup \{\varepsilon\}$ .

$\supseteq$ : Nech  $w \in L \cup \{\varepsilon\}$ . Potom  $w \in L = L^1 \subseteq L^*$ , alebo  $w \in \{\varepsilon\} = L^0 \subseteq L^*$ .  $\square$

*Porovnať dvojicu jazykov  $L, L'$  znamená zistiť, či platia inklúzie  $L \subseteq L'$  a  $L \supseteq L'$ . Pri riešení úloh tohto typu je vždy potrebné overiť obidve inklúzie – nestačí sa teda napríklad uspokojiť s konštatovaním, že sa daná dvojica jazykov nemusí rovnať.*

Často pritom býva úlohou porovnať jazyky typu  $F(L_1, \dots, L_k)$  a  $G(L_1, \dots, L_k)$ , kde  $L_1, \dots, L_k$  sú nejaké (ľubovoľné) jazyky a  $F, G$  sú operácie na jazykoch (v nasledujúcich dvoch úlohách je  $k = 2$ ). V takom prípade je potrebné dvojicu jazykov  $F(L_1, \dots, L_k)$  a  $G(L_1, \dots, L_k)$  porovnať vo všeobecnosti – to znamená zistiť, či jednotlivé inklúzie platia, nech sú jazyky  $L_1, \dots, L_k$  zvolené akokoľvek. Na dôkaz niektorej z inklúzií teda nemožno o jazykoch  $L_1, \dots, L_k$  predpokladať nič špeciálne. Za účelom vyvrátenia inklúzie naopak stačí nájsť konkrétne jazyky  $L_1, \dots, L_k$ , pre ktoré inklúzia neplatí.

**Úloha 5.** Nech  $L_1, L_2$  sú jazyky. Porovnajte jazyky  $(L_1 \cup L_2)^*$  a  $L_1^* \cup L_2^*$ .

*Riešenie.* Dokážeme, že  $(L_1 \cup L_2)^* \supseteq L_1^* \cup L_2^*$ , pričom opačná inklúzia vo všeobecnosti neplatí.

$\not\subseteq$ : Nech  $L_1 = \{a\}$  a  $L_2 = \{b\}$ . Potom  $ab \in (L_1 \cup L_2)^*$ , ale  $ab \notin L_1^* \cup L_2^*$ .

$\supseteq$ : Nech  $w \in L_1^* \cup L_2^*$ . Potom buď  $w \in L_1^*$ , alebo  $w \in L_2^*$ .

Ak  $w \in L_1^*$ , podľa tvrdenia 2 existuje  $k \in \mathbb{N}$  a slová  $w_1, \dots, w_k \in L_1$  tak, že  $w = w_1 \dots w_k$ . Slová  $w_1, \dots, w_k$  sú súčasne aj v  $L_1 \cup L_2$ ; vďaka tvrdeniu 2 tak  $w = w_1 \dots w_k \in (L_1 \cup L_2)^*$ .

Podobne ak  $w \in L_2^*$ , tak  $w = w_1 \dots w_k$ , kde  $k \in \mathbb{N}$  a  $w_1, \dots, w_k \in L_2$ . Slová  $w_1, \dots, w_k$  sú zároveň aj v  $L_1 \cup L_2$ , a teda  $w = w_1 \dots w_k \in (L_1 \cup L_2)^*$ .  $\square$

**Úloha 6.** Nech  $L_1, L_2$  sú jazyky. Porovnajte jazyky  $(L_1 \cup L_2)^*$  a  $L_1^* \cdot (L_2 \cdot L_1^*)^*$ .

Než pristúpime k riešeniu tejto úlohy, pokúsme sa získať trochu intuície. Jazyk  $(L_1 \cup L_2)^*$  obsahuje zretáženia nejakého – prípadne aj nulového – počtu slov, ktoré sú vždy buď z  $L_1$  alebo z  $L_2$ . Jazyk  $L_1^* \cdot (L_2 \cdot L_1^*)^*$  tiež obsahuje takéto slová, ale zdanlivo požaduje trochu viac: zretáženie má začínať niekoľkými slovami z  $L_1$  a následne pokračovať niekoľkými „úsekmi“, kde každý z nich obsahuje najprv práve jedno slovo z  $L_2$  a za ním niekoľko slov z  $L_1$ ; „niekoľko“ tu vždy môže byť aj nula.

Istotne teda bude  $(L_1 \cup L_2)^* \supseteq L_1^* \cdot (L_2 \cdot L_1^*)^*$ . Platnosť opačnej inklúzie závisí od toho, či je každé zretáženie  $w_1 \dots w_k$  slov  $w_1, \dots, w_k$  z  $L_1$  alebo z  $L_2$  súčasne aj zretážením druhého uvedeného typu. Vyznačme ale v zretážení  $w_1 \dots w_k$  tie spomedzi slov  $w_1, \dots, w_k$ , ktoré patria do  $L_2$  a rozdelme ho na „úseky“ tak, aby každý z nich začínal označeným slovom a spolu s ním obsahoval aj všetky bezprostredne nasledujúce *neoznačené* slová (každý „úsek“ sa teda vždy bude končiť buď pred nasledujúcim označeným slovom, alebo na konci slova). Z tohto pohľadu už ľahko vidieť, že je naše zretáženie v skutočnosti aj zretážením druhého typu. Platí teda aj inklúzia  $(L_1 \cup L_2)^* \subseteq L_1^* \cdot (L_2 \cdot L_1^*)^*$  a vo výsledku tak budeme dokazovať rovnosť oboch jazykov. Samotné riešenie úlohy bude pozostávať z náležitej *formalizácie* uvedených pozorovaní.

*Riešenie.* Dokážeme, že  $(L_1 \cup L_2)^* = L_1^* \cdot (L_2 \cdot L_1^*)^*$ .

$\supseteq$ : Nech  $w \in L_1^* \cdot (L_2 \cdot L_1^*)^*$ . Z definície zretáženia jazykov je  $w = uv$ , kde  $u \in L_1^*$  a  $v \in (L_2 \cdot L_1^*)^*$ . Z tvrdenia 2 je  $u = u_1 \dots u_m$  pre nejaké  $m \in \mathbb{N}$  a  $u_1, \dots, u_m \in L_1 \subseteq (L_1 \cup L_2)$ . Podobne  $v = v_1 \dots v_n$  pre nejaké  $n \in \mathbb{N}$  a  $v_1, \dots, v_n \in L_2 \cdot L_1^*$ . Z definície zretáženia teraz pre  $i = 1, \dots, n$  dostávame  $v_i = x_i y_i$ , kde  $x_i \in L_2 \subseteq (L_1 \cup L_2)$  a  $y_i \in L_1^*$ . Ďalšou aplikáciou tvrdenia 2 napokon pre  $i = 1, \dots, n$  zisťujeme, že  $y_i = z_{i,1} \dots z_{i,s_i}$ , kde  $s_i \in \mathbb{N}$  a  $z_{i,1}, \dots, z_{i,s_i} \in L_1 \subseteq (L_1 \cup L_2)$ . V dôsledku toho

$$\begin{aligned} w &= uv = u_1 \dots u_m v_1 \dots v_n = u_1 \dots u_m (x_1 y_1) \dots (x_n y_n) = \\ &= u_1 \dots u_m (x_1 z_{1,1} \dots z_{1,s_1}) \dots (x_n z_{n,1} \dots z_{n,s_n}) \in (L_1 \cup L_2)^*, \end{aligned}$$

opäť podľa tvrdenia 2.

$\subseteq$ : Nech  $w \in (L_1 \cup L_2)^*$ . Potom podľa tvrdenia 2 existuje  $k \in \mathbb{N}$  a slová  $w_1, \dots, w_k \in L_1 \cup L_2$  tak, že  $w = w_1 \dots w_k$ . Nech  $1 \leq i_1 < \dots < i_s \leq k$  sú indexy také, že  $w_{i_1}, \dots, w_{i_s}$  sú práve všetky slová spomedzi  $w_1, \dots, w_k$ , ktoré sú v  $L_2$ . Slová

$$u_0 = w_1 w_2 \dots w_{i_1-1}, \quad u_1 = w_{i_1+1} w_{i_1+2} \dots w_{i_2-1}, \quad \dots, \quad u_s = w_{i_s+1} w_{i_s+2} \dots w_k$$

potom podľa tvrdenia 2 musia byť v  $L_1^*$  – niektoré z nich môžu byť aj prázdne. Zrejme

$$w = u_0 w_{i_1} u_1 w_{i_2} u_2 \dots w_{i_s} u_s = u_0 ((w_{i_1} u_1)(w_{i_2} u_2) \dots (w_{i_s} u_s)). \quad (1)$$

Pre  $j = 1, \dots, s$  je  $w_{i_j} u_j \in L_2 \cdot L_1^*$  a podľa tvrdenia 2 tak  $(w_{i_1} u_1)(w_{i_2} u_2) \dots (w_{i_s} u_s) \in (L_2 \cdot L_1^*)^*$ . Keďže  $u_0 \in L_1^*$ , z definície zretáženia jazykov a (1) napokon dostávame  $w \in L_1^* \cdot (L_2 \cdot L_1^*)^*$ .  $\square$