

# Substitúcie

Peter Kostolányi

21. februára 2017

## Definícia

Pod substitúciou sa v teórii formálnych jazykov chápe „zovšeobecnenie“ homomorfizmu, kde obrazom slov nie sú slová, ale jazyky.

**Definícia 1.** Nech  $\Sigma, \Gamma$  sú abecedy a  $\tau: \Sigma^* \rightarrow 2^{\Gamma^*}$  je zobrazenie. Zobrazenie  $\tau$  sa nazýva *substitúcia*, ak  $\tau(\varepsilon) = \{\varepsilon\}$  a pre všetky  $u, v \in \Sigma^*$  platí

$$\tau(uv) = \tau(u)\tau(v).$$

*Poznámka 1.* Požiadavka  $\tau(\varepsilon) = \{\varepsilon\}$  je v uvedenej definícii skutočne podstatná, pretože *nevyplyva* z vlastnosti  $\tau(uv) = \tau(u)\tau(v)$  pre všetky  $u, v \in \Sigma^*$ , čím sa substitúcie odlišujú od homomorfizmov. Nájdenie vhodného protipríkladu je jednou z úloh určených na nasledujúce cvičenie.

*Poznámka 2.* Ak  $h: \Sigma^* \rightarrow \Gamma^*$  je homomorfizmus, zobrazenie  $\tau: \Sigma^* \rightarrow 2^{\Gamma^*}$  definované pre všetky  $w \in \Sigma^*$  ako  $\tau(w) = \{h(w)\}$  je zjavne substitúcia. Aj keď teda homomorfizmus z formálneho hľadiska nie je substitúciou, možno sa na substitúcie z určitého pohľadu dívať ako na zovšeobecnenie homomorfizmov.

*Poznámka 3.* Definíciu substitúcie možno interpretovať aj tak, že ide o homomorfizmus monoidov  $(\Sigma^*, \cdot)$  a  $(2^{\Gamma^*}, \cdot)$ .

Z nasledujúceho tvrdenia vyplýva, že podobne ako homomorfizmy sú aj substitúcie jednoznačne určené obrazmi jednotlivých písmen, a teda ich možno alternatívne definovať aj ako zobrazenia zo  $\Sigma$  do  $2^{\Gamma^*}$  (s následným rozšírením na  $\Sigma^*$ ). V nasledujúcom budeme túto skutočnosť využívať bez toho, aby sme na to explicitne upozorňovali.

**Tvrdenie 1.** Nech  $\Sigma, \Gamma$  sú abecedy a  $\tau: \Sigma^* \rightarrow 2^{\Gamma^*}$  je substitúcia. Nech  $\tau': \Sigma^* \rightarrow 2^{\Gamma^*}$  je substitúcia taká, že pre všetky  $c \in \Sigma$  platí  $\tau'(c) = \tau(c)$ . Potom  $\tau' = \tau$ .

*Dôkaz.* Treba ukázať, že pre všetky  $w \in \Sigma^*$  platí  $\tau'(w) = \tau(w)$ . To možno urobiť jednoduchou indukciou vzhľadom na dĺžku slova  $w$  (detaily prenechávame čitateľovi).  $\square$

Podobne ako v prípade homomorfizmov možno definíciu substitúcie aditívne rozšíriť aj na jazyky.

**Definícia 2.** Nech  $\Sigma, \Gamma$  sú abecedy,  $\tau: \Sigma^* \rightarrow 2^{\Gamma^*}$  je substitúcia a  $L \subseteq \Sigma^*$  je jazyk. *Obraz jazyka  $L$  pri zobrazení substitúciou  $\tau$  je jazyk*

$$\tau(L) = \bigcup_{w \in L} \tau(w).$$

*Príklad 1.* Nech  $\Sigma = \{a, b\}$  a substitúcia  $\tau: \Sigma^* \rightarrow 2^{\Sigma^*}$  je daná ako  $\tau(a) = \{\varepsilon, b\}$  a  $\tau(b) = \{a\}^*$ . Potom pre  $L = \{ab, bb\}$  platí

$$\tau(L) = \tau(ab) \cup \tau(bb) = (\{a\}^* \cup \{b\}\{a\}^*) \cup \{a\}^* = \{a\}^* \cup \{b\}\{a\}^*.$$

Je zrejmé, že substitúcia je veľmi silná operácia: stačí si uvedomiť, že jazyk  $\tau(a)$  napríklad nemusí byť ani rekurzívne vyčísliteľný. Z tohto dôvodu sa v súvislosti s konkrétnymi triedami jazykov budeme zaoberať väčšinou substitúciami, ktorých obor hodnôt je určitým spôsobom obmedzený. To odôvodňuje zavedenie pojmu  $\mathcal{L}$ -substitúcie pre triedu jazykov  $\mathcal{L}$ .

**Definícia 3.** Nech  $\Sigma, \Gamma$  sú abecedy,  $\tau: \Sigma^* \rightarrow 2^{\Gamma^*}$  je substitúcia a  $\mathcal{L}$  je trieda jazykov. Hovoríme, že  $\tau$  je  $\mathcal{L}$ -substitúcia, ak pre všetky  $c \in \Sigma$  platí  $\tau(c) \in \mathcal{L}$ .

*Poznámka 4.* Treba upozorniť na skutočnosť, že z uvedenej definície ešte pre  $\mathcal{L}$ -substitúciu  $\tau: \Sigma^* \rightarrow 2^{\Gamma^*}$  vo všeobecnosti *nevyplýva*  $\tau(w) \in \mathcal{L}$  pre všetky  $w \in \Sigma^*$ . Túto vlastnosť však zjavne majú všetky  $\mathcal{L}$ -substitúcie pre triedy  $\mathcal{L}$  uzavreté na zrežazenie (čo sú napr. všetky triedy jazykov Chomského hierarchie).

V podobnom duchu tiež definujeme *regulárnu substitúciu* ako  $\mathcal{R}$ -substitúciu, *bezkontextovú substitúciu* ako  $\mathcal{L}_{CF}$ -substitúciu a podobnú terminológiu budeme používať aj pre ďalšie známe triedy jazykov.


### Uzavretosť tried $\mathcal{R}$ a $\mathcal{L}_{CF}$ na substitúciu

Z predchádzajúcich úvah okrem iného vyplýva, že nemá zmysel očakávať uzavretosť nejakej zmysluplnej a netriviálnej triedy jazykov na všeobecnú substitúciu. Aj preto budeme hovoriť, že trieda  $\mathcal{L}$  je *uzavretá na substitúciu*, ak je uzavretá na  $\mathcal{L}$ -substitúciu. V nasledujúcom dokážeme, že triedy  $\mathcal{R}$  a  $\mathcal{L}_{CF}$  sú uzavreté na substitúciu.

**Veta 1.** *Trieda  $\mathcal{R}$  je uzavretá na substitúciu.*

*Dôkaz.* Nech  $L \subseteq \Sigma^*$  je regulárny jazyk akceptovaný deterministickým konečným automatom  $A = (K, \Sigma, \delta, q_0, F)$  a  $\tau: \Sigma^* \rightarrow 2^{\Gamma^*}$  je regulárna substitúcia. Zostrojíme nedeterministický konečný automat  $A'$  taký, že  $L(A') = \tau(L)$ .

Keďže je substitúcia  $\tau$  regulárna, pre každé  $c \in \Sigma$  existuje nedeterministický konečný automat  $A_c$  v „prasiatkovom“ normálnom tvare taký, že  $L(A_c) = \tau(c)$ . Automat  $A'$  zostrojíme z automatu  $A$  tak, že každý prechod na symbol  $c$  nahradíme samostatnou kópiou automatu  $A_c$  tak, ako je znázornené na obrázku 1. Každá kópia automatu  $A_c$  musí byť označená počiatočným a koncovým stavom prechodu, ktorý nahrádza – inak by mohlo dôjsť k „pomiešaniu stavov“ jednotlivých kópií automatu  $A_c$ .



**Obr. 1:** Každý prechod automatu  $A$  na písmeno  $c$  nahradíme samostatnou kópiou automatu  $A_c$ .

Predpokladajme, že pre všetky  $c \in \Sigma$  je  $A_c = (K[A_c], \Gamma, \delta[A_c], q_0[A_c], \{q_F[A_c]\})$ , pričom pre všetky  $a, b \in \Sigma$  také, že  $a \neq b$  sú množiny stavov  $K[A_a]$  a  $K[A_b]$  disjunktné. Formálnu konštrukciu automatu  $A'$  potom môžeme zapísať nasledovne:  $A' = (K', \Sigma', \delta', q'_0, F')$ , kde

$$K' = K \cup \bigcup_{c \in \Sigma} (K[A_c] \times K^2),$$

$\Sigma' = \Gamma$ ,  $q'_0 = q_0$ ,  $F' = F$  a kde prechodová funkcia  $\delta'$  je daná nasledovne: pre všetky stavy  $p \in K$  definujeme

$$\delta'(p, \varepsilon) = \{(q_0[A_c], p, \delta(p, c)) \mid c \in \Sigma\},$$

čo zodpovedá prechodom na  $\varepsilon$  vedúcim zo stavov z množiny  $K$  do počiatočných stavov kópií automatu  $A_c$ . Ďalej pre všetky  $p, r \in K$ ,  $c \in \Sigma$  a pre všetky  $q \in K[A_c] - \{q_F[A_c]\}$  a  $a \in \Gamma \cup \{\varepsilon\}$  definujeme prechod

$$\delta'((q, p, r), a) = (\delta[A_c](q, a), p, r)$$

v rámci zodpovedajúcej kópie automatu  $A_c$  a nakoniec, pre všetky  $p, r \in K$  a  $c \in \Sigma$  definujeme prechod

$$\delta'((q_F[A_c], p, r), \varepsilon) = r$$

vedúci z akceptačného stavu danej kópie automatu  $A_c$  do zodpovedajúceho stavu z  $K$ . Konštrukcia je hotová. Dôkaz rovnosti  $L(A') = \tau(L)$  robiť nebudeme.  $\square$

**Veta 2.** Trieda  $\mathcal{L}_{CF}$  je uzavretá na substitúciu.

*Dôkaz.* Nech  $L$  je bezkontextový jazyk generovaný bezkontextovou gramatikou  $G = (N, T, P, \sigma)$ . Nech  $\tau$  je bezkontextová substitúcia na  $T^*$ . Gramatiku  $G'$  generujúcu jazyk  $L(G') = \tau(L)$  možno získať nahradením každého terminálu  $c \in T$  počiatočným neterminálom bezkontextovej gramatiky pre  $\tau(c)$  (za predpokladu disjunktnosti jednotlivých množín neterminálov a neexistencie symbolu, ktorý je súčasne neterminálom jednej gramatiky a terminálom inej gramatiky).

Presnejšie: nech pre každé  $c \in T$  je  $G_c = (N_c, T_c, P_c, \sigma_c)$  bezkontextová gramatika taká, že  $L(G_c) = \tau(c)$ . Predpokladajme navyše, že platí

$$\begin{aligned} N_c \cap N_d &= \emptyset & \forall c, d \in T, c \neq d, \\ N_c \cap N &= \emptyset & \forall c \in T, \\ \left( N \cup \bigcup_{c \in T} N_c \right) \cap \left( \bigcup_{c \in T} T_c \right) &= \emptyset. \end{aligned}$$

Uvažujme homomorfizmus  $h$  na  $(N \cup T)^*$  taký, že pre všetky  $\xi \in N$  je  $h(\xi) = \xi$  a pre všetky  $c \in T$  je  $h(c) = \sigma_c$ . Gramatiku  $G'$  potom môžeme zostrojiť nasledovne:  $G' = (N', T', P', \sigma')$ , kde

$$\begin{aligned} N' &= N \cup \bigcup_{c \in T} N_c, \\ T' &= \bigcup_{c \in T} T_c, \\ P' &= \{ \xi \rightarrow h(w) \mid (\xi \rightarrow w) \in P \} \cup \bigcup_{c \in T} P_c, \\ \sigma' &= \sigma. \end{aligned}$$

Konštrukcia je hotová (pričom dôkaz rovnosti  $L(G') = \tau(L)$  vynechávame). □