

Cvičenie č. 9 Bezkontextové jazyky

Peter Kostolányi

16. novembra 2022

Vieme už, že zásobníkové automaty sú – bez ohľadu na mód akceptácie – z hľadiska opisnej sily ekvivalentné bezkontextovým gramatikám. Obidva modely teda realizujú rovnakú triedu jazykov, ktoré nazývame *bezkontextovými*.

Definícia 1. *Bezkontextový jazyk* je jazyk L , pre ktorý existuje bezkontextová gramatika G taká, že $L(G) = L$. Triedu všetkých bezkontextových jazykov označujeme \mathcal{L}_{CF} .

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

- (i) *Jazyk L je bezkontextový.*
- (ii) *Existuje zásobníkový automat A taký, že $L(A) = L$.*
- (iii) *Existuje zásobníkový automat A taký, že $N(A) = L$.*

1 Pumpovacia lema pre bezkontextové jazyky

Nech L je *ľubovoľný* bezkontextový jazyk. Potom *existuje* bezkontextová gramatika $G = (N, T, P, \sigma)$ taká, že $L(G) = L$. Nech má najdlhšia pravá strana pravidiel z P dĺžku k ; bez ujmy na všeobecnosti predpokladajme, že $k \geq 2$. V každom kroku odvodu potom možno jeden neterminál prepísať na najviac k symbolov. Strom odvodu s hĺbkou menšou alebo rovnou n tak môže zodpovedať iba slovu dĺžky najviac k^n a každý strom odvodu slova dĺžky aspoň k^n preto musí mať hĺbku najmenej n . Položme $p := k^{|N|+1}$.

Nech $w \in L$ je *ľubovoľné* slovo také, že $|w| \geq p$. Vezmime strom najkratšieho¹ odvodu slova w v gramatike G . Ten má hĺbku aspoň $|N| + 1$. Najdlhšia cesta z koreňa do niektorého z listov preto obsahuje aspoň $|N| + 2$ uzlov, pričom v liste je terminál alebo prázdne slovo a vo vnútorných uzloch, ktorých je aspoň $|N| + 1$, sú neterminály. Na tejto ceste sa teda musí zopakovať niektorý neterminál ξ . Ak je cesta dlhšia ako $|N| + 1$, môžeme predpokladať, že k obojm výskytom neterminálu ξ dôjde v rámci najnižších $|N| + 2$ úrovní. Situácia je znázornená na obrázku 1.

Odvodenie slova w v gramatike G tak možno s odkazom na obrázok 1 zapísať nasledovne:


$$\sigma \Rightarrow^* x\xi z \Rightarrow^+ xu\xi v z \Rightarrow^* xuyvz = w.$$

Pre slovo w teda *existujú* slová x, u, y, v, z také, že $w = xuyvz$. Keďže k podslovu uyv prislúcha podstrom hĺbky najviac $|N| + 1$, nutne $|uyv| \leq k^{|N|+1} = p$. Keby boli obidve slová u, v prázdne, bolo by možné časť odvodu – konkrétne $x\xi z \Rightarrow^+ xu\xi v z$ – vynechať bezo zmeny vygenerovaného slova; to by ale odporovalo nášmu predpokladu, podľa ktorého ide o najkratšie odvodenie slova w . Preto $|uv| \geq 1$. Keďže napokon možno uvedenú časť odvodu – $x\xi z \Rightarrow^+ xu\xi v z$ – vynechať alebo niekoľkokrát zopakovať, pre každé $i \in \mathbb{N}$ patrí aj slovo $xu^i y v^i z$ do jazyka generovaného gramatikou G . Dokázali sme teda nasledujúce tvrdenie – *pumpovaciu lemu pre bezkontextové jazyky*.

Veta 2. *Nech Σ je abeceda a $L \subseteq \Sigma^*$ bezkontextový jazyk. Potom existuje $p \in \mathbb{N}$ také, že pre všetky $w \in L$ s $|w| \geq p$ existujú slová $x, u, y, v, z \in \Sigma^*$ také, že:*

- (i) $w = xuyvz$,
- (ii) $|uyv| \leq p$,
- (iii) $|uv| \geq 1$,
- (iv) $\forall i \in \mathbb{N} : xu^i y v^i z \in L$.

¹Ak existuje viacero odvodení minimálnej dĺžky, môžeme vziať ľubovoľné z nich.



Obr. 1: Schematické znázornenie stromu odvodenia v gramatike G . Ak má slovo dĺžku aspoň p , jeho strom odvodenia je hĺbky najmenej $|N| + 1$. Najdlhšia cesta z koreňa do listu je znázornená hrubou čiarou. V rámci posledných $|N| + 2$ uzlov – čiže v podstrome hĺbky najviac $|N| + 1$ – sa na tejto ceste musí zopakovať niektorý neterminál ξ . Tieto jeho dva výskyty určujú faktorizáciu $w = xyvz$ vygenerovaného slova.

1.1 Riešené úlohy

Pumpovacia lema pre bezkontextové jazyky je užitočným nástrojom pri dokazovaní, že nejaký jazyk L nie je bezkontextový. Jej použitie je podobné ako pri pumpovacej leme pre regulárne jazyky.

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

Riešenie. Za účelom sporu predpokladajme, že $L \in \mathcal{L}_{CF}$. Nech $p \in \mathbb{N}$ je konštanta prislúchajúca k jazyku L podľa pumpovacej lemy. Uvažujme slovo $w = a^p b^p c a^p b^p$; evidentne $w \in L$ a $|w| \geq p$. Podľa pumpovacej lemy teda existujú slová x, u, y, v, z , pre ktoré sú splnené podmienky (i) až (iv).

Keby bolo $\#_c(u) > 0$ alebo $\#_c(v) > 0$, muselo by byť aj $\#_c(xu^2yv^2z) \geq 2$, pričom z podmienky (iv) by sme pre $i = 2$ dostali $xu^2yv^2z \in L$ – to je očividný spor s definíciou jazyka L .

Môžeme teda predpokladať, že $\#_c(u) = \#_c(v) = 0$. Jediný výskyt písmena c v slove w tak musí byť súčasťou niektorého z faktorov x, y, z .

- Nech $\#_c(x) = 1$. Potom $x = a^p b^p c x'$ pre nejaké $x' \in \{a, b\}^*$ také, že $x'uyvz = a^p b^p$. Vďaka (iii) ďalej $|u| + |v| \geq 1$. Z podmienky (iv) pre $i = 2$ dostávame $xu^2yv^2z = a^p b^p c x' u^2 y v^2 z \in L$. To ale odporuje definícii jazyka L , pretože $|x' u^2 y v^2 z| = |x' u y v z| + |u| + |v| \geq |a^p b^p| + 1$ – nemôže teda platiť $a^p b^p = x' u^2 y v^2 z$.
- Nech $\#_c(z) = 1$. Potom $z = z' c a^p b^p$ pre nejaké $z' \in \{a, b\}^*$ také, že $xuyvz' = a^p b^p$. Vďaka (iii) je $|u| + |v| \geq 1$ a zo (iv) pre $i = 2$ dostávame $xu^2yv^2z = xu^2yv^2z' c a^p b^p \in L$. To je spor, lebo $|xu^2yv^2z'| = |xuyvz'| + |u| + |v| \geq |a^p b^p| + 1$ – nemôže teda platiť $xu^2yv^2z' = a^p b^p$.
- Nech $\#_c(y) = 1$. Keďže vďaka podmienke (ii) je $|uyv| \leq p$, pre nejaké $k, \ell, m, n \in \mathbb{N}$ musí byť $x = a^p b^k$, $u = b^\ell$, $y = b^{p-k-\ell} c a^m$, $v = a^n$ a $z = a^{p-m-n} b^p$. Vďaka podmienke (iii) pritom platí aspoň jedna z nerovností $\ell \geq 1$ alebo $n \geq 1$. Z podmienky (iv) pre $i = 2$ napokon dostávame $xu^2yv^2z = a^p b^k b^{2\ell} b^{p-k-\ell} c a^m a^{2n} a^{p-m-n} b^p = a^p b^{p+\ell} c a^{p+n} b^p \in L$ – to je spor, pretože v prípade platnosti aspoň jednej z nerovností $\ell \geq 1$ a $n \geq 1$ nemôže byť $a^p b^{p+\ell} = a^{p+n} b^p$. \square

Úloha 2. Dokážte, že jazyk $L = \{a^{2^n} \mid n \in \mathbb{N}\}$ nie je bezkontextový.

Riešenie. Budeme postupovať veľmi podobne ako pri dokazovaní, že $L \notin \mathcal{R}$. Za účelom sporu predpokladajme, že $L \in \mathcal{L}_{CF}$. Nech $p \in \mathbb{N}$ je konštanta prislúchajúca k jazyku L podľa pumpovacej lemy. Vezmime ľubovoľné slovo $w = a^{2^m}$ také, že $2^m > p$ – evidentne $w \in L$ a $|w| \geq p$. Existujú teda slová x, u, y, v, z , pre ktoré sú splnené podmienky (i) až (iv) z pumpovacej lemy.

Vďaka (i) je $w = xyvz$. Z (ii) a (iii) ďalej vyplýva, že pre nejaké $r, s, t, k \in \mathbb{N}$ s $s + k \geq 1$ a $s + t + k \leq p$ je $x = a^r$, $u = a^s$, $y = a^t$, $v = a^k$ a $z = a^{2^m - r - s - t - k}$. Z podmienky (iv) pumpovacej lemy napokon pre $i = 2$ vyplýva $xu^2yv^2z = a^r a^{2s} a^t a^{2k} a^{2^m - r - s - t - k} = a^{2^m + s + k} \in L$. Keďže ale $1 \leq s + k \leq s + t + k \leq p < 2^m$, je $2^m < 2^m + s + k < 2^{m+1}$, a teda $2^m + s + k$ nie je mocnina dvoch – dostávame teda spor s definíciou jazyka L . \square