

Formální jazyky a automaty

Jednoduchá pravidla a epsilon-pravidla, Chomského normální forma, věta o vkládání pro bezkontextové jazyky

Jan Křetínský

Fakulta informatiky, MU Brno

Jaro 2024

Kanonické tvary bezkontextových gramatik

- ▶ redukované bezkontextové gramatiky
- ▶ gramatiky bez ϵ -pravidel
- ▶ gramatiky bez jednoduchých pravidel
- ▶ vlastní gramatiky
- ▶ Chomského normální forma
- ▶ gramatiky bez levé rekurze
- ▶ Greibachové normální forma

Definice 3.13.

Řekneme, že CFG $\mathcal{G} = (N, \Sigma, P, S)$ je **bez ε -pravidel** právě když buď

1. P neobsahuje žádné ε -pravidlo (tj. pravidlo tvaru $A \rightarrow \varepsilon$) nebo
2. v P existuje právě jedno ε -pravidlo $S \rightarrow \varepsilon$ a S se nevyskytuje na pravé straně žádného pravidla z P .

Příklad

$\mathcal{G} = (\{S, A, B\}, \{a, b, c\}, P, S)$, kde P obsahuje pravidla

$$S \rightarrow aAbBc$$

$$A \rightarrow BB \mid a \mid \varepsilon$$

$$B \rightarrow AcA \mid b$$

Algoritmus pro odstranění ε -pravidel

Vstup: CFG $\mathcal{G} = (N, \Sigma, P, S)$

Výstup: CFG $\mathcal{G}' = (N', \Sigma, P', S')$ bez ε -pravidel splňující $L(\mathcal{G}) = L(\mathcal{G}')$

- 1: Zkonstruuj $N_\varepsilon = \{A \in N \mid A \Rightarrow^* \varepsilon\}$
- 2: Množinu pravidel P' zkonstruuj takto:
- 3: **for all** $A \rightarrow X_1 \dots X_n \in P, n > 0$ **do**
- 4: přidej do P' všechna pravidla tvaru $A \rightarrow \alpha_1 \dots \alpha_n$ splňující
- 5: (a) pokud $X_i \notin N_\varepsilon$ pak $\alpha_i = X_i$
- 6: (b) pokud $X_i \in N_\varepsilon$ pak α_i je buď X_i nebo ε
- 7: (c) ne všechna α_i jsou ε
- 8: **if** $S \in N_\varepsilon$ **then**
- 9: přidej do P' pravidla $S' \rightarrow S \mid \varepsilon$
- 10: $N' := N \cup \{S'\}$
- 11: **else**
- 12: $N' := N; S' := S$

Algoritmus pro odstranění ε -pravidel

Vstup: CFG $\mathcal{G} = (N, \Sigma, P, S)$

Výstup: CFG $\mathcal{G}' = (N', \Sigma, P', S')$ bez ε -pravidel splňující $L(\mathcal{G}) = L(\mathcal{G}')$

- 1: Zkonstruuuj $N_\varepsilon = \{A \in N \mid A \Rightarrow^* \varepsilon\}$
- 2: Množinu pravidel P' zkonstruuuj takto:
- 3: **for all** $A \rightarrow X_1 \dots X_n \in P, n > 0$ **do**
- 4: přidej do P' všechna pravidla tvaru $A \rightarrow \alpha_1 \dots \alpha_n$ splňující
- 5: (a) pokud $X_i \notin N_\varepsilon$ pak $\alpha_i = X_i$
- 6: (b) pokud $X_i \in N_\varepsilon$ pak α_i je buď X_i nebo ε
- 7: (c) ne všechna α_i jsou ε
- 8: **if** $S \in N_\varepsilon$ **then**
- 9: přidej do P' pravidla $S' \rightarrow S \mid \varepsilon$
- 10: $N' := N \cup \{S'\}$
- 11: **else**
- 12: $N' := N; S' := S$

Korektnost algoritmu:

Konečnost

Výsledná gramatika je bez ε -pravidel

Ekvivalence gramatik

Příklad

$\mathcal{G} = (\{S, A, B\}, \{a, b, c\}, P, S)$, kde P obsahuje pravidla

$S \rightarrow aAbBc \mid AB$

$A \rightarrow BB \mid a \mid \varepsilon$

$B \rightarrow AA \mid b$

Jednoduchá pravidla

Jednoduchým pravidlem nazýváme každé pravidlo tvaru $A \rightarrow B$, kde $A, B \in N$.

$$S \rightarrow aAbBc$$

$$A \rightarrow aA \mid B \mid a$$

$$B \rightarrow bB \mid b$$

Algoritmus pro odstranění jednoduchých pravidel

Vstup: CFG $\mathcal{G} = (N, \Sigma, P, S)$ bez ε -pravidel

Výstup: CFG $\mathcal{G}' = (N, \Sigma, P', S)$ bez jednoduchých a ε -pravidel, kde
 $L(\mathcal{G}) = L(\mathcal{G}')$

- 1: **for all** $A \in N$ **do**
- 2: $i := 0$; $M_0 := \{A\}$
- 3: **repeat**
- 4: $i := i + 1$
- 5: $M_i := M_{i-1} \cup \{C \mid C \rightarrow B \in P, B \in M_{i-1}\}$
- 6: **until** $M_i = M_{i-1}$
- 7: $M_A := M_i$

- 8: $P' := \emptyset$
- 9: **for all** $B \rightarrow \alpha \in P$, které není jednoduché **do**
- 10: do P' přidej $A \rightarrow \alpha$ pro každé $A \in M_B$, tj. $A \Rightarrow_{\mathcal{G}}^* B$

Příklad

$\mathcal{G} = (\{S, A, B, C\}, \{a, b, c\}, P, S)$, kde P obsahuje pravidla

$S \rightarrow ABC$

$A \rightarrow aA \mid B \mid a$

$B \rightarrow bB \mid A$

$C \rightarrow cC \mid A$

Korektnost algoritmu

Konečnost.

Výsledná gramatika neobsahuje jednoduchá pravidla ani ε -pravidla.

Ekvivalence gramatik:

$L(\mathcal{G}') \subseteq L(\mathcal{G})$ Necht $w \in L(\mathcal{G}')$, pak existuje derivace

$$S = \alpha_0 \Rightarrow_{\mathcal{G}'} \alpha_1 \Rightarrow_{\mathcal{G}'} \dots \Rightarrow_{\mathcal{G}'} \alpha_n = w.$$

Pokud bylo při kroku $\alpha_i \Rightarrow_{\mathcal{G}'} \alpha_{i+1}$ použito pravidlo $A \rightarrow \beta$, pak $A \in M_B$ pro nějaké $B \in N$ takové, že v \mathcal{G} platí $A \Rightarrow^* B$ a $B \rightarrow \beta$.

Tedy v \mathcal{G} platí $A \Rightarrow^* \beta$ a $\alpha_i \Rightarrow^* \alpha_{i+1}$.

$L(\mathcal{G}) \subseteq L(\mathcal{G}')$ Necht $w \in L(\mathcal{G})$, pak existuje levá derivace

$$S = \alpha_0 \Rightarrow_{\mathcal{G}} \alpha_1 \Rightarrow_{\mathcal{G}} \dots \Rightarrow_{\mathcal{G}} \alpha_n = w.$$

Tu lze rozdělit na úseky tak, že v každém úseku se použila pouze jednoduchá pravidla anebo žádné jednoduché pravidlo.

Úsek s jednoduchými pravidly lze vypustit (a ponechat pouze jeho počáteční větnou formu). □

Definice 3.17.

CFG $\mathcal{G} = (N, \Sigma, P, S)$ se nazývá **necyklická**, právě když neexistuje $A \in N$ takový, že $A \Rightarrow^+ A$.

\mathcal{G} se nazývá **vlastní**, právě když je bez nepoužitelných symbolů, bez ε -pravidel a necyklická.

Věta 3.18.

Ke každému neprázdnému bezkontextovému jazyku existuje **vlastní** bezkontextová gramatika, která jej generuje.

Důkaz. Z bezkontextové gramatiky pro neprázdný jazyk odstraníme ε -pravidla a jednoduchá pravidla. Odstraněním nepoužitelných symbolů pak získáme vlastní gramatiku. □

Definice 3.19.

Bezkontextová gramatika $\mathcal{G} = (N, \Sigma, P, S)$ je v **Chomského normální formě (CNF)**, právě když \mathcal{G} je bez ε -pravidel a každé pravidlo z P má jeden z těchto tvarů:

1. $A \rightarrow BC$, kde $B, C \in N$
2. $A \rightarrow a$, kde $a \in \Sigma$
3. $S \rightarrow \varepsilon$

Věta 3.21.

Každý bezkontextový jazyk lze generovat bezkontextovou gramatikou v Chomského normální formě.

Příklad

$\mathcal{G} = (\{S, A, B\}, \{a, b\}, P, S)$, kde P obsahuje pravidla

$S \rightarrow AS \mid a$

$A \rightarrow AB \mid AA \mid a$

$B \rightarrow b$

Algoritmus transformace do CNF

Algoritmus 3.6

Princip:

1. $L = \emptyset$

2. $L \neq \emptyset$

Gramatiku pro L převedeme na vlastní a bez jednoduchých pravidel.

$$X \rightarrow \varepsilon$$

$$X \rightarrow a$$

$$X \rightarrow A$$

$$X \rightarrow ab$$

$$X \rightarrow aB$$

$$X \rightarrow Ab$$

$$X \rightarrow AB$$

\vdots

$$X \rightarrow aBcD$$

Lemma o vkládání pro bezkontextové jazyky

Věta 3.24.

Nechť L je CFL. Pak existují $p, q \in \mathbb{N}$ (závisející na L) taková, že každé slovo $z \in L$ delší než p lze psát ve tvaru $z = uvwxy$, kde

- ▶ alespoň jedno ze slov v, x je neprázdné (tj. $vx \neq \varepsilon$),
- ▶ $|vwx| \leq q$ a
- ▶ $uv^iwx^iy \in L$ pro každé $i \in \mathbb{N}_0$.

Poznámka 3.25. Tvzení zůstává v platnosti i když namísto konstant p, q budeme všude psát jen (jedinou) konstantu n .

Použití Lemmatu o vkládání pro bezkontextové jazyky

Lemma o vkládání je implikace $P \implies Q$, kde P je výrok, že L je CFL a Q jsou uvedené vlastnosti.

Obměnu Lemmatu o vkládání $\neg Q \implies \neg P$ lze použít k důkazu, že nějaký jazyk L **není** CFL: stačí, když ukážeme platnost $\neg Q$.

$\neg Q$:

1. Pro libovolnou konstantu $n \in \mathbb{N}$
2. existuje slovo $z \in L$ delší než n takové, že
3. pro všechny slova u, v, w, x, y splňující $z = uvwxy$, $vx \neq \varepsilon$ a $|vwx| \leq n$
4. existuje $i \in \mathbb{N}_0$ takové, že $uv^iwx^i y \notin L$.

Příklad použití Lemmatu o vkládání

$$L = \{a^i b^i c^i \mid i \geq 1\}$$

1. Pro libovolnou konstantu $n \in \mathbb{N}$
2. existuje slovo $z \in L$ delší než n takové, že
3. pro všechny slova u, v, w, x, y splňující
 $z = uvwxy$, $vx \neq \varepsilon$ a $|vwx| \leq n$
4. existuje $i \in \mathbb{N}_0$ takové, že $uv^i wx^i y \notin L$.

$\implies L$ není CFL.

Důkaz Lemmatu o vkládání pro bezkontextové jazyky

Nechť L je generován gramatikou v CNF.

hloubka stromu $\stackrel{def}{=} \max.$ počet hran na cestě = $\max.$ počet
neterminálů na cestě


- ▶ Derivační strom hloubky k má max. 2^{k-1} listů \implies slovo délky nejvýše 2^{k-1} .
- ▶ Derivační strom pro slovo delší než 2^{k-1} má hloubku alespoň $k + 1$. Nejdelší cesta obsahuje alespoň $k + 1$ neterminálů.

Důkaz Lemmatu o vkládání pro bezkontextové jazyky

- Derivační strom pro slovo delší než 2^{k-1} má cestu délky alespoň $k + 1$. Tato cesta obsahuje alespoň $k + 1$ neterminálů.

Označme $k = |N|$ a položme $p = 2^{k-1}, q = 2^k$.

Nechť $z \in L$ je slovo delší než p . Pak v libovolném derivačním stromu slova z existuje cesta s alespoň $k + 1$ neterminály (vezměme tu nejdelší).



u_1, u_2 poslední opakování neterminálu na této cestě.

Tedy hloubka z u_1 je nejvýše $k + 1$, a proto $|vwx| \leq 2^k$.

