

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

Chomského normální forma

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

$$\begin{array}{l} S \rightarrow AS \mid a \\ A \rightarrow AB \mid AA \mid a \\ B \rightarrow b \end{array}$$

Algoritmus transformace do CNF

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. Necht' 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. Tvrzení zůstává v platnosti i když namísto konstant p, q budeme všude psát jen (jedinou) konstantu n .

Důkaz Lemmatu o vkládání pro bezkontextové jazyky

Nechť L je generován gramatikou v CNF.

délka cesty z kořene do listu

= počet modrých hran

= počet neterminálů na cestě - 1

hloubka stromu

= maximální délka cesty

Derivační strom hloubky k má max. 2^k listů \implies slovo délky nejvýše 2^k .

Derivační strom pro slovo delší než 2^{k-1} má cestu délky alespoň k .

Tato cesta obsahuje alespoň $k + 1$ neterminálů.

Důkaz Lemmatu o vkládání pro bezkontextové jazyky

Nechť L je generován gramatikou $\mathcal{G} = (N, \Sigma, P, S)$, která je v CNF.
Označme $k = \text{card}(N)$ 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 délky alespoň k . Zvolme pevně jeden takový strom T a v něm (libovolnou) nejdelší cestu C .

Na cestě C lze zvolit tři uzly u_1, u_2, u_3 s vlastnostmi:

- 1 uzly u_1, u_2 jsou označeny týmž neterminálem, řekněme A
- 2 u_1 leží blíže ke kořenu než u_2
- 3 u_3 je list
- 4 cesta z u_1 do u_3 má délku nejvýše k

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 $uv^iwx^iy \notin L$.

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.

Rekursivní neterminály a gramatiky

Definice 3.28. Neterminál A v CFG $\mathcal{G} = (N, \Sigma, P, S)$ se nazývá **levorekursivní** jestliže v \mathcal{G} existuje derivace $A \Rightarrow^+ A\beta$.

CFG bez levorekursivních neterminálů se nazývá **nelevorekursivní**.

Je-li v CFG pravidlo tvaru $A \rightarrow A\alpha$, hovoříme o **přímé levé rekursi** na A .

Praktický význam: některé nástroje pro automatickou tvorbu parserů k zadaným gramatikám vyžadují na vstupu nelevorekursivní gramatiku (např. ANTLR).

Algoritmus odstranění přímé levé rekurze

Nechť CFG $\mathcal{G} = (N, \Sigma, P, S)$ je necyklická a bez ε -pravidel, v níž všechna A -pravidla (pravidla mající na levé straně A) jsou tvaru

$$A \rightarrow A\alpha_1 \mid \dots \mid A\alpha_m \mid \beta_1 \mid \dots \mid \beta_n,$$

kde každý řetěz β_i začíná symbolem různým od A .

Nechť $\mathcal{G}' = (N \cup \{A'\}, \Sigma, P', S)$, kde P' obdržíme z P tak, že všechna výše uvedená pravidla nahradíme pravidly:

$$A \rightarrow \beta_1 \mid \dots \mid \beta_n \mid \beta_1 A' \mid \dots \mid \beta_n A'$$

$$A' \rightarrow \alpha_1 \mid \dots \mid \alpha_m \mid \alpha_1 A' \mid \dots \mid \alpha_m A'$$

Pak $L(\mathcal{G}) = L(\mathcal{G}')$ a \mathcal{G}' je necyklická a bez ε -pravidel.

Lemma o substituci

Lemma 3.20. (o substituci)

Nechť $\mathcal{G} = (N, \Sigma, P, S)$ je CFG. Nechť $A \rightarrow \alpha_1 B \alpha_2 \in P$.

Nechť $B \rightarrow \beta_1 \mid \dots \mid \beta_r$ jsou všechna pravidla v P tvaru $B \rightarrow \alpha$.

Definujme $\mathcal{G}' = (N, \Sigma, P', S)$, kde

$$P' = (P \setminus \{A \rightarrow \alpha_1 B \alpha_2\}) \cup \{A \rightarrow \alpha_1 \beta_1 \alpha_2 \mid \dots \mid \alpha_1 \beta_r \alpha_2\}.$$

Pak $L(\mathcal{G}) = L(\mathcal{G}')$.

Příklad

$A \rightarrow Bd \mid c$

$B \rightarrow Bdd \mid Ccc \mid aAd$

$C \rightarrow Aa$

Algoritmus odstranění levé rekurze

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

Výstup: Ekvivalentní nelevorekursivní gramatika bez ε -pravidel

- 1: Uspořádej libovolně N , $N = \{A_1, \dots, A_n\}$
- 2: **for** $i \leftarrow 1$ **to** n **do**
- 3: **for** $j \leftarrow 1$ **to** $i - 1$ **do**
- 4: **for all** pravidlo tvaru $A_i \rightarrow A_j\alpha$ **do**
- 5: přidej pravidla $A_i \rightarrow \beta_1\alpha \mid \dots \mid \beta_k\alpha$
- 6: (kde $A_j \rightarrow \beta_1 \mid \dots \mid \beta_k$ jsou všechna pravidla pro A_j)
- 7: vypuť pravidlo $A_i \rightarrow A_j\alpha$
- 8: **end for**
- 9: **end for**
- 10: odstraň případnou přímou levou rekursi na A_i
- 11: **end for**

Korektnost algoritmu

Konečnost.

Ekvivalence gramatik: Všechny úpravy jsou dle Lemmatu o substituci nebo odstraňují přímou levou rekursi.

Výsledná gramatika je nelevorekursivní:

- 1 po i -té iteraci vnějšího cyklu začíná každé A_i -pravidlo buď terminálem nebo neterminálem A_k , kde $k > i$.
- 2 po j -té iteraci vnitřního cyklu začíná každé A_i -pravidlo buď terminálem nebo neterminálem A_k , kde $k > j$.

Výsledná gramatika je bez ε -pravidel.

Greibachové normální forma

Definice 3.33. Bezkontextová gramatika $\mathcal{G} = (N, \Sigma, P, S)$ je v **Greibachové normální formě** (GNF), právě když

- \mathcal{G} je bez ε -pravidel a
- každé pravidlo z P je tvaru $A \rightarrow a\alpha$, kde $a \in \Sigma$ a $\alpha \in N^*$ (s případnou výjimkou pravidla $S \rightarrow \varepsilon$).

Věta 3.34. Každý bezkontextový jazyk lze generovat bezkontextovou gramatikou v Greibachové normální formě.

Zásobníkové automaty

Definice zásobníkového automatu

Definice 3.36. **Nedeterministický zásobníkový automat** (PushDown Automaton, PDA) je sedmice $\mathcal{M} = (Q, \Sigma, \Gamma, \delta, q_0, Z_0, F)$, kde

- Q je konečná množina, jejíž prvky nazýváme **stavy**,
- Σ je konečná množina, tzv. **vstupní abeceda**,
- Γ je konečná množina, tzv. **zásobníková abeceda**,
- $\delta : Q \times (\Sigma \cup \{\varepsilon\}) \times \Gamma \rightarrow \mathcal{P}_{Fin}(Q \times \Gamma^*)$, tzv. (parciální) **přechodová funkce**¹,
- $q_0 \in Q$ je **počáteční stav**,
- $Z_0 \in \Gamma$ je **počáteční symbol v zásobníku**,
- $F \subseteq Q$ je množina **koncových stavů**.

¹Zápis $\mathcal{P}_{Fin}(Q \times \Gamma^*)$ značí množinu všech **konečných** podmnožin množiny $Q \times \Gamma^*$.

Výpočet zásobníkového automatu

Definice 3.37. Necht' $\mathcal{M} = (Q, \Sigma, \Gamma, \delta, q_0, Z_0, F)$ je PDA.

Konfigurací nazveme libovolný prvek $(p, w, \alpha) \in Q \times \Sigma^* \times \Gamma^*$.

Na množině všech konfigurací automatu \mathcal{M} definujeme binární relaci

krok výpočtu $\vdash_{\mathcal{M}}$ takto:

$$(p, aw, Z\alpha) \vdash_{\mathcal{M}} (q, w, \gamma\alpha) \stackrel{\text{def}}{\iff} \exists(q, \gamma) \in \delta(p, a, Z) \text{ pro } a \in \Sigma \cup \{\varepsilon\}$$

Reflexivní a tranzitivní uzávěr relace $\vdash_{\mathcal{M}}$ značíme $\vdash_{\mathcal{M}}^*$.

Je-li \mathcal{M} zřejmý z kontextu, píšeme pouze \vdash resp. \vdash^* .

Akceptující výpočet zásobníkového automatu

Definice 3.37. (pokračování)

Jazyk akceptovaný PDA \mathcal{M} koncovým stavem definujeme jako

$$L(\mathcal{M}) = \{w \in \Sigma^* \mid (q_0, w, Z_0) \xrightarrow{*} (q_f, \varepsilon, \alpha), \text{ kde } q_f \in F, \alpha \in \Gamma^*\}$$

a jazyk akceptovaný PDA \mathcal{M} **prázdným zásobníkem** definujeme jako

$$L_e(\mathcal{M}) = \{w \in \Sigma^* \mid (q_0, w, Z_0) \xrightarrow{*} (q, \varepsilon, \varepsilon), \text{ kde } q \in Q\}.$$