

Automaty a gramatiky (BI-AAG)

6. Bezkontextové gramatiky

Jan Holub

Katedra teoretické informatiky
Fakulta informačních technologií
ČVUT v Praze



© Jan Holub, 2014

Bezkontextové gramatiky

- Bezkontextové gramatiky
 - Dokáží popsat převážnou většinu syntaktických struktur programovacích jazyků.
 - Jsou známy algoritmy pro efektivní analýzu věty bezkontextových jazyků.
- Syntaktická analýza:
 - Je daný řetězec w generován danou gramatikou G ?
 - Jaká je struktura tohoto řetězce?

Jednoznačné a nejednoznačné gramatiky

Definice

Bezkontextová gramatika $G = (N, T, P, S)$ je *nejednoznačná* (*víceznačná*), jestliže existuje věta $w \in L(G)$ taková, že je výsledkem nejméně dvou různých derivačních stromů. V opačném případě je gramatika *jednoznačná*.

Jednoznačné a nejednoznačné gramatiky

Příklad



$G = (\{S\}, \{a, b, \text{if}, \text{then}, \text{else}\}, P, S)$, kde P :

$S \rightarrow \text{if } b \text{ then } S \text{ else } S$

$S \rightarrow \text{if } b \text{ then } S$

$S \rightarrow a$

Gramatika je nejednoznačná: **if b then if b then a else a**



Jednoznačné a nejednoznačné gramatiky

Příklad

BG obsahuje pravidlo $A \rightarrow AA$ a proto je nejednoznačná. Pro větnou formu AAA existují dva derivační stromy.

Lze odstranit nahrazením pravidla $A \rightarrow AA$ pravidly

$$A \rightarrow AB$$

$$A \rightarrow B.$$



Jednoznačné a nejednoznačné gramatiky

- V mnoha případech lze nejednoznačnost z gramatiky odstranit.
- Inherentně (podstatně) nejednoznačné jazyky:
Nelze je generovat jednoznačnou gramatikou.
- Pro bezkontextové gramatiky nelze sestrojít algoritmus, který by rozhodl, zda daná gramatika je nejednoznačná, a vhodnou modifikací této gramatiky získat gramatiku jednoznačnou.

Příklad

$G = (\{S_1, S_2\}, \{a, b, \text{if}, \text{then}, \text{else}\}, P, S_1)$, kde P :

$S_1 \rightarrow \text{if } b \text{ then } S_1 \mid \text{if } b \text{ then } S_2 \text{ else } S_1 \mid a$

$S_2 \rightarrow \text{if } b \text{ then } S_2 \text{ else } S_2 \mid a$

Symbol **else** se vztahuje vždy k nejbližšímu předchozímu **then**.

Transformace bezkontextových gramatik

Věta

Existuje algoritmus, který určí, zda jazyk generovaný danou bezkontextovou gramatikou je prázdný. □

Algoritmus Je $L(G)$ neprázdný?

Vstup: Bezkontextová gramatika $G = (N, T, P, S)$.

Výstup: Ano, jestliže $L(G) \neq \emptyset$, ne jinak.

Metoda: Konstruujeme množiny N_0, N_1, \dots takto:

1. $N_0 = \emptyset, i := 1$
2. $N_i = \{A : A \rightarrow \alpha \in P, \alpha \in (N_{i-1} \cup T)^*\} \cup N_{i-1}$
3. Jestliže $N_i \neq N_{i-1}$, pak $i := i + 1$ a proved' (2), jinak $N_t = N_i$.
4. Jestliže $S \in N_t$, pak ano, jinak ne. □

Transformace bezkontextových gramatik

Příklad

$$G = (\{S, A, B\}, \{a, b\}, \{S \rightarrow a, S \rightarrow A, A \rightarrow AB, B \rightarrow b\}, S).$$

$$N_0 = \emptyset$$

$$N_1 = \{S, B\}$$

$$N_2 = \{S, B\}$$

$$N_1 = N_2 = N_t$$

$S \in N_t \Rightarrow$ gramatika G generuje neprázdný jazyk.

Transformace bezkontextových gramatik

Definice

Symbol $X \in N \cup T$ je *nedostupný* v bezkontextové gramatice $G = (N, T, P, S)$, jestliže X se neobjeví v žádné větné formě, tj. neexistuje derivace tvaru $S \Rightarrow^+ \alpha X \beta$, $\alpha, \beta \in (N \cup T)^*$.

Transformace bezkontextových gramatik

Algoritmus Vyloučení nedostupných symbolů.

Vstup: Bezkontextová gramatika $G = (N, T, P, S)$.

Výstup: $G' = (N', T', P', S)$ taková, že

a) $L(G') = L(G)$,

b) pro všechna $X \in N' \cup T'$ existují $\alpha, \beta \in (N' \cup T')^*$ taková, že $S \Rightarrow^* \alpha X \beta$.

Metoda:

1. $V_0 = \{S\}$ a $i := 1$.

2. $V_i = \{X : A \rightarrow \alpha X \beta \in P, A \in V_{i-1}\} \cup V_{i-1}$.

3. Jestliže $V_i \neq V_{i-1}$ pak $i := i + 1$ a proved' krok 2, jinak

$$N' = V_i \cap N,$$

$$T' = V_i \cap T,$$

$$P' = \{A \rightarrow \alpha : A \in N', \alpha \in V_i^*, A \rightarrow \alpha \in P\},$$

$$G' = (N', T', P', S)$$

Transformace bezkontextových gramatik

Příklad

$$G = (\{S, A, B\}, \{a, b\}, \{S \rightarrow a, S \rightarrow A, A \rightarrow AB, B \rightarrow b\}, S)$$

$$V_0 = \{S\}$$

$$V_1 = \{S\} \cup \{a, A\}$$

$$V_2 = \{S, A, a\} \cup \{B\}$$

$$V_3 = \{S, A, B, a, \} \cup \{b\}$$

$$V_4 = \{S, A, B, a, b\}$$

Transformace bezkontextových gramatik

Definice

Symbol $X \in N \cup T$ je *zbytečný* $G = (N, T, P, S)$, jestliže neexistuje $S \Rightarrow^* wXy \Rightarrow^* wxy$, kde $w, x, y \in T^*$.

Transformace bezkontextových gramatik

Algoritmus Vyloučení zbytečných symbolů.

Vstup: BG $G = (N, T, P, S)$, $L(G) \neq \emptyset$.

Výstup: BG $G' = (N', T', P', S)$,

a) $L(G') = L(G)$ a

b) $\forall X \in N' \cup T' \ S \Rightarrow^* \alpha X \beta$.

Metoda:

1. Pomocí algoritmu 3.6 (Je $L(G)$ prázdný?) získáme N_t .

$$G_1 = (N_t, T, P_1, S),$$

$$P_1 = \{A \rightarrow \alpha : A \in N_t, \alpha \in (N_t \cup T)^*, A \rightarrow \alpha \in P\}.$$

2. Algoritmus 3.9 (Vyloučení nedostupných symbolů) vyloučí všechny neterminální symboly z G takové, ze kterých není možno generovat terminální řetězce a poté všechny nedostupné symboly. Získáme $G' = (N', T', P', S)$.

Transformace bezkontextových gramatik

Příklad

$$G = (\{S, A, B\}, \{a, b\}, \{S \rightarrow a, S \rightarrow A, A \rightarrow AB, B \rightarrow b\}, S)$$

Krok 1.:

$$N_t = \{S, B\}$$

$$G_1 = (\{S, B\}, \{a, b\}, \{S \rightarrow a, B \rightarrow b\}, S)$$

Krok 2.:

$$V_0 = \{S\}$$

$$V_1 = \{S, a\}$$

$$V_2 = \{S, a\}$$

$$G' = (\{S\}, \{a\}, \{S \rightarrow a\}, S)$$

Transformace bezkontextových gramatik

Věta

(Věta o vyloučení pravidla, věta o dosazování).

$G = (N, T, P, S)$ je bezkontextová gramatika a

$A \rightarrow \alpha B \beta \in P, B \in N, A \neq B$ a $\alpha, \beta \in (N \cup T)^*$.

Nechť $B \rightarrow \gamma_1 \mid \gamma_2 \mid \dots \mid \gamma_k$ jsou všechna pravidla se symbolem B na levé straně v P . Nechť $G' = (N, T, P', S)$, kde

$P' = P \cup \{A \rightarrow \alpha \gamma_1 \beta \mid \alpha \gamma_2 \beta \mid \dots \mid \alpha \gamma_k \beta\} \setminus \{A \rightarrow \alpha B \beta\}$. Pak

$L(G) = L(G')$.

Transformace bezkontextových gramatik

Definice

Bezkontextová gramatika $G = (N, T, P, S)$ je *bez cyklů*, jestliže v ní není možná derivace: $A \Rightarrow^+ A$ pro nějaké $A \in N$. □

Definice

Bezkontextová gramatika $G = (N, T, P, S)$ je bez ε -pravidel, když

1. P neobsahuje žádná ε -pravidla, nebo
2. P obsahuje jediné ε -pravidlo tvaru $S \rightarrow \varepsilon$ a S se nevyskytuje na pravé straně žádného pravidla v P . □

Definice

Bezkontextová gramatika $G = (N, T, P, S)$ je *vlastní*, jestliže je bez cyklů, bez ε -pravidel a nemá zbytečné symboly. □

Transformace bezkontextových gramatik

Věta

Jestliže je bezkontextová gramatika $G = (N, T, P, S)$ bez ε -pravidel a bez jednoduchých pravidel, pak je bez cyklů. ☐

Věta

Jestliže L je bezkontextový jazyk, potom může být generován nějakou vlastní gramatikou G . ☐

Definice

Bezkontextová gramatika $G = (N, T, P, S)$ je *redukováaná*, jestliže neobsahuje zbytečné symboly. ☐

Normální tvar podle Chomského

Definice

BG $G = (N, T, P, S)$ je v normálním tvaru podle Chomského, jestliže každé pravidlo v P má jeden z následujících tvarů:

1. $A \rightarrow BC$ pro $A, B, C \in N$.
2. $A \rightarrow a$ pro $a \in T, A \in N$.
3. Jestliže $\varepsilon \in L(G)$, pak $S \rightarrow \varepsilon$ je pravidlo v P a S se nevyskytuje na pravé straně žádného pravidla. □

Normální tvar podle Chomského

Algoritmus Převod gram. do Chomského normálního tvaru

Vstup: Vlastní bezkontextová gramatika $G = (N, T, P, S)$ bez jednoduchých pravidel.

Výstup: BG $G' = (N', T, P', S)$ v Chomského normálním tvaru, $L(G) = L(G')$

Metoda:

1. $P' = \emptyset$.
2. Přidej všechna pravidla tvaru $A \rightarrow a$ z P do P' .
3. Přidej všechna pravidla tvaru $A \rightarrow BC$ z P do P' .
4. Jestliže $S \rightarrow \varepsilon$ je v P , přidej $S \rightarrow \varepsilon$ do P' .

Normální tvar podle Chomského

Algoritmus (pokračování):

5. Pro každé pravidlo tvaru $A \rightarrow X_1 X_2 \dots X_k \in P$, kde $k > 2$, přidej do P' následující pravidla (když $X_i \in N$, $X'_i = X_i$, když $X_i \in T$, X'_i je nový neterminální symbol):

$$A \rightarrow X'_1 \langle X_2 \dots X_k \rangle$$

$$\langle X_2 \dots X_k \rangle \rightarrow X'_2 \langle X_3 \dots X_k \rangle$$

$$\vdots$$

$$\langle X_{k-2} \dots X_k \rangle \rightarrow X'_{k-2} \langle X_{k-1} X_k \rangle$$

$$\langle X_{k-1} X_k \rangle \rightarrow X'_{k-1} X'_k,$$

kde každý symbol $\langle X_i \dots X_k \rangle$ je nový neterminální symbol v P .

Normální tvar podle Chomského

Algoritmus (pokračování):

6. Pro každé pravidlo tvaru $A \rightarrow X_1 X_2$, kde X_1 nebo X_2 nebo X_1 i X_2 jsou v T , přidej do P' pravidla $A \rightarrow X'_1 X'_2$.
7. Pro každý neterminální symbol a' vzniklý v krocích 5. a 6. přidej do P' pravidlo $a' \rightarrow a$. Konečně N' je sjednocení N se všemi nově vzniklými neterminálními symboly. Gramatika $G' = (N', T, P', S)$.

Normální tvar podle Chomského

Věta

Nechť L je bezkontextový jazyk. Pak L je jazyk generovaný nějakou gramatikou v Chomského normálním tvaru.

Normální tvar podle Chomského

Příklad

Vlastní BG $G = (\{S, A, B\}, \{a, b\}, P, S)$, P :

$$S \rightarrow aAB \mid BA$$

$$A \rightarrow BBB \mid a$$

$$B \rightarrow AS \mid b$$

krok 1: $A \rightarrow a$

$$B \rightarrow b$$

přidáme do P' .

krok 2: $S \rightarrow BA$

$$B \rightarrow AS$$

přidáme do P' .

krok 3: Neprovedeme nic.

krok 4: $S \rightarrow aAB \in P \Rightarrow S \rightarrow a'\langle AB \rangle$

$$\langle AB \rangle \rightarrow AB$$

přidáme do P' .

$$A \rightarrow BBB \in P \Rightarrow A \rightarrow B\langle BB \rangle$$

$$\langle BB \rangle \rightarrow BB$$

přidáme do P' .

Normální tvar podle Chomského

Příklad (pokračování)

krok 5: Nprovedeme nic.

krok 6: $a' \rightarrow a$ přidáme do P' .

$$P': S \rightarrow a' \langle AB \rangle \mid BA$$

$$A \rightarrow B \langle BB \rangle \mid a$$

$$B \rightarrow AS \mid b$$

$$\langle AB \rangle \rightarrow AB$$

$$\langle BB \rangle \rightarrow BB$$

$$a' \rightarrow a$$

$$N' = N \cup \{ \langle AB \rangle, \langle BB \rangle, a' \}$$

Normální tvar podle Chomského

Algoritmus Cocke-Younger-Kasami (CYK) algorithm

Vstup: Bezkontextová gramatika $G = (N, T, P, S)$

v Chomského normálním tvaru, $X \in T^*$

Výstup: Odpověď, zda $X \in L(G)$

Metoda: $X = \{x_1, x_2, \dots, x_n\}$

1. Inicializuj pole $P[n, n]$ na \emptyset .
2. Pro každé $i = 1..n$ a pro každé pravidlo $A \rightarrow t_i$ nastav
 $P[i, 1] := P[i, 1] \cup \{A\}$
3. Pro každé $i = 2..n$ udělej (délka řetězce)
 Pro každé $j = 1..n - i + 1$ udělej (pozice v textu)
 Pro každé $k = 1..i - 1$ udělej (délka gen. řetězce)
 Jestliže $B \in P[j, k]$, $C \in P[j + k, i - k]$ a $A \rightarrow BC$
 pak $P[j, i] := P[j, i] \cup \{A\}$
4. Jestliže $S \in P[1, n]$, pak $X \in L(G)$,
 jinak, $X \notin L(G)$.

Normální tvar podle Chomského

Příklad

Text $aaba$ a BG $G = (\{S, A, B, C\}, \{a, b\}, P, S)$, P :

$$S \rightarrow AB \mid BC$$

$$A \rightarrow BA \mid a$$

$$B \rightarrow CC \mid b$$

$$C \rightarrow AB \mid a$$

4

3

2

1

$a \quad a \quad b \quad a$

Normální tvar podle Chomského

Věta

Je-li $G = (N, T, P, S)$ bezkontextová gramatika a $X \in T^*$ řetězec délky n , pak lze zjistit zda $X \in L(G)$ v čase $\mathcal{O}(n^3)$.

Normální tvar podle Greibachové

Definice

Neterminální symbol A v BG $G = (N, T, P, S)$ nazveme *rekurzivní*, jestliže existuje derivace $A \Rightarrow^+ \alpha A \beta$ pro nějaké α a $\beta \in (N \cup T)^*$.

Jestliže $\alpha = \varepsilon$, pak A nazveme *symbol rekurzivní zleva*, podobně jestliže $\beta = \varepsilon$, pak A nazveme *symbol rekurzivní zprava*.

Gramatiku s alespoň jedním neterminálním symbolem rekurzivním zleva (zprava) nazveme *rekurzivní zleva (zprava)*.

Gramatiku, ve které je alespoň jeden neterminální symbol rekurzivní, nazveme *rekurzivní*.

Normální tvar podle Greibachové

Věta

(O vyloučení rekurzivity zleva z jednotlivých pravidel).

Nechť $G = (N, T, P, S)$ je bezkontextová gramatika, ve které

$$A \rightarrow A \alpha_1 \mid A \alpha_2 \mid \dots \mid A \alpha_m \mid \beta_1 \mid \beta_2 \mid \dots \mid \beta_n$$

jsou všechna pravidla v P s neterminálním symbolem A na levé straně a žádné $\beta_i, i = 1, 2, \dots, n$, nezačíná symbolem A .

Nechť $G' = (N \cup \{A'\}, T, P', S)$ je bezkontextová gramatika, kde P' je množina P , ve které pravidla uvedená výše jsou nahrazena pravidly:

$$A \rightarrow \beta_1 \mid \beta_2 \mid \dots \mid \beta_n \mid \beta_1 A' \mid \beta_2 A' \mid \dots \mid \beta_n A'$$

$$A' \rightarrow \alpha_1 \mid \alpha_2 \mid \dots \mid \alpha_m \mid \alpha_1 A' \mid \alpha_2 A' \mid \dots \mid \alpha_m A',$$

kde A' je nový neterminální symbol, který není v N . Pak

$$L(G') = L(G).$$

Normální tvar podle Greibachové

Příklad

$G = (\{E, T, F\}, \{+, *, (,), a\}, P, E), P:$

$E \rightarrow E + T \mid T$

$T \rightarrow T * F \mid F$

$F \rightarrow (E) \mid a.$

Odstraníme levou rekurzi:

$E \rightarrow T \mid TE'$

$E' \rightarrow +T \mid +TE'$

$T \rightarrow F \mid FT'$

$T' \rightarrow *F \mid *FT'$

$F \rightarrow (E) \mid a$

$G' = (\{E, E', T', T, F\}, \{+, *, (,), a\}, P', E), P'$ je množina pravidel uvedených výše.

Normální tvar podle Greibachové

Definice

Bezkontextová gramatika G je v normálním tvaru podle Greibachové, jestliže G je bez ε -pravidel a každé pravidlo, které neobsahuje prázdný řetězec na pravé straně, má tvar $A \rightarrow a\alpha$, kde $a \in T$, $\alpha \in N^*$. \square

Normální tvar podle Greibachové

Algoritmus Vyloučení rekurzivity zleva.

Vstup: Vlastní bezkontextová gramatika $G = (N, T, P, S)$ bez jednoduchých pravidel.

Výstup: BG G' bez rekurzivity zleva, $L(G) = L(G')$.

Metoda:

1. Zvolíme uspořádání $N = \{A_1, \dots, A_r\}$: $A_i \rightarrow \alpha$, α začíná buď terminálním symbolem nebo neterminálním symbolem A_j pro $j \geq i$.
Položme $i := 1$.

Normální tvar podle Greibachové

Algoritmus (pokračování):

2. Všechna pravidla $A_i \rightarrow A_i\alpha_1 \mid \dots \mid A_i\alpha_m \mid \beta_1 \mid \dots \mid \beta_n$ z P s neterminálním symbolem A_i na levé straně, kde žádné β_j nezačíná neterminálním symbolem A_k pro $k \leq i$, nahradíme tato pravidla pravidly:
 $A_i \rightarrow \beta_1 \mid \dots \mid \beta_n \mid \beta_1 A'_i \mid \dots \mid \beta_n A'_i$,
 $A'_i \rightarrow \alpha_1 \mid \dots \mid \alpha_m \mid \alpha_1 A'_i \mid \dots \mid \alpha_m A'_i$, kde A'_i je nový neterminální symbol.
3. Jestliže $i = r$, máme výslednou gramatiku G' a končíme, jinak $i := i + 1$ a $j := 1$.
4. Jestliže pro neterminální symbol A_j existují pravidla $A_j \rightarrow \beta_1 \mid \dots \mid \beta_m$, pak nahradíme všechna pravidla tvaru $A_i \rightarrow A_j\alpha$ pravidly $A_i \rightarrow \beta_1\alpha \mid \dots \mid \beta_m\alpha$.
5. Jestliže $j = i - 1$, jdi na krok 2., jinak polož $j := j + 1$ a jdi na krok 4.

Normální tvar podle Greibachové

Věta

Každý bezkontextový jazyk může být generován gramatikou, která neobsahuje rekurzivitu zleva.



Normální tvar podle Greibachové

Příklad

$G = (\{A, B, C\}, \{a, b\}, P, A), P:$

$A \rightarrow BC \mid a$

$B \rightarrow CA \mid Ab$

$C \rightarrow AB \mid CC \mid a$. Aplikujme algoritmus 3.28 na tuto gramatiku.

Položme $A_1 = A, A_2 = B, A_3 = C$.

Krok 2: ($i = 1$) beze změn.

Krok 4: ($i = 2, j = 1$)

Po dosazení za A dostaneme pro B pravidla: $B \rightarrow CA \mid BCb \mid ab$.

Krok 2: Odstraníme rekurzivitu zleva u symbolu B :

$B \rightarrow CA \mid ab \mid CA B' \mid abB'$

$B' \rightarrow CbB' \mid Cb$

Krok 4: ($i = 3, j = 1$)

$C \rightarrow BCB \mid aB \mid CC \mid a$

Normální tvar podle Greibachové

Příklad (pokračování)

Krok 4: ($i = 3, j = 2$)

$$C \rightarrow CACB \mid abCB \mid CAB'CB \mid abB'CB \mid aB \mid CC \mid a$$

Krok 2: ($i = 3$)

$$C \rightarrow abCB \mid abB'CB \mid aB \mid a \mid abCBC' \mid abB'CBC' \mid aBC' \mid aC'$$

$$C' \rightarrow ACBC' \mid AB'CBC' \mid CC' \mid ACB \mid AB'CB \mid C$$

Výsledná gramatika je $G' = (\{A, B, C, B', C'\}, \{a, b\}, P', A)$,
kde P' obsahuje pravidla:

$$A \rightarrow BC \mid a$$

$$B \rightarrow CA \mid ab \mid CAB' \mid abB'$$

$$B' \rightarrow CbB' \mid Cb$$

$$C \rightarrow abCB \mid abB'CB \mid aB \mid a \mid abCBC' \mid abB'CBC' \mid aBC' \mid aC'$$

$$C' \rightarrow ACBC' \mid AB'CBC' \mid CC' \mid ACB \mid AB'CB \mid C$$