

Bezkontextové gramatiky

Def. **BKG**: $G = (N, T, P, S)$ kde

1. N je množina neterminálních symbolů,
2. T " " terminálních " ,
3. $S \in N$ je počáteční symbol,
4. P je množina přepisovacích pravidel tvaru
 $A \rightarrow \alpha$, kde $A \in N$, $\alpha \in (N \cup T)^*$

Bezkontextový jazyk

Def. **BKL**: $L(G) = \{ w : S \Rightarrow^* w, w \in T^* \}$

Tj. $L(G)$ je množina řetězců derivovatelných z S

Úmluva pro zjednodušení zápisů:

- a, b, c, \dots představují terminální symboly
 A, B, C, \dots " " neterminální "
 X, Y, Z, \dots " " $N \cup T$
 $\alpha, \beta, \gamma, \dots$ " " řetězce z $N \cup T$
 u, v, z, \dots " " z terminálních symbolů
 e představuje prázdný řetězec

- **DERIVACE** řetězce α je posloupnost kroků odvození α pomocí přepisovacích pravidel gramatiky

$$S = \alpha_1 \Rightarrow \alpha_2 \Rightarrow \dots \Rightarrow \alpha_n = \alpha$$

Dtto $S \Rightarrow^* \alpha$ pozn.: \Rightarrow^* je uzávěr relace \Rightarrow

- **PŘÍMÁ DERIVACE** $\alpha A \beta \Rightarrow \alpha \gamma \beta$, kde $A \rightarrow \gamma \in P$

- **DERIVAČNÍ STROM** je grafickým vyjádřením derivace (struktury) řetězce. Kořenem je počáteční symbol, uzly jsou prvky $N \cup T$, listy jsou prvky T , větve z uzlu A vedou do uzlů, které zleva doprava tvoří řetězec α , který je pravou stranou pravidla $A \rightarrow \alpha$

Př. **G[E]**

$E \rightarrow T \mid E + T$
 $T \rightarrow F \mid T * F$
 $F \rightarrow (E) \mid i$

Vytvořte derivační strom a derivaci věty např. $i + i * i$ (na tabuli)

Vztah derivace a derivačního stromu: derivaci odpovídá jeden strom, jednomu stromu odpovídá více derivací.

- **KANONICKÉ DERIVACE**

- **Levá derivace** -expanduje vždy nejlevější neterminál
- **Pravá derivace** -expanduje vždy nejpravější neterminál

Př. levá a pravá derivace věty $i + i * i$ na tabuli

- **VĚTNÁ FORMA**

Def.: Řetězec α se nazývá větnou formou v gramatice G , s počátečním symbolem S , platí-li:

$$S \Rightarrow^* \alpha, \text{ kde } \alpha \in (N \cup T)^*$$

- **VĚTA**

Def.: Řetězec α se nazývá větou v gramatice G , s počátečním symbolem S , platí-li:

$$S \Rightarrow^* \alpha, \text{ kde } \alpha \in T^*$$

- **FRÁZE**

Def.: Necht' $\lambda = \alpha \beta \gamma$ je větná forma v gramatice G . Podřetězec β se nazývá frází větné formy λ vzhledem k neterminálnímu symbolu A , platí-li

$$S \Rightarrow^* \alpha A \gamma \quad \text{a} \quad A \Rightarrow^* \beta$$

Tzn. frázi tvoří listy podstromu derivačního stromu.

- **JEDNODUCHÁ FRÁZE** větné formy $\alpha A \gamma$ vzhledem k neterm. A je podřetězec β , platí-li

$$S \Rightarrow^* \alpha A \gamma \quad \text{a} \quad A \Rightarrow \beta$$

- **L-FRÁZE**

je nejlevější jednoduchou frází

Př.

Najdi fráze, jednoduché fráze a l-frázi větné formy i^*i+i v $G[E]$ (na tabuli)

Problémy analýzy při konstrukci derivačního stromu:

1. (shora dolů) Kterou z pravých stran vybrat k derivování
2. (zdola nahoru) Jak vymezit l-frázi a na co ji redukovat

řešení: -bud' analýza s návratem (neefektivní, složitost kubická)

-nebo deterministická analýza (jen pro některé, druhy BKG)

Víceznačnost gramatik

Def. Věta generovaná gramatikou G je víceznačná, existují-li alespoň dva různé derivační stromy této věty.
 G pak rovněž nazýváme víceznačnou.

Př. Jazyk $\{ a^m c a^n ; m, n \geq 0 \}$

je generován gramatikou $S \rightarrow aS \mid Sa \mid c$

-Je věta $aaca$ jednoznačná? jak vypadá strom, je jen jeden?

-Může pro nejednoznačnou gramatiku existovat ekvivalentní jednoznačná gramatika? Může: $S \rightarrow aS \mid Z$
 $Z \rightarrow Za \mid c$

Př. $G[E] \quad E \rightarrow E + E \mid E * E \mid i$

-Jaké jsou důsledky v generovaném jazyce ?

Věta: Nutnou podmínkou jednoznačnosti gramatiky je, aby pro žádný neterminální symbol neexistovalo jak pravidlo rekurzivní zprava, tak i pravidlo rekurzivní zleva.

Problém nejednoznačnosti bezkontextových jazyků je algoritmicky nerozhodnutelný. Tzn. je dokázáno, že nikdy nebude existovat pro takový problém algoritmus.

Př. Syntaktický tvar podmíněného příkazu:

$S \rightarrow a S b S \mid a S \mid c$

-Je $G[S]$ víceznačná ?

$S_1 \rightarrow a S_2 b S_1 \mid a S_1 \mid c$
 $S_2 \rightarrow a S_2 b S_2 \mid c$

Gramatika je také, víceznačná, existují-li v G pro rekurzivní neterm. symbol A alespoň 2 rekurzivní pravidla, z nichž jedno je rekurzivní zprava (zleva) a má shodný prefix (postfix) rekurzivního symbolu A s druhým pravidlem.

Jazyky, které nelze generovat jednoznačnou gramatikou se nazývají inherentně nejednoznačné.

Úpravy gramatik

Odstranění zbytečných symbolů

Zbytečný je takový symbol X , který buď (1.) je-li neterminální z něj nelze generovat terminální řetězec, nebo (2.) at' je terminální či neterminální, je nedosažitelný z S .

$$\underbrace{S \Rightarrow^* w X y}_{2.} \xrightarrow{1.} \Rightarrow^* w x y, \text{ kde } w, x, y \in T^*$$

Postup při eliminaci zbytečných symbolů

1. a) Označíme všechny $X \in T$.
b) Označíme všechny $X \in N$, pro něž existuje X -pravidlo, jehož pravá strana neobsahuje neoznačený symbol.
c) Opakujeme krok b), dokud přibývá označených symbolů.
d) Neoznačené symboly jsou zbytečné.
2. a) Označíme počáteční symbol S .
b) Označíme všechny symboly z pravých stran pravidel s označeným levostranným symbolem.
c) Opakujeme krok b), dokud přibývá označených symbolů.
d) Neoznačené symboly jsou zbytečné.

! záleží na pořadí kroků 1. a 2. !

Př. $G[S]: S \rightarrow a \mid A \quad A \rightarrow A B \quad B \rightarrow b$

Odstranění prázdných pravidel

Gramatika G je bez prázdných pravidel, jestliže buď neobsahuje žádné pravidlo $A \rightarrow e$, nebo obsahuje jedině takové pravidlo tvaru $S \rightarrow e$ a S se nevyskytuje na pravé straně žádného pravidla v G .

Postup při odstranění prázdných pravidel

1. Označíme všechny symboly X , pro něž existuje pravidlo s prázdnou pravou stranou.
2. Označíme všechny symboly X , pro něž existuje pravidlo s pravou stranou obsahující pouze označené symboly.
3. Opakujeme 2 dokud přibývá označených symbolů.
4. Takto získanou množinu označíme N_e .
5. Každé pravidlo gramatiky mající na pravé straně jeden či více symbolů z N_e , nahradíme množinou pravidel vzniklých všemi možnými způsoby vypuštění v pravých stranách symbolů z N_e . Případně vznikající pravidla tvaru $X \rightarrow e$ do výsledné gramatiky nezařazujeme.
6. Obsahuje-li N_e počáteční symbol S , vytvoříme nový počáteční symbol S' s pravidly
 $S' \rightarrow e$
 $S' \rightarrow S$

(Gramatika bez prázdných pravidel je nezkracující, větné formy při derivování se nezkracují)

Př. Na tabuli. Odstraňte prázdná pravidla z $G[S]: S \rightarrow a S b S \mid e$

Výsledek: $S' \rightarrow S \mid e$
 $S \rightarrow a S b S \mid a b S \mid a S b \mid a b$

Odstranění jednoduchých pravidel

Jednoduchá pravidla mají tvar $A \rightarrow B$, kde $A, B \in N$

Odstranění = žádný problém = nahradíme $A \rightarrow B$ všemi možnými pravidly vzniklými záměnou B za pravé strany B -pravidel

Př. Zkusme pro $G[E]$ na tabuli

Odstranění cyklů

$A \Rightarrow^* A$ implikuje existenci jednoduchých pravidel

Cyklus je evidentní nešvar. Proč?

Cykly eliminujeme odstraněním jednoduchých pravidel.

Odstranění libovolného pravidla

Necht' chceme z G odstranit pravidlo $A \rightarrow \alpha B \beta$. Musíme proto místo něj dát do G všechna pravidla tvaru $A \rightarrow \alpha \gamma \beta$, kde γ jsou pravé strany B pravidel.

Př. V G s pravidly $A \rightarrow a A A \mid b$ odstranit pravidlo $A \rightarrow a A A$

Na tabuli:

Výsledek: $A \rightarrow a a A A A \mid a b A \mid b$

Upravená gramatika

neobsahuje cykly, e-pravidla a zbytečné symboly

Odstranění levé rekurze

(Greibachové normální forma: Vpravo strany začínají terminálem)

Levorekurzivní gramatiku nelze použít k analýze shora dolů

Odstranění pravidla rekurzivního zleva:

Necht' je dána BKG $G = (N, T, P, S)$, 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 A pravidla v P a žádné, z β nezačíná A .

Pak $G' = (N \cup \{A'\}, T, P', S)$, kde P' obsahuje místo uvedených pravidel pravidla:

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

je ekvivalentní s gramatikou G

Levou rekurzi nahradíme pravou, jak je zřejmé z obr.



Př.a) $G[E]$ na tabuli.


$E \rightarrow E + T$	T
$T \rightarrow T * F$	F
$F \rightarrow (E)$	i

? proč nepoužijeme $E \rightarrow T + E$

Alternativa odstranění s kratším výsledkem:

Ekvivalentní bude jak vidno z obr. i gramatika s pravidly

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



Př.b) G[E] na tabuli.

$E \rightarrow E + T$		T
$T \rightarrow T * F$		F
$F \rightarrow (E)$		i

Pro pohodlné:

Výsledek př.a)

$E \rightarrow T \mid T E'$
$E' \rightarrow +T \mid + T E'$
$T \rightarrow F \mid F T'$
$T' \rightarrow * F \mid * F T'$
$F \rightarrow (E) \mid i$

výsledek př.b)

$E \rightarrow T E'$
$E' \rightarrow + T E' \mid e$
$T \rightarrow F T'$
$T' \rightarrow * F T' \mid e$
$F \rightarrow (E) \mid i$

Odstranění levé rekurze (včetně nepřímé rekurze):

- Zvolíme uspořádání na $N = \{A_1, A_2, \dots, A_n\}$ tak, aby:
 - je-li $A_i \rightarrow \alpha$ pravidlo, jehož pravá strana začíná neterminálním symbolem A_j , pak $j > i$.
 - Přiřadme $i = 1$
- Odstraníme přímou levou rekurzi u A_i pravidel (postup viz výše)
- Je-li $i = n$, pak jsme získali výslednou G' a skonči
 - Jinak přiřad' $i = i + 1$; $j = 1$
- Každé, pravidlo tvaru $A_i \rightarrow A_j \gamma$ nahrad' pravidly
 - $A_i \rightarrow \alpha_1 \gamma \mid \alpha_2 \gamma \mid \dots \mid \alpha_p \gamma$, kde
 - $A_j \rightarrow \alpha_1 \mid \alpha_2 \mid \dots \mid \alpha_p$ jsou všechna A_j pravidla
- Je-li $j = i - 1$ jdi na krok 2., jinak $j = j + 1$ a jdi na 4.

Př. na tabuli s použitím kratší alt.: $A \rightarrow B C \mid a$
 $B \rightarrow C A \mid A b$
 $C \rightarrow A B \mid C C \mid a$


- Zvolíme uspořádání $A_1 = A < A_2 = B < A_3 = C$ a přiřadíme $i=1$
- Odstaníme případnou levou rekurzi u A_1 pravidel (žádná tam není)
 - Proto do výsledku jdou pravidla $A \rightarrow B C \mid a$
- $i \neq n$, proto $i=2$ a $j=1$
- Vnutíme uspořádání B pravidlům: $B \rightarrow C A \mid B C b \mid a b$
- $j = i-1$ proto dělej bod 2.
- Teď z nich odstraníme přímou levou rekurzi. Do výsledku jde:
 - $B \rightarrow C A B' \mid a b B'$ $B' \rightarrow C b B' \mid e$
- $i \neq n$, proto $i=3$ a $j=1$
- Vnutíme uspořádání C pravidlům s ohledem na A:
 - $C \rightarrow B C B \mid a B \mid C C \mid a$
- $j \neq i-1$ proto $j = 2$ a dělej znovu bod 4.
- Vnutíme uspořádání C pravidlům i vzhledem k B:
 - $C \rightarrow C A B' C B \mid a b B' C B \mid a B \mid C C \mid a$
- $j = i-1$ proto dělej bod 2 a do výsledku půjde:
 - $C \rightarrow a b B' C B C' \mid a B C' \mid a C'$
 - $C' \rightarrow A B' C B C' \mid C C' \mid e$
- Konec

Zásobníkové automaty

ZA je abstraktní model syntaktického analyzátoru BK jazyků

Obecně je:

- jednocestný,
- nedeterministický,
- s nekonečnou pamětí (zásobníkem)



Definice:

ZA $\mathcal{P} = (Q, \Sigma, \Gamma, \delta, q_0, Z_0, F)$

1 2 3 4 5 6 7

1. Konečná množina stavů
2. Konečná vstupní abeceda
3. Konečná abeceda zásobníkových symbolů
4. Zobrazení $\delta: Q \times (\Sigma \cup \{e\}) \times \Gamma \rightarrow 2^{Q \times \Gamma^*}$
5. Počáteční stav řadiče $q_0 \in Q$
6. Dno zásobníku $Z_0 \in \Gamma$
7. Množina koncových stavů $F \subset Q$

Konfigurace ZA $(q, w, \alpha) \in Q \times \Sigma^* \times \Gamma^*$

Stav řadiče

Dosud nepřečtený vstup

Obsah zásobníku

Pozn.: Je to akceptační automat, ne překladový.

Přechod ZA je binární relace \vdash nad množinou konfigurací, nebo její p-tou mocninou \vdash_p či uzávěrem \vdash^* a \vdash_+

$(q, aw, \alpha\beta) \vdash (p, w, \gamma\beta)$ jestliže $\delta(q, a, \alpha)$ obsahuje (p, γ) , $a \in \Sigma \cup \{e\}$, $\alpha, \beta, \gamma \in \Gamma^*$

Př. na tabuli. Popsat \mathcal{P} akceptující $L = \{0^n 1^n\}$ kde $n \geq 0$

Počáteční konfigurace ZA je (q_0, w, Z_0) , kde $w \in \Sigma^*$

Interpretace zápisu přechodové fce

$$\delta(q, a, b) = \{ (p_1, \gamma_1), (p_2, \gamma_2), \dots, (p_n, \gamma_n) \}$$

ZA ve stavu q , se vstupním symbolem a , vrcholovým řetězcem zásobníku b , přejde do některého ze stavů p_i a vrchol α nahradí příslušným řetězcem $\gamma_i \in \Gamma^*$.

Přechod bez čtení vstupního symbolu (e-přechod)

$$\delta(q, e, \alpha) = \{ (p_1, \gamma_1), (p_2, \gamma_2), \dots, (p_n, \gamma_n) \}$$

Def.

Rozšířený ZA (RZA) je sedmice $\mathcal{P} = (Q, \Sigma, \Gamma, \delta, q_0, Z_0, F)$

kde $\delta: Q \times (\Sigma \cup \{e\}) \times \Gamma^* \rightarrow Q \times \Gamma^*$

tj. reaguje na vrcholové řetězce zásobníku

Př. popsat \mathcal{P} akceptující $L = \{ w w^R \}$ kde $w \in \{a, b\}^*$

R má význam „reverzní“

$$\mathcal{P} = (\{q, p\}, \{a, b\}, \{a, b, s, Z\}, \delta, q, Z, \{p\})$$

$$\delta(q, a, e) = \{(q, a)\}$$

$$\delta(q, b, e) = \{(q, b)\}$$

$$\delta(q, e, e) = \{(q, s)\} \text{ to je e-přechod, vloží střed } s$$

$$\delta(q, e, aSa) = \{(q, s)\} \text{ to je e-přechod}$$

$$\delta(q, e, bSb) = \{(q, s)\} \text{ to je e-přechod}$$

$$\delta(q, e, ZS) = \{(p, e)\}$$

Např akceptace věty abba

$$\begin{aligned} & (q, abba, Z) \vdash (q, bba, Za) \vdash (q, ba, Zab) \vdash (q, ba, ZabS) \\ & \vdash (q, a, ZabSb) \vdash (q, a, ZaS) \vdash (q, e, ZaSa) \vdash (q, e, ZS) \\ & \vdash (p, e, e) \end{aligned}$$

Def.

Věta w jazyka může být akceptována zásobníkovým automatem

$\mathcal{P} = (Q, \Sigma, \Gamma, \delta, q_0, Z_0, F)$ dvojím způsobem:

a) přechodem do koncového stavu

$$L(\mathcal{P}) = \{ w: (q_0, w, Z_0) \vdash^* (q, e, \gamma), \gamma \in \Gamma^*, q \in F, w \in \Sigma^* \}$$

b) s prázdným zásobníkem

$$L_e(\mathcal{P}) = \{ w: (q_0, w, Z_0) \vdash^* (q, e, e), q \in Q, w \in \Sigma^* \}$$

Vztah bezkontextových gramatik a zásobníkových automatů

Pro danou BKG $G = (N, T, P, S)$ můžeme sestrojít Z A \mathcal{P} takový, že $L(G) = L(\mathcal{P})$. Platí to i opačně.

A.

Konstrukce ZA, který je modelem syntaktické analýzy metodou shora dolů.

$\mathcal{P} = (\{q\}, T, N \cup T, \delta, s, \emptyset)$, kde δ je definováno takto:

1. $\delta(q, e, A) = \{ (q, \alpha) : A \rightarrow \alpha \in P \}$ pro $\forall A \in N$,
2. $\delta(q, a, a) = \{ (q, e) \}$ pro $\forall a \in T$.

Operaci 1. nazýváme **expanzí** (nahradí na vrcholu zásobníku a tím i ve větě formě neterminální symbol některou jeho pravou stranou).

Operaci 2. nazýváme **srovnáním** (čteného vstupního symbolu a symbolu z vrcholu zásobníku).

Tento ZA má vrchol zásobníku vždy vlevo.

Př. Zapsat \mathcal{P} pro $G[E]$ (na tabuli)

$\mathcal{P} = (\{q\}, \{ (,), +, *, a \}, \{ E, T, F, (,), +, *, a \}, \delta, q, E, \emptyset)$
 $\delta(q, e, E) = \{ (q, E+T), (q, T) \}$
 $\delta(q, e, T) = \{ (q, T*F), (q, F) \}$
 $\delta(q, e, F) = \{ (q, (E)), (q, a) \}$
 $\delta(q, a', a') = \{ (q, e) \}$ pro $\forall a' \in \{ (,), +, *, a \}$

Např. zpracování věty $a+a$

Tady je vrchol zásobníku

$(q, a+a, E) \vdash (q, a+a, E+T) \vdash (q, a+a, T+T)$ to jsou expanze
 $\vdash (q, a+a, F+T) \vdash (q, a+a, a+T)$ teď provedeme 2krát srovnání
 $\vdash (q, +a, +T) \vdash (q, a, T)$ a opět expandujeme
 $\vdash (q, a, F) \vdash (q, a, a)$ a naposledy srovnáme $\vdash (q, e, e)$

Zásobník je po přečtení vstupního řetězce prázdný, takže řetězec byl akceptován

B.

Konstrukce ZA, který je modelem syntaktické analýzy metodou zdola nahoru.

$P = (\{q, r\}, T, N \cup T \cup \{#\}, \delta, q, \#, \{r\})$, kde δ je definováno takto:

1. $\delta(q, a, e) = \{ (q, a) \}$ pro $\forall a \in T$,
2. $\delta(q, e, \alpha) = \{ (q, A) : A \rightarrow \alpha \in P \}$,
3. $\delta(q, e, \#S) = \{ (r, e) \}$.

Operaci 1. nazýváme přesun (přesun vstupního symbolu na vrchol zásobníku).

Operaci 2. nazýváme redukce (náhrada pravé strany pravidla na vrcholu zásobníku a tím i ve větě formě stranou levou).

Operace 3. je přijetí.

Tento ZA má vrchol zásobníku vpravo.

Konfiguraci budeme zapisovat ve tvaru: (stav, zásobník, vstup). Zřetězením stavu zásobníku se zbytkem vstupu pak uvidíme jednotlivé větné formy

Př. Zapsat \mathcal{P} pro $G[E]$ (na tabuli)

$$\begin{aligned} \mathcal{P} = & (\{q, r\}, \{ (,), +, *, a \}, \{ \#, E, T, F, (,), +, *, a \}, \delta, q, \#, r) \\ & \delta(q, a', e) = \{ (q, a') \} \quad \text{pro } \forall a \in T, \\ & \delta(q, e, E+T) = \{ (q, E) \} \\ & \delta(q, e, T) = \{ (q, E) \} \\ & \delta(q, e, T*F) = \{ (q, T) \} \\ & \dots \\ & \delta(q, e, \#E) = \{ (r, e) \} \end{aligned}$$

Např. zpracování věty $a+a$

$$\begin{aligned} & (q, \#, a+a) \mid (q, \#a, +a) \mid (q, \#F, +a) \mid (q, \#T, +a) \\ & \mid (q, \#E, +a) \mid (q, \#E+, a) \mid (q, \#E+a, e) \mid (q, \#E+F, e) \\ & \mid (q, \#E+T, e) \mid (q, \#E, e) \mid (r, e, e) \end{aligned}$$

ZA konstruované dle A. i B. jsou obecně nedeterministické (nepoužitelné pro SA). Pro konstrukci SA lze použít buď:

- a) Deterministickou simulaci nedeterministického ZA = algoritmus syntaktické analýzy s návraty.
- b) Zdokonalit konstrukci ZA tak, aby byl pro určitou třídu BKG deterministický.

Pozn.: Obsah zásobníku zřetězený se zbytkem vstupu je větnou formou.