

## 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

$\epsilon$  představuje prázdný řetězec

- DERIVACE řetězce  $\alpha$  je posloupnost kroků odvození  $\alpha$  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  $\alpha$ , 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

- KANONICKÁ DERIVACE

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

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

- VĚTNÁ FORMA

Def.: Řetězec  $\alpha$  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  $\alpha$  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  $\beta$  se nazývá frází větné formy  $\lambda$  vzhledem k neterminálnímu symbolu  $A$ , platí-li

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

- JEDNODUCHÁ FRÁZE větné formy  $\alpha A \gamma$  vzhledem k neterm.  $A$  je podřetězec  $\beta$ , 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 ?

-Může pro nejednoznačnou gramatiku existovat ekvivalentní jednoznačná gramatika?

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

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 je buď nedosažitelný z  $S$ , nebo (je-li neterminální) z něj nelze generovat terminální řetězec.

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

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.

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.

! na pořadí kroků !

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 jediné 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 nezahrnujeme.

6. Obsahuje-li  $N_e$  počáteční symbol  $S$ , vytvoříme nový počáteční symbol  $S'$  s pravidly

$$\begin{array}{l} S' \rightarrow e \\ a \quad S' \rightarrow S \end{array}$$

(Gramatika bez prázdných pravidel je nezkracující)  
Př. Na tabuli. Odstraňte prázdná pravidla z  $G[S]: S \rightarrow a S b S \mid e$

### 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?  
Odstraníme jednoduchá pravidla.

### 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  $\gamma$  jsou pravé strany B pravidel.  
Př. V  $G$  s pravidly  $A \rightarrow a A A \mid b$  odstranit pravidlo  $A \rightarrow a A A$

### Upravená gramatika

neobsahuje cykly, e-pravidla a zbytečné symboly

## Odstranění levé rekurze

(Greibachově 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  $\beta$  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  $G$



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 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):

1. 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  $i = 1$

2. Odstraníme přímou levou rekurzi u  $A_i$  pravidel (postup viz výše)

3. Je-li  $i = n$ , pak jsme získali výslednou  $G'$  a skonči

Jinak přiřad'  $i = i + 1$ ;  $j = 1$

4. 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

5. Je-li  $j = i - 1$  jdi na krok 2., jinak  $j = j + 1$  a jdi na 4.

Př. na tabuli  $A \rightarrow B C \mid a$   
 $B \rightarrow C A \mid A b$   
 $C \rightarrow A B \mid CC \mid a$





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  $a$  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“

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 ZA  $\mathcal{P}$  takový, že  $L(G) = L(\mathcal{P})$ . Platí i opačně.

A.

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

$\mathcal{P} = ( \{q\}, T, N \cup T, \delta, S, \phi )$ , kde  $\delta$  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)

B.

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

$\mathcal{P} = ( \{q, r\}, T, N \cup T \cup \{\#\}, \delta, q, \#, \{r\} )$ , kde  $\delta$  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.

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

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.

? Co představuje obsah zásobníku zřetězený s ještě nezpracovanou částí vstupního řetězce?