

Bezkontextové gramatiky

Definice: **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

Definice: **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

ϵ 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: -buď analýza s návratem (neefektivní složitost)

-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 (získání redukované gramatiky)

Zbytečný je takový symbol X , který buď (1.) je-li neterminální z něj nelze generovat terminální řetězec, nebo (2.) ať 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 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 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 nevypouštějící = 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:

$$\begin{array}{l} A \rightarrow \beta_1 \mid \beta_2 \mid \dots \mid \beta_n \mid \beta_1 A' \mid \beta_2 A' \mid \dots \mid \beta_n A' \\ A' \rightarrow \alpha_1 \mid \alpha_2 \mid \dots \mid \alpha_m \mid \alpha_1 A' \mid \alpha_2 A' \mid \dots \mid \alpha_m A' \end{array}$$

je ekvivalentní s gramatikou G

Levou rekurzi nahradíme pravou, jak je zřejmé z obr.




Př.a) $G[E]$ na tabuli. $E \rightarrow E + T \mid T$
 $T \rightarrow T * F \mid F$
 $F \rightarrow (E) \mid i$

?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.

$$E \rightarrow E + T \mid T$$

$$T \rightarrow T * F \mid F$$

$$F \rightarrow (E) \mid i$$

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.:
 $A \rightarrow B C \mid a$
 $B \rightarrow C A \mid A b$
 $C \rightarrow A B \mid C C \mid a$

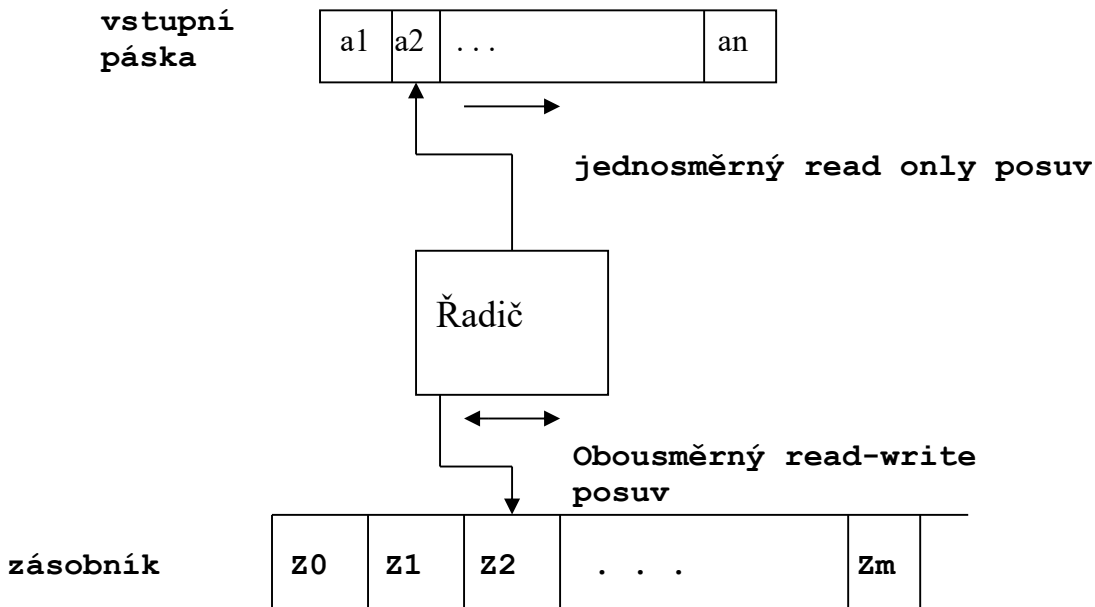
- Zvolíme uspořádání $A_1 = A < A_2 = B < A_3 = C$ a přiřadíme $i=1$
- Odstaníme případnou levou rekurzi u A_1 pravidel (žádná tam není)
 Proto do výsledku jdou pravidla $A \rightarrow B C \mid a$
- $i \neq n$, proto $i=2$ a $j=1$
- Vnutíme uspořádání B pravidlům: $B \rightarrow C A \mid B C b \mid a b$
- $j = i-1$ 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 q

Dosud nepřečtený vstup w

Obsah zásobníku α

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

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

ZA ve stavu q , se vstupním symbolem a , vrcholovým řetězcem zásobníku α , 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“

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

$\delta(q, a, \epsilon)$	=	$\{(q, a)\}$		$\delta(q, a, -)$
$\delta(q, b, \epsilon)$	=	$\{(q, b)\}$		$\delta(q, b, -)$
$\delta(q, e, \epsilon)$	=	$\{(q, S)\}$	to je e-přechod, vloží střed S	$\delta(q, -, -)$
$\delta(q, e, aSa)$	=	$\{(q, S)\}$	to je e-přechod	$\delta(q, e, aSa)$
$\delta(q, e, bSb)$	=	$\{(q, S)\}$	to je e-přechod	$\delta(q, e, bSb)$
$\delta(q, e, ZS)$	=	$\{(p, e)\}$		

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

Pozn.: Argument „cokoliv“ znamená, že se jedná o e-přechod

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)

$\mathcal{P} = (\{q\}, \{ (,) , + , * , a \}, \{ E, T, F, (,) , + , * , a \}, \delta, q, E, \emptyset)$

$\delta(q, \text{cokoliv}, E) = \{ (q, E+T), (q, T) \}$

$\delta(q, \text{cokoliv}, T) = \{ (q, T*F), (q, F) \}$

$\delta(q, \text{cokoliv}, F) = \{ (q, (E)), (q, a) \}$

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

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

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

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

Např. zpracování věty $a+a$

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

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.

Řešení příkladů

Př. eliminace zbytečných symbolů

$G[S]: S \rightarrow a \mid A \qquad A \rightarrow A B \qquad B \rightarrow b$

Krok1. {S, B} tj. vypadne A

Krok2. {S, a}

Výsledek je $S \rightarrow a$

Krok2. {S, A, B, a, b}

Krok1. {S, B} tj. Vypadne A

Výsledek je $S \rightarrow a, B \rightarrow b$

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

$N_e = \{ S \}$ proto modifikujeme pravidla s S na pravé straně
všemi možnými vypuštěními S

Výsledek: $S' \rightarrow S \mid e$

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

Př. Odstranění jednoduchých pravidel

$G[E]$

$E \rightarrow T \mid E + T$

$T \rightarrow F \mid T * F$

$F \rightarrow (E) \mid i$

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

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

$F \rightarrow (E) \mid i$

Cocke-Younger-Kasami algoritmus analýzy BK jazyků

Vychází z Chomského normální formy

Chomského normální forma (CNF)

Přepisovací pravidla jsou pouze v některém z tvarů:

1. $X \rightarrow YZ$
2. $X \rightarrow a$
3. $S \rightarrow \varepsilon$ pokud jazyk obsahuje prázdný řetězec. S nesmí být na pravé straně žádného přepisovacího pravidla.

Algoritmus převodu na gramatiku v CNF

Vstup: upravená (vlastní) gramatika bez jednoduchých pravidel $G = (N, T, P, S)$

Výstup: Gramatika v CNF $G' = (N', T, P', S)$

1. Množina P' obsahuje všechna pravidla z P ve tvaru $A \rightarrow BC$ a $A \rightarrow a$, případně $S \rightarrow \varepsilon$.
2. Každé pravidlo tvaru $A \rightarrow X_1X_2\dots X_k$ ($k > 2$) přepíšeme do P' jako sérii pravidel:
 $A \rightarrow X_1X_2'$
 $X_2' \rightarrow X_2X_3'$
...
 $X_{k-1}' \rightarrow X_{k-1}X_k$
A zavedeme nové neterminální symboly $X_2' \dots X_{k-1}'$ (tj. pravidla mající pravou stranu delší než dva prvky rozdělíme na sérii pravidel, která mají napravo jen dva prvky)
3. Ve všech pravidlech v P' které nejsou ve tvaru $A \rightarrow a$, kde se vyskytují na pravé straně terminální symboly, nahradíme tyto terminály za nové neterminály a přidáme pravidlo přepisující tyto nové neterminály na původní terminály (tj. nepovolená pravidla s terminály na pravé straně upravíme tak, že terminál nahradíme neterminálem, který se přepisuje na původní terminál).

Př. Mějme $G[S]$:

$S \rightarrow aXbX$
 $X \rightarrow aY \mid bY \mid \varepsilon$
 $Y \rightarrow X \mid c$

Odstraníme prázdná pravidla ($N_\varepsilon = \{X, Y\}$)

$S \rightarrow aXbX \mid abX \mid aXb \mid ab$
 $X \rightarrow aY \mid bY \mid a \mid b$
 $Y \rightarrow X \mid c$

Odstraníme jednoduchá pravidla

$S \rightarrow aXbX \mid abX \mid aXb \mid ab$
 $X \rightarrow aY \mid bY \mid a \mid b$
 $Y \rightarrow aY \mid bY \mid a \mid b \mid c$

Převédeme do CNF

$S \rightarrow EF \mid AF \mid EB \mid AB$
 $X \rightarrow AY \mid BY \mid a \mid b$
 $Y \rightarrow AY \mid BY \mid a \mid b \mid c$
 $E \rightarrow AX$
 $F \rightarrow BX$
 $A \rightarrow a$
 $B \rightarrow b$
 $C \rightarrow c$

Idea algoritmu CYK:

Bottom Up Parsing, Dynamické programování – rozklad na subproblémy = parsing substrings

Algoritmus (stručně):

Dán řetězec s délky N

Pro $k = 1 \dots N$ dělej

Pro každý **subřetěz** délky k

Urči, které neterminály jej mohou derivovat a zapiš je do tabulky.

Algoritmus CYK (detailně):

Vstup: řetězec $w = w_1w_2\dots w_n$

Metoda:

Jestliže $w = \varepsilon$, a $S \rightarrow \varepsilon$ je pravidlem, pak akceptuj

Pro $i = 1 \dots n$ dělej

Pro každý neterminál A dělej

Jestliže $A \rightarrow b$ je pravidlo, kde $b = w_i$

pak přidej A do buňky $X(i, i)$

Pro $l = 2 \dots n$ dělej

Pro $i = 1 \dots (n - l + 1)$ dělej

$j = i + l - 1$

Pro $k = i \dots (j - 1)$ dělej

Pro každé pravidlo tvaru $A \rightarrow BC$ dělej

Jestliže $X(i, k)$ obsahuje B a $X(k+1, j)$ obsahuje C

pak přidej A do buňky $X(i, j)$

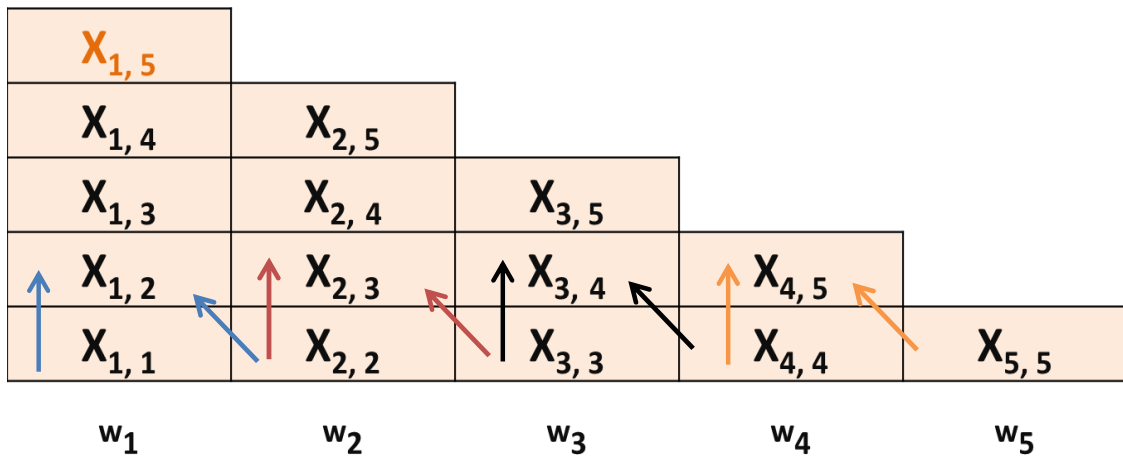
Jestliže S je obsaženo v $X(1, n)$ pak akceptuj, jinak odmítni.

Konstruujeme trojúhelníkovou matici X , řádky odpovídají subřetězcům:


- Dolní řádek – řetězec délky 1
- Druhý odspoda - řetězec délky 2
- :
- Vrcholový – odpovídá řetězci w

$X_{1,5}$				
$X_{1,4}$	$X_{2,5}$			
$X_{1,3}$	$X_{2,4}$	$X_{3,5}$		
$X_{1,2}$	$X_{2,3}$	$X_{3,4}$	$X_{4,5}$	
$X_{1,1}$	$X_{2,2}$	$X_{3,3}$	$X_{4,4}$	$X_{5,5}$
w_1	w_2	w_3	w_4	w_5


Tabulka pro w délky 5



Porovnávání dvojice při konstrukci druhé řádky



Porovnávání dvojice při konstrukci třetí řádky (prvku $X_{1,3}$)



Porovnávání dvojice při konstrukci vrcholové hodnoty

Př.

- CNF gramatika $G[S]$
 - $S \rightarrow AB \mid BC$
 - $A \rightarrow BA \mid a$
 - $B \rightarrow CC \mid b$
 - $C \rightarrow AB \mid a$
- w má tvar $b a a b a$. Je **baaba** v $L(G)$?
- **Konstruujeme trojúhelníkovou matici, vyplnění spodní řádky**

	{B}	{A, C}	{A, C}	{B}	{A, C}
	b	a	a	b	a

Dále počítáme

- $X_{1,2} = (X_{i,i}, X_{i+1,j}) = (X_{1,1}, X_{2,2})$
- $\rightarrow \{B\} \{A,C\} = \{BA, BC\}$
- Kroky:
 - Najdi pravidla generující BA nebo BC
 - Jsou dvě: $S \rightarrow A$ a A
 - $X_{1,2} = \{S, A\}$

$S \rightarrow AB \mid BC$
 $A \rightarrow BA \mid a$
 $B \rightarrow CC \mid b$
 $C \rightarrow AB \mid a$

$\{S, A\}_{1,2}$				
$\{B\}$	$\{A, C\}$	$\{A, C\}$	$\{B\}$	$\{A, C\}$
b	a	a	b	a

Dále $X_{2,3}$

- $X_{2,3} = (X_{i,i}, X_{i+1,j}) = (X_{2,2}, X_{3,3})$
- $\rightarrow \{A, C\} \{A,C\} = \{AA, AC, CA, CC\} = Y$
- Kroky:
 - Najdi pravidla generující Y
 - Je jen jedno: B
 - $X_{2,3} = \{B\}$

$S \rightarrow AB \mid BC$
 $A \rightarrow BA \mid a$
 $B \rightarrow CC \mid b$
 $C \rightarrow AB \mid a$

$\{S, A\}$	$\{B\}_{2,3}$			
$\{B\}$	$\{A, C\}$	$\{A, C\}$	$\{B\}$	$\{A, C\}$
b	a	a	b	a

Dále $X_{3,4}$

- $X_{3,4} = (X_{i,i}, X_{i+1,j}) = (X_{3,3}, X_{4,4})$
- $\rightarrow \{A, C\} \{B\} = \{AB, CB\} = Y$
- Kroky:
 - Najdi pravidla generující Y
 - Jsou dvě: S a C
 - $X_{3,4} = \{S, C\}$

$S \rightarrow AB \mid BC$
 $A \rightarrow BA \mid a$
 $B \rightarrow CC \mid b$
 $C \rightarrow AB \mid a$

$\{S, A\}$	$\{B\}$	$\{S, C\}$		
$\{B\}$	$\{A, C\}$	$\{A, C\}$	$\{B\}$	$\{A, C\}$
b	a	a	b	a

Dále $X_{4,5}$

- $X_{4,5} = (X_{i,i}, X_{i+1,j}) = (X_{4,4}, X_{5,5})$
- $\rightarrow \{B\} \{A, C\} = \{BA, BC\} = Y$
- Kroky:
 - Najdi pravidla generující Y
 - Jsou dvě: S a A
 - $X_{4,5} = \{S, A\}$

$S \rightarrow AB \mid BC$
 $A \rightarrow BA \mid a$
 $B \rightarrow CC \mid b$
 $C \rightarrow AB \mid a$

$\{S, A\}$	$\{B\}$	$\{S, C\}$	$\{S, A\}$	
$\{B\}$	$\{A, C\}$	$\{A, C\}$	$\{B\}$	$\{A, C\}$
b	a	a	b	a

Dále $X_{1,3}$

- $X_{1,3} = (X_{i,i}, X_{i+1,j}) \cup (X_{i,i+1}, X_{i+2,j})$
 $= (X_{1,1}, X_{2,3}) \cup (X_{1,2}, X_{3,3})$
- $\rightarrow \{B\} \{B\} \cup \{S, A\} \{A, C\} = \{BB, SA, SC, AA, AC\} = Y$
- Kroky:
 - Najdi pravidla generující Y
 - Nejsou žádná: S a A
 - $X_{1,3} = \emptyset$

S \rightarrow AB | BC
 A \rightarrow BA | a
 B \rightarrow CC | b
 C \rightarrow AB | a

\emptyset				
$\{S, A\}$	$\{B\}$	$\{S, C\}$	$\{S, A\}$	
$\{B\}$	$\{A, C\}$	$\{A, C\}$	$\{B\}$	$\{A, C\}$
b	a	a	b	a

Další $X_{2,4}$

- $X_{2,4} = (X_{i,i}, X_{i+1,j}) \cup (X_{i,i+1}, X_{i+2,j})$
 $= (X_{2,2}, X_{3,4}) \cup (X_{2,3}, X_{4,4})$
- $\rightarrow \{A, C\} \{S, C\} \cup \{B\} \{B\} = \{AS, AC, CS, CC, BB\} = Y$
- Kroky:
 - Najdi pravidla generující Y
 - Je jen jedno: B
 - $X_{2,4} = \{B\}$

S \rightarrow AB | BC
 A \rightarrow BA | a
 B \rightarrow CC | b
 C \rightarrow AB | a

\emptyset	$\{B\}$			
$\{S, A\}$	$\{B\}$	$\{S, C\}$	$\{S, A\}$	
$\{B\}$	$\{A, C\}$	$\{A, C\}$	$\{B\}$	$\{A, C\}$
b	a	a	b	a

Další $X_{3,5}$

- $X_{3,5} = (X_{i,i}, X_{i+1,j}) \cup (X_{i,i+1}, X_{i+2,j})$
 $= (X_{3,3}, X_{4,5}) \cup (X_{3,4}, X_{5,5})$
- $\rightarrow \{A,C\} \{S,A\} \cup \{S,C\} \{A,C\}$
 $= \{AS, AA, CS, CA, SA, SC, CA, CC\} = Y$
- Kroky:
 - Najdi pravidla generující Y
 - Je jen jedno: B
 - $X_{3,5} = \{B\}$

$S \rightarrow AB \mid BC$
 $A \rightarrow BA \mid a$
 $B \rightarrow CC \mid b$
 $C \rightarrow AB \mid a$

\emptyset	$\{B\}$	$\{B\}$			
$\{S, A\}$	$\{B\}$	$\{S, C\}$	$\{S, A\}$		
$\{B\}$	$\{A, C\}$	$\{A, C\}$	$\{B\}$	$\{A, C\}$	
b	a	a	b	a	

Další $X_{1,4}$

- $X_{1,4} = (X_{1,1}, X_{2,4}) \cup (X_{1,3}, X_{4,4}) \cup (X_{1,2}, X_{3,4})$
 $\rightarrow \{B\} \{B\} \cup \emptyset \{B\}$
 $= \{BB, B\} = Y$
- Kroky:
 - Najdi pravidla generující Y
 - Není žádné
 - $X_{1,4} = \emptyset$

$S \rightarrow AB \mid BC$
 $A \rightarrow BA \mid a$
 $B \rightarrow CC \mid b$
 $C \rightarrow AB \mid a$

\emptyset	$\{B\}$	$\{B\}$			
$\{S, A\}$	$\{B\}$	$\{S, C\}$	$\{S, A\}$		
$\{B\}$	$\{A, C\}$	$\{A, C\}$	$\{B\}$	$\{A, C\}$	
b	a	a	b	a	

Další $X_{2,5}$

$$X_{2,5} = (X_{2,2}, X_{3,5}) \cup (X_{2,4}, X_{5,5}) \cup (X_{2,3}, X_{4,5})$$

$$\rightarrow \{AB, CB\} \cup \{BA, BC\} \cup \{BS, BA\} = Y$$

$S \rightarrow AB \mid BC$
 $A \rightarrow BA \mid a$
 $B \rightarrow CC \mid b$
 $C \rightarrow AB \mid a$

Kroky:

- Najdi pravidla generující Y
- Jsou tři
- $X_{2,5} = \{S, A, C\}$

\emptyset	$\{S, A, C\}$				
\emptyset	$\{B\}$	$\{B\}$			
$\{S, A\}$	$\{B\}$	$\{S, C\}$	$\{S, A\}$		
$\{B\}$	$\{A, C\}$	$\{A, C\}$	$\{B\}$	$\{A, C\}$	
b	a	a	b	a	

Poslední $X_{1,5}$

$$X_{1,5} = (X_{1,1}, X_{2,5}) \cup (X_{1,4}, X_{5,5}) \cup (X_{1,3}, X_{4,5}) \cup (X_{1,2}, X_{3,5})$$

$$\rightarrow \{BS, BA, BC\} \cup \{A, C\} \cup \{S, A\} \cup \{SB, AB\} = Y$$

$S \rightarrow AB \mid BC$
 $A \rightarrow BA \mid a$
 $B \rightarrow CC \mid b$
 $C \rightarrow AB \mid a$

Kroky:

- Najdi pravidla generující Y
- Jsou tři
- $X_{1,5} = \{S, A, C\}$

$\{S, A, C\}$					
\emptyset	$\{S, A, C\}$				
\emptyset	$\{B\}$	$\{B\}$			
$\{S, A\}$	$\{B\}$	$\{S, C\}$	$\{S, A\}$		
$\{B\}$	$\{A, C\}$	$\{A, C\}$	$\{B\}$	$\{A, C\}$	
b	a	a	b	a	


Výsledek: $X_{1,5}$ Obsahuje S, věta patří do jazyka

Jak získat derivační strom?

Pro získání stromu je třeba si pamatovat, jak vznikaly jeho uzly.

Jdeme postupně od kořene S dolů:

- S bylo získáno z A B



{ S, A, C }				
∅	{B}	{B}		
{S, A}	{B}	{S, C}	{S, A}	
{B}	{A, C}	{A, C}	{B}	{A, C}
b	a	a	b	a

- A bylo získáno z B A
- B bylo získáno z C C
- B bylo získáno z b
- A bylo získáno z a
- C bylo získáno z A B
- C bylo získáno z a
- A bylo získáno z a
- B bylo získáno z b

