

Chomského NF, Pumping Lemma pro CFL

Marta Vomlelová

MS 303

Bezkontextové gramatiky (CFG) v Chomského normální formě

- Chomského normální forma bezkontextové gramatiky:
 - ▶ neobsahuje zbytečné symboly (S není nikdy zbytečný)
 - ▶ všechna pravidla tvaru $A \rightarrow BC$ nebo $A \rightarrow a$, A, B, C jsou neterminály, a terminál, nebo $S \rightarrow \epsilon$ pro startovní symbol S , který se pak nesmí vyskytovat na pravé straně žádného pravidla.
 - ▶ Pro každý bezkontextový jazyk L existuje gramatika v Chomského normálním tvaru, která generuje L .

Postupně provedeme zjednodušení gramatiky, nejdřív:

- Eliminace *zbytečných symbolů*
- eliminace *ϵ -pravidel* $A \rightarrow \epsilon$; $A \in V$
- eliminace *jednotkových pravidel* $A \rightarrow B$ pro $A, B \in V$.
- To vše potřebujeme k formulaci iteračního lemmatu pro bezkontextové jazyky.
- A ověření, zda zadaný řetězec patří do jazyka gramatiky pomocí Cocke-Younger-Kasami algoritmu.

Eliminace zbytečných symbolů

Definice 1.35: zbytečný, užitečný, generující, dosažitelný symbol

- Startovní symbol S je užitečný vždy (i když negeneruje žádné $w \in T^*$).
- Nestartovní symbol X je **užitečný** v gramatice $G = (V, T, P, S)$ pokud existuje derivace tvaru $S \Rightarrow^* \alpha X \beta \Rightarrow^* w$ kde $w \in T^*$, $X \in (V \cup T)$, $\alpha, \beta \in (V \cup T)^*$.
- Pokud X není užitečný, říkáme, že je **zbytečný**.
- X je **generující** pokud $X \Rightarrow^* w$ pro nějaké slovo $w \in T^*$. Vždy $w \Rightarrow^* w$ v nula krocích.
- X je **dosažitelný** pokud $S \Rightarrow^* \alpha X \beta$ pro nějaká $\alpha, \beta \in (V \cup T)^*$.

Chceme eliminovat ne-generující a ne-dosažitelné symboly.

Příklad 1.41

Uvažujme gramatiku:

$$S \rightarrow AB|a$$

$$A \rightarrow b$$

Eliminujeme B
(ne-generující):

$$S \rightarrow a$$

$$A \rightarrow b.$$

Eliminujeme A
(nedosažitelný):

$$S \rightarrow a.$$

Lemma 1.4 (Eliminace zbytečných symbolů)

Nechť $G = (V, T, P, S)$ je CFG. Zkonstruujeme $G_1 = (V_1, T_1, P_1, S)$ následovně:

- Eliminujeme ne-generující symboly (kromě S) a pravidla je obsahující
- poté eliminujeme všechny nedosažitelné symboly

Pak G_1 nemá zbytečné symboly a $L(G_1) = L(G)$.

Algoritmus 1.9: Generující symboly

Základ Každý $a \in T$ je generující.

Indukce Pro každé pravidlo $A \rightarrow \alpha$, kde každý symbol v α je generující. Pak i A je generující.
(Včetně $A \rightarrow \epsilon$).

Algoritmus 1.10: Dosažitelné symboly

Základ S je dosažitelný.

Indukce Je-li A dosažitelný, pro všechna pravidla $A \rightarrow \alpha$ jsou všechny symboly v α dosažitelné.

Lemma 1.5 (generující/dosažitelné symboly)

Výše uvedené algoritmy najdou právě všechny generující / dosažitelné symboly.

Eliminace ϵ pravidel

Definice 1.36: nulovatelný neterminál

Neterminál A je **nulovatelný** pokud $A \Rightarrow^* \epsilon$.

Pro nulovatelné neterminály na pravé straně pravidla $B \rightarrow CAD$, vytvoříme dvě verze pravidla – s a bez nulovatelného neterminálu.

Algoritmus 1.11: Nalezení nulovatelných symbolů v G

Základ Pokud $A \rightarrow \epsilon$ je pravidlo G , pak A je nulovatelné.

Indukce Pokud $B \rightarrow C_1 \dots C_k$, kde jsou všechna C_i nulovatelná, je i B nulovatelné (terminály nejsou nulovatelné nikdy).

Algoritmus 1.12: Konstrukce gramatiky bez ϵ -pravidel z G

- Najdi nulovatelné symboly
- Pro každé pravidlo $A \rightarrow X_1 \dots X_k \in P$, $k \geq 1$, nechť m z X_i je nulovatelných. Nová gramatika G_1 bude mít 2^m verzí tohoto pravidla s/bez každého nulovatelného symbolu kromě ϵ v případě $m = k$.

Pokud S je startovní symbol a gramatika obsahuje pravidlo $S \rightarrow \epsilon$, zavedeme nový počáteční symbol S_1 , přidáme $S_1 \rightarrow S|\epsilon$, toto pravidlo necháváme a s $S \rightarrow \epsilon$ eliminujeme.

Příklad 1.42

Mějme gramatiku $(\{A, B, S\}, \{a, b\}, P, S)$:

$$P = \left\{ \begin{array}{l} S \rightarrow AB \\ A \rightarrow AA|B|\epsilon \\ B \rightarrow bBB|\epsilon \end{array} \right\}.$$

- Pro každé pravidlo přidáme verze s/bez nulovatelných symbolů kromě ϵ .

$$\left\{ \begin{array}{l} S \rightarrow AB|A|B \\ A \rightarrow AA|A|A|B \\ B \rightarrow bBB|bB|bB|b \end{array} \right\}.$$

- Výsledná gramatika:

$$\left\{ \begin{array}{l} S_1 \rightarrow S|\epsilon \\ S \rightarrow AB|A|B \\ A \rightarrow AA|A|B \\ B \rightarrow bBB|bB|b \end{array} \right\}.$$

Eliminace jednotkových pravidel

Definice 1.37: jednotkové pravidlo

Jednotkové pravidlo je $A \rightarrow B \in P$ kde A, B jsou oba neterminály.

Idea: Rodič iterativně kopíruje pravou stranu dítěte jednotkového pravidla

Příklad 1.43 (Eliminace jednotkových pravidel)

$$\left\{ \begin{array}{l} I \rightarrow a|b|Ia|Ib|I0|I1 \\ F \rightarrow I|(E) \\ T \rightarrow F|T * F \\ E \rightarrow T|E + T \end{array} \right\} \quad \begin{array}{ll} \text{Expanze } T \vee E \rightarrow T & \\ E \rightarrow F|T * F & \text{Expanze } E \rightarrow I \\ \text{Expanze } E \rightarrow F & E \rightarrow a|b|Ia|Ib|I0|I1 \\ E \rightarrow I|(E) & \end{array}$$

Dohromady: $E \rightarrow a|b|Ia|Ib|I0|I1|(E)|T * F|E + T$.

Dále se musíme vyhnout možným cyklům.

Definice 1.38: jednotkový pár

Dvojici $A, B \in V$ takovou, že $A \Rightarrow^* B$ pouze jednotkovými pravidly nazýváme **jednotkový pár** (jednotková dvojice).

Algoritmus 1.14: Nalezení jednotkových párů

Základ (A, A) pro každý $A \in V$ je jednotkový pár.

Indukce Je-li (A, B) jednotkový pár a $(B \rightarrow C) \in P$, pak (A, C) je jednotkový pár.

Příklad 1.44 (Jednotkové páry z předchozí gramatiky)

$(E, E), (T, T), (F, F), (I, I), (E, T), (E, F), (E, I), (T, F), (T, I), (F, I).$

Algoritmus 1.15: Eliminace jednotkových pravidel z G

- najdi všechny jednotkové páry v G
- pro každý jednotkový pár (A, B) dáme do nové gramatiky všechna pravidla $A \rightarrow \alpha$ kde $B \rightarrow \alpha \in P$ a $B \rightarrow \alpha$ není jednotkové pravidlo.

Příklad 1.45

$$\left\{ \begin{array}{l} I \rightarrow a|b|Ia|Ib|IO|I1 \\ F \rightarrow I|(E) \\ T \rightarrow F|T * F \\ E \rightarrow T|E + T \end{array} \right\} \text{ převedeme } \left\{ \begin{array}{l} I \rightarrow a|b|Ia|Ib|IO|I1 \\ F \rightarrow (E)|a|b|Ia|Ib|IO|I1 \\ T \rightarrow T * F|(E)|a|b|Ia|Ib|IO|I1 \\ E \rightarrow E + T|T * F|(E)|a|b|Ia|Ib|IO|I1 \end{array} \right\}$$

Gramatiky v normálním tvaru

Lemma 1.6 (Gramatika v normálním tvaru, redukováná)

Mějme bezkontextovou gramatiku G , pak existuje CFG G_1 taková že $L(G_1) = L(G)$ a G_1 neobsahuje ϵ -pravidla kromě $S \rightarrow \epsilon$, neobsahuje jednotková pravidla ani zbytečné symboly. Gramatika G_1 se nazývá **redukováná**.

Redukce bezkontextové gramatiky.

Idea důkazu:

- Začneme eliminací ϵ -pravidel.
- Eliminujeme jednotková pravidla. Tím nepřidáme ϵ -pravidla.
- Eliminujeme zbytečné symboly. Tím nepřidáme žádná pravidla.
 - ▶ Nejříve negenerující (kromě počátečního symbolu S),
 - ▶ pak nedosažitelné.



Definice 1.39: Chomského normální tvar

O bezkontextové gramatice $G = (V, T, P, S)$ bez zbytečných symbolů kde jsou všechna pravidla v jednom ze tří tvarů

- $A \rightarrow BC, A, B, C \in V,$
- $A \rightarrow a, A \in V, a \in T,$
- případně $S \rightarrow \epsilon$, pak S není na pravé straně žádného pravidla,

říkáme, že je v **Chomského normálním tvaru (ChNF)**.

Potřebujeme dva další kroky:

- pravé strany délky 2 a více předělat na samé neterminály
- rozdělit pravé strany délky 3 a více neterminálů na více pravidel

Algoritmus 1.16: neterminály

- Pro každý terminál a vytvoříme nový neterminál, řekněme A ,
- přidáme pravidlo $A \rightarrow a$,
- použijeme A místo a na pravé straně pravidel délky 2 a více.

Algoritmus 1.17: rozdělení pravidel

- Pro pravidlo $A \rightarrow B_1 \dots B_k$ zavedeme $k - 2$ neterminálů C_i
- Přidáme pravidla $A \rightarrow B_1 C_1, C_1 \rightarrow B_2 C_2, \dots, C_{k-2} \rightarrow B_{k-1} B_k.$

Věta 1.17: Chomského normální tvar bezkontextové gramatiky

Mějme bezkontextovou gramatiku G . Pak existuje CFG G_1 v Chomského normálním tvaru taková, že $L(G_1) = L(G)$.

Příklad 1.46

$\{ I \rightarrow a|b|Ia|Ib|I0|I1, F \rightarrow I|(E), T \rightarrow F|T * F, E \rightarrow T|E + T \}$

$\left\{ \begin{array}{l} I \rightarrow a b IA IB IZ IU \\ F \rightarrow LER a b IA IB IZ IU \\ T \rightarrow TMF LER a b IA IB IZ IU \\ E \rightarrow EPT TMF LER a b IA IB IZ IU \\ A \rightarrow a \\ B \rightarrow b \\ Z \rightarrow 0 \\ U \rightarrow 1 \\ P \rightarrow + \\ M \rightarrow * \\ L \rightarrow (\\ R \rightarrow) \end{array} \right\}$	$\left\{ \begin{array}{l} F \rightarrow LC_3 a b IA IB IZ IU \\ T \rightarrow TC_2 LC_3 a b IA IB IZ IU \\ E \rightarrow EC_1 TC_2 LC_3 a b IA IB IZ IU \\ C_1 \rightarrow PT \\ C_2 \rightarrow MF \\ C_3 \rightarrow ER \\ I, A, B, Z, U, P, M, L, R \text{ jako předchozí} \end{array} \right\}$
--	---

Příprava na (pumping) lemma o vkládání

Lemma (Velikost derivačního stromu gramatiky v CNF)

Mějme derivační strom podle gramatiky $G = (V, T, P, S)$ v Chomského normálním tvaru, který dává slovo w . Je-li délka nejdelší cesty n , pak $|w| \leq 2^{n-1}$.

Proof.

Indukcí podle n ,

Základ $|a| = 1 = 2^0$

Indukce $2^{n-2} + 2^{n-2} = 2^{n-1}$.



Lemma (Důsledek)


Mějme derivační strom podle gramatiky $G = (V, T, P, S)$ v Chomského normální formě, který dává slovo w , $|w| > p = 2^{n-1}$. Pak ve stromě existuje cesta delší než n .

Lemma o vkládání (pumping) pro bezkontextové jazyky

Věta 1.18: !!Lemma o vkládání (pumping) pro bezkontextové jazyky

Mějme bezkontextový jazyk L . Pak existuje přirozené číslo $n \in \mathbb{N}$ takové, že každé $z \in L$, $|z| > n$ lze rozložit na $z = uvwxy$ kde:

- $|vwx| \leq n$
- $vx \neq \epsilon$
- $\forall i \geq 0, uv^iwx^iy \in L$.



Idea důkazu:

- vezmeme derivační strom pro z
- najdeme nejdelší cestu
- na ní dva stejné neterminály
- tyto neterminály určí dva podstromy
- podstromy definují rozklad slova
- nyní můžeme větší podstrom posunout ($i > 1$)
- nebo nahradit menším podstromem ($i = 0$).

Důkaz: $|z| > n : z = uvwxy, |vwx| \leq n, vx \neq \epsilon, \forall i \geq 0 uv^iwx^iy \in L$

- vezmeme gramatiku v Chomského NF (pro $L = \{\epsilon\}$ a $\emptyset$ zvol $n = 1$).
- Necht $|V| = k$. Položíme $n = 2^k$.
- Pro $z \in L, |z| > 2^k$, má v derivačním stromu z cestu délky $> k$
- vezmeme cestu maximální délky; terminál kam vede označíme t
- Aspoň dva z posledních $(k + 1)$ neterminálů na cestě do t jsou stejné
- vezmeme dvojici A^1, A^2 nejbližší k t (určuje podstromy T^1, T^2)
- cesta z A^1 do t je nejdelší v podstromu T^1 a má délku maximálně $(k + 1)$

tedy slovo dané stromem T^1 není delší než 2^k (tedy $|vwx| \leq n$)

- z A^1 vedou dvě cesty (ChNF), jedna do T^2 druhá do zbytku vx
ChNF je nevypouštějící, tedy $vx \neq \epsilon$

- derivace slova ($A^1 \Rightarrow^* vA^2x, A^2 \Rightarrow^* w$)

$$S \Rightarrow^* uA^1y \Rightarrow^* uvA^2xy \Rightarrow^* uvwxy$$

- posuneme-li A^2 do A^1 ($i = 0$)
- posuneme-li A^1 do A^2 ($i = 2, 3, \dots$)

$$S \Rightarrow^* uA^2y \Rightarrow^* uwy$$

$$S \Rightarrow^* uA^1y \Rightarrow^* uvA^1xy \Rightarrow^* uvvA^2xxy \Rightarrow^* uvvwxy.$$



Použití lemma o vkládání

Příklad 1.47 (ne-bezkontextový jazyk)

Následující jazyk není bezkontextový

- $\{0^i 1^i 2^i \mid i \geq 1\}$

- důkaz sporem: předpokládejme bezkontextovost

- z lemmatu o vkládání máme n

- zvolme $z = |0^n 1^n 2^n| > n$

žádné dělení nesplňuje PL neboť

- pumpovací slovo $|vwx| \leq n$

- tj. vždy lze pumpovat maximálně dva různé symboly

- $vx \neq \epsilon$, iterací se slovo změní

- poruší se rovnost počtu symbolů –

Příklad 1.48 (ne-bezkontextový jazyk)

Následující jazyk není bezkontextový

- $\{0^i 1^j 2^k \mid 0 \leq i \leq j \leq k\}$

- důkaz sporem: předpokládejme bezkontextovost

- z lemmatu o vkládání máme n

- zvolme $z = |0^n 1^n 2^n| > n$

žádné dělení nesplňuje PL neboť

- pumpovací slovo $|vwx| \leq n$

- tj. vždy lze pumpovat maximálně dva různé symboly

- ▶ pokud 0 (nebo 1), pumpujeme nahoru – SPOR $i \leq j$ (nebo $j \leq k$)

- ▶ pokud 2 (nebo 1), pumpujeme

Použití lemma o vkládání

Příklad 1.49 (ne-bezkontextový jazyk)

Následující jazyk není bezkontextový

- $\{0^i 1^j 2^i 3^j \mid i, j \geq 1\}$
- důkaz sporem: předpokládejme bezkontextovost
- z lemmatu o vkládání máme n
- zvolme $z = |0^n 1^n 2^n 3^n| > n$
- pumpovací slovo $|vwx| \leq n$
- tj. vždy lze pumpovat maximálně dva různé sousední symboly
- poruší se rovnost počtu symbolů 0 a 2 nebo 1 a 3 – SPOR.

Příklad 1.50 (ne-bezkontextový jazyk)

Následující jazyk není bezkontextový

- $\{ww \mid w \in \{0, 1\}^*\}$
- důkaz sporem: předpokládejme bezkontextovost
- z lemmatu o vkládání máme n
- zvolme $z = |0^n 1^n 0^n 1^n| > n$
- pumpovací slovo $|vwx| \leq n$
- tj. vždy lze pumpovat maximálně dva různé sousední symboly
- poruší se buď rovnost nul či jedniček
 - ▶ rozeberete 4 případy, vx obsahuje znak z prvních nul, prvních jedniček, druhých nul, druhých jedniček.

Kdy lemma o vkládání nezabere

- Lemma o vkládání je pouze implikace!

Příklad 1.51 (pumpovatelný, ne-bezkontextový jazyk)

$L = \{a^i b^j c^k d^l \mid i = 0 \vee j = k = l\}$ není bezkontextový jazyk, přesto lze pumpovat.

$i = 0 : b^j c^k d^l$ lze pumpovat v libovolném písmenu

$i > 0 : a^i b^n c^n d^n$ lze pumpovat v části obsahující a

Co s tím?

- zobecnění pumping lemmatu (Ogdenovo lemma)
 - ▶ pumpování vyznačených symbolů
- uzávěrové vlastnosti.

Příklad převodu FA na gramatiku

Příklad 1.52 (G, FA binární zápis čísla dělitelného 5)

$L = \{w \mid w \in \{0,1\}^* \text{ \& } w \text{ je binární zápis čísla dělitelného } 5\}$


$A \rightarrow 1B \mid 0A \mid \epsilon$

$B \rightarrow 0C \mid 1D$

$C \rightarrow 0E \mid 1A$

$D \rightarrow 0B \mid 1C$

$E \rightarrow 0D \mid 1E$



Příklady derivací

$A \Rightarrow 0A \Rightarrow 0$ (0)

$A \Rightarrow 1B \Rightarrow 10C \Rightarrow 101A \Rightarrow 101$ (5)

$A \Rightarrow 1B \Rightarrow 10C \Rightarrow 101A \Rightarrow 1010A \Rightarrow 1010$ (10)

$A \Rightarrow 1B \Rightarrow 11D \Rightarrow 111C \Rightarrow 1111A \Rightarrow 1111$ (15)

Převod konečného automatu na gramatiku typu 3

Věta 1.19: $L \in RE \Rightarrow L \in \mathcal{L}_3$

Pro každý jazyk rozpoznávaný konečným automatem existuje gramatika typu 3, která ho generuje.

Důkaz: Převod konečného automatu na gramatiku typu 3

- $L = L(A)$ pro deterministický konečný automat $A = (Q, \Sigma, \delta, q_0, F)$.
- definujme gramatiku $G = (Q, \Sigma, P, q_0)$, kde pravidla P mají tvar
$$p \rightarrow aq, \quad \text{když } \delta(p, a) = q$$
$$p \rightarrow \epsilon, \quad \text{když } p \in F$$
- je $L(A) = L(G)$?
 - ▶ $\epsilon \in L(A) \Leftrightarrow q_0 \in F \Leftrightarrow (q_0 \rightarrow \epsilon) \in P \Leftrightarrow \epsilon \in L(G)$
 - ▶ $a_1 \dots a_n \in L(A) \Leftrightarrow \exists q_0, \dots, q_n \in Q$ tž. $\delta(q_i, a_{i+1}) = q_{i+1}, q_n \in F$
 $\Leftrightarrow (q_0 \Rightarrow a_1 q_1 \Rightarrow \dots a_1 \dots a_n q_n \Rightarrow a_1 \dots a_n)$ je derivace pro $a_1 \dots a_n$
 $\Leftrightarrow a_1 \dots a_n \in L(G)$



Příprava převodu gramatiky typu 3 na FA

- Opačný směr
 - ▶ pravidla $A \rightarrow aB$ kódujeme do přechodové funkce
 - ▶ pravidla $A \rightarrow \epsilon$ určují koncové stavy
 - ▶ pravidla $A \rightarrow a_1 \dots a_n B$, $A \rightarrow a_1 \dots a_n$ s více neterminály rozepíšeme
 - ★ zavedeme nové neterminály $Y_2, \dots, Y_n, Z_1, \dots, Z_n$
 - ★ vytvoříme pravidla $A \rightarrow a_1 Y_2, Y_2 \rightarrow a_2 Y_3, \dots, Y_n \rightarrow a_n B$
 - ★ resp. $Z \rightarrow a_1 Z_1, Z_1 \rightarrow a_2 Z_2, \dots, Z_{n-1} \rightarrow a_n Z_n, Z_n \rightarrow \epsilon$
 - ▶ pravidla $A \rightarrow B$ odpovídají ϵ přechodům
 - ★ zbavíme se jich tranzitivním uzavěrem
 - ★ nebo musíme tranzitivně uzavřít $S \rightarrow B$ pro hledání $S \rightarrow \epsilon$.

Lemma

Ke každé gramatice typu 3 existuje gramatika typu 3, která generuje stejný jazyk a obsahuje pouze pravidla ve tvaru: $A \rightarrow aB, A \rightarrow \epsilon, A, B \in V, a \in T$.

Standardizace gramatiky typu 3

Lemma

Ke každé gramatice typu 3 existuje gramatika typu 3, která generuje stejný jazyk a obsahuje pouze pravidla ve tvaru: $A \rightarrow aB, A \rightarrow \epsilon, A, B \in V, a \in T$.

Proof.

Pro gramatiku $G = (V, T, S, P)$ definujeme $G^| = (V^|, T, S, P^|)$, kde pro každé pravidlo zavedeme dostatečný počet nových neterminálů $Y_2, \dots, Y_n, Z_1, \dots, Z_n$ a definujeme

P	$P^ $
$A \rightarrow aB$	$A \rightarrow aB$
$A \rightarrow \epsilon$	$A \rightarrow \epsilon$
$A \rightarrow a_1 \dots a_n B$	$A \rightarrow a_1 Y_2, Y_2 \rightarrow a_2 Y_3, \dots, Y_n \rightarrow a_n B$
$Z \rightarrow a_1 \dots a_n$	$Z \rightarrow a_1 Z_1, Z_1 \rightarrow a_2 Z_2, \dots, Z_{n-1} \rightarrow a_n Z_n, Z_n \rightarrow \epsilon$
odstraníme i pravidla: $A \rightarrow B$	tranzitivní uzávěr $U(A) = \{B B \in V \& A \Rightarrow^* B\}$ $A \rightarrow \gamma$ pro všechna $Z \in U(A)$ a $(Z \rightarrow \gamma) \in P^ $



Pouze pravidla $A \rightarrow aB, A \rightarrow \epsilon$

Příklad 1.53

P	$P $
$B \rightarrow a_1$	$B \rightarrow a_1 H_1, H_1 \rightarrow \epsilon$
	$U(A) = \{A, B\}$, proto
$A \rightarrow B$	$A \rightarrow a_1 H_2, H_2 \rightarrow \epsilon$
$A \rightarrow a_2$	$A \rightarrow a_2 H_3, H_3 \rightarrow \epsilon$

Převod gramatiky typu 3 na konečný automat

Věta 1.20: ϵ -NFA pro gramatiku typu 3 rozpoznávající stejný jazyk

Pro každý jazyk L generovaný gramatikou typu 3 existuje ϵ -NFA rozpoznávající L .

Důkaz: Převod gramatiky typu 3 na konečný automat

- Vezmeme $G = (V, T, P, S)$ obsahující jen pravidla tvaru $A \rightarrow aB$, $A \rightarrow \epsilon$, $A, B \in V$, $a \in T$ generující L (předchozí lemma)
 - definujeme nedeterministický ϵ -NFA $A = (V, T, \delta, S, F)$, kde:
$$F = \{A \mid (A \rightarrow \epsilon) \in P\}$$
$$\delta(A, a) = \{B \mid (A \rightarrow aB) \in P\}$$
 - $L(G) = L(A)$
 - ▶ $\epsilon \in L(G) \Leftrightarrow (S \rightarrow \epsilon) \in P \Leftrightarrow S \in F \Leftrightarrow \epsilon \in L(A)$
 - ▶ $a_1 \dots a_n \in L(G) \Leftrightarrow$ existuje derivace
$$(S \Rightarrow a_1 H_1 \Rightarrow \dots \Rightarrow a_1 \dots a_n H_n \Rightarrow a_1 \dots a_n)$$
- $\Leftrightarrow \exists H_0, \dots, H_n \in V$ tak že $H_0 = S, H_n \in F$
- $$H_{i+1} \in \delta(H_i, a_k) \quad \text{pro krok } a_1 \dots a_{k-1} H_i \Rightarrow a_1 \dots a_{k-1} a_k H_{i+1}$$
- $a_1 \dots a_n \in L(A)$

Levé (a pravé) lineární gramatiky

Definice 1.40: Levé (a pravé) lineární gramatiky

Gramatiky typu 3 nazýváme také **pravé lineární** (neterminál je vždy vpravo). Gramatika G je **levá lineární**, jestliže má pouze pravidla tvaru $A \rightarrow Bw, A \rightarrow w, A, B \in V, w \in T^*$.

Lemma

Jazyky generované levou lineární gramatikou jsou právě regulární jazyky.

Důkaz:

- ⇒ 'otočením' pravidel levé lineární gramatiky dostaneme pravou lineární $A \rightarrow Bw, A \rightarrow w$ převedeme na $A \rightarrow w^R B, A \rightarrow w^R$
- získaná gramatika generuje jazyk L^R , najdeme automat
 - víme, že regulární jazyky jsou uzavřené na reverzi, L^R je regulární, tudíž i $L = (L^R)^R$ je regulární
- ⇐ takto lze získat všechny regulární jazyky

Lineární gramatiky (a jazyky)

- Levá a pravá lineární pravidla dohromady jsou už silnější.

Definice 1.41: lineární gramatika, jazyk

Gramatika je lineární, jestliže má pouze pravidla tvaru $A \rightarrow uBw$, $A \rightarrow w$, $A, B \in V$, $u, w \in T^*$ (na pravé straně vždy maximálně jeden neterminál).

Lineární jazyky jsou právě jazyky generované lineárními gramatikami.

- Zřejmě platí: regulární jazyky $\subseteq$ lineární jazyky.
- Jde o vlastní podmnožinu $\subsetneq$.

Příklad 1.54 (lineární, neregulární jazyk)

Jazyk $L = \{0^i 1^i \mid i \geq 1\}$ není regulární jazyk, ale je lineární, generovaný gramatikou s pravidly $S \rightarrow 0S1 \mid 01$.

Pozorování:

- lineární pravidla lze rozložit na levě a pravě lineární pravidla: $S \rightarrow 0A$, $A \rightarrow S1$.



Definice 1.42: ekvivalence gramatik

Gramatiky G_1, G_2 jsou **ekvivalentní**, jestliže $L(G_1) = L(G_2)$, tj. generují stejný jazyk.

Víceznačnost gramatik

Dvě derivace téhož výrazu:

$$E \Rightarrow E + E \Rightarrow E + E * E \quad E \Rightarrow E * E \Rightarrow E + E * E$$



- Rozdíl je důležitý, vlevo $1 + (2 * 3) = 7$, vpravo $(1 + 2) * 3 = 9$.
- Tato gramatika může být modifikovaná na jednoznačnou.

Příklad 1.55

Různé derivace mohou reprezentovat stejný derivační strom, pak není problém.


1. $E \Rightarrow E + E \Rightarrow I + E \Rightarrow a + E \Rightarrow a + I \Rightarrow a + b$
2. $E \Rightarrow E + E \Rightarrow E + I \Rightarrow I + I \Rightarrow I + b \Rightarrow a + b$.

Definice 1.43: Jednoznačnost a víceznačnost CFG

- Bezkontextová gramatika $G = (V, T, P, S)$ je **víceznačná** pokud existuje aspoň jeden řetězec $w \in T^*$ pro který můžeme najít dva různé derivační stromy, oba s kořenem S dávající slovo w .
- V opačném případě nazýváme gramatiku **jednoznačnou**.
- Bezkontextový jazyk L je **jednoznačný**, jestliže existuje jednoznačná CFG G tak, že $L = L(G)$.
- Bezkontextový jazyk L je (podstatně) nejednoznačný**, jestliže každá CFG G taková, že $L = L(G)$, je nejednoznačná. Takovému jazyku říkáme i **víceznačný**.

Příklad 1.56 (nejednoznačnost CFG)

Dva derivační stromy dávající $a + a * a$ ukazující víceznačnost gramatiky.



Příklad víceznačného jazyka

Příklad 1.57 (Víceznačný jazyk)


Příklad víceznačného jazyka:

$$L = \{a^n b^n c^m d^m \mid n \geq 1, m \geq 1\} \cup \{a^n b^m c^m d^n \mid n \geq 1, m \geq 1\}.$$

1. $S \rightarrow AB \mid C$
2. $A \rightarrow aAb \mid ab$
3. $B \rightarrow cBd \mid cd$
4. $C \rightarrow aCd \mid aDd$
5. $D \rightarrow bDc \mid bc$.

Jakákoli gramatika pro daný jazyk bude generovat pro některá slova typu $a^n b^n c^n d^n$ dva různé derivační stromy.

Dva derivační stromy pro $aabbccdd$.



Odstanění víceznačnosti gramatiky

- Neexistuje algoritmus, který nám řekne, zda je daná gramatika víceznačná.
- Existují bezkontextové jazyky, pro které neexistuje jednoznačná bezkontextová gramatika, pouze víceznačné CFG.
- Existují určitá doporučení pro odstranění víceznačnosti.

Víceznačnost má různé příčiny:

- Není respektovaná priorita operátorů.
- Posloupnost identických operátorů lze shlukovat zleva i zprava.
- $S \rightarrow \text{if then } S \text{ else } S \mid \text{if then } S \mid \epsilon$

slovo 'if then if then else' má dva významy

'if then (if then else)' nebo 'if then (if then) else'

Řešení:

- ▶ syntaktická chyba (Algol 60)
- ▶ else patří k bližšímu if (preference pořadí pravidel)
- ▶ závorky begin-end, odsazení v Python (asi nejčistší řešení).

Vynucení priority

Řešením je zavést více různých proměnných, každou pro jednu úroveň 'priority'.


Konkrétně:

- **Faktor** je výraz který nesmí rozdělit žádný operátor.
 - ▶ identifikátory
 - ▶ výraz v závorkách
- **Term** je výraz, který nemůže rozdělit operátor $+$.
- **Výraz** může být rozdělen $*$ i $+$.

Jednoznačná gramatika pro výrazy:

1. $I \rightarrow a|b|Ia|Ib|I0|I1$
2. $F \rightarrow I|(E)$
3. $T \rightarrow F|T * F$
4. $E \rightarrow T|E + T$.

Jediný derivační strom pro $a + a *$



Kompilace výrazu (zásobník na mezivýsledky + dva registry):

- (1) $E \rightarrow E + T$... pop r1; pop r2; add r1,r2; push r2
- (2) $E \rightarrow T$
- (3) $T \rightarrow T * F$... pop r1; pop r2; mul r1,r2; push r2
- (4) $T \rightarrow F$
- (5) $F \rightarrow (E)$
- (6) $F \rightarrow a$... push a

- 'a+a*a' získáme postupnou aplikací pravidel 1,2,4,6,3,4,6,6
- posloupnost obrátíme a vybereme pouze pravidla generující kód
6,6,3,6,1
- nyní nahradíme pravidla příslušným kódem
push a; push a; pop r1; pop r2; mul r1,r2; push r2; push a; pop r1; pop r2;
add r1,r2; push r2

- Gramatiky
 - ▶ obecné
 - ▶ kontextové
 - ▶ bezkontextové
 - ▶ regulární, pravé lineární
- jazyk gramatiky, derivace, derivace dává slovo, derivační strom (pro bezkontextové gramatiky), ekvivalentní gramatiky
- ne každá lineární gramatika má ekvivalentní pravou lineární
- bezkontextové gramatiky
- jednoznačné a (podstatně) víceznačné gramatiky.