

Rekapitulace

- Víme, co jsou to regulární jazyky.
- Umíme je vymežit pomocí konečných automatů nebo regulárních výrazů.

Regulární jazyky jsou “jednoduché”.

Postačují například pro lexikální analýzu (detekci klíčových slov, operátorů, konstant, atd.)

Na popis o něco složitějších jazyků zatím ale prostředky nemáme.

$$L = \{a^i b^i \mid i \in \mathbf{N}\}$$

Téma dnešní přednášky

Gramatiky – generativní formalismus.

- Na rozdíl od rozpoznávání slouží k postupnému vygenerování všech slov daného jazyka.
1. Zaměříme se na tzv. **bezkontextové** gramatiky, které generují **bezkontextové jazyky**.
 - vhodné pro popis syntaxe programovacích jazyků
 2. Uvedeme i další důležité typy gramatik.
 - např. regulární gramatiky

Zápis syntaxe programovacího jazyka

- používá se tzv. rozšířená Backus-Naurova forma

Příklad – podmíněný příkaz (Java):

```
branching-statement ::= if condition-clause  
                        single-statement | block-statement  
                        [ else  
                          single-statement | block-statement ]  
condition-clause ::= ( Boolean-expression )  
single-statement ::= Statement  
block-statement ::= { Statement [ Statements ] }
```

Odvození aritmetických výrazů

$$\langle \text{EXPR} \rangle \rightarrow \langle \text{EXPR} \rangle + \langle \text{EXPR} \rangle$$

$$\langle \text{EXPR} \rangle \rightarrow \langle \text{EXPR} \rangle * \langle \text{EXPR} \rangle$$

$$\langle \text{EXPR} \rangle \rightarrow (\langle \text{EXPR} \rangle)$$

$$\langle \text{EXPR} \rangle \rightarrow v$$

Zjednodušený zápis:

$$E \rightarrow E + E \mid E * E \mid (E) \mid v$$

Terminální symboly: $(,), +, *, v$

Neterminální symbol (proměnná): E

Odvození aritmetických výrazů

Odvození (derivative) slova $v + v * v$:



$$E \Rightarrow E + E \Rightarrow v + E \Rightarrow v + E * E \Rightarrow v + v * E \Rightarrow v + v * v$$

(**levá derivative**, nahrazujeme vždy neterminál nejvíce vlevo)

$$E \Rightarrow E * E \Rightarrow E + E * E \Rightarrow v + E * E \Rightarrow v + v * E \Rightarrow v + v * v$$

(též levá derivative)

Derivační strom:



Odstranění nejednoznačnosti

Pokud existují dvě různé levé derivace pro jedno slovo, říkáme, že gramatika je **nejednoznačná**.

$$\langle \text{EXPR} \rangle \rightarrow \langle \text{EXPR} \rangle + \langle \text{TERM} \rangle \mid \langle \text{TERM} \rangle$$

$$\langle \text{TERM} \rangle \rightarrow \langle \text{TERM} \rangle * \langle \text{FACTOR} \rangle \mid \langle \text{FACTOR} \rangle$$

$$\langle \text{FACTOR} \rangle \rightarrow (\langle \text{EXPR} \rangle) \mid v$$

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

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

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

$$E \Rightarrow E + T \Rightarrow T + T \Rightarrow F + T \Rightarrow$$

$$v + T \Rightarrow v + T * F \Rightarrow v + F * F \Rightarrow$$

$$v + v * F \Rightarrow v + v * v$$

Definice bezkontextové gramatiky

Bezkontextová gramatika G je čtveřice (Π, Σ, S, P) , kde

- Π je konečná množina neterminálních symbolů
- Σ je konečná množina terminálních symbolů, $\Sigma \cap \Pi = \emptyset$
- $S \in \Pi$ je počáteční neterminál
- P je konečná množina pravidel typu $A \rightarrow \alpha$, kde
 - $A \in \Pi$
 - $\alpha \in (\Pi \cup \Sigma)^*$

Poznámka: Označení „bezkontextová“ vyjadřuje, že na levé straně pravidel je pouze jeden neterminál, bez jakýkoliv sousedů, tj. není v „kontextu“.

Odvození podle gramatiky

Nechť $G = (\Pi, \Sigma, S, P)$ je bezkontextová gramatika.
Pro $\gamma, \delta \in (\Pi \cup \Sigma)^*$ řekneme, že γ **přímo odvodí** δ , jestliže existují slova α_1, α_2 taková, že $\gamma = \alpha_1 A \alpha_2$, $\delta = \alpha_1 \beta \alpha_2$ a $A \rightarrow \beta$ je pravidlo v P .

Píšeme:

$$\gamma \Rightarrow_G \delta \qquad \alpha_1 A \alpha_2 \Rightarrow_G \alpha_1 \beta \alpha_2$$

Řekneme, že γ **odvodí** δ , pokud existuje posloupnost přímých odvození:

$$\gamma = \mu_0 \Rightarrow_G \mu_1 \Rightarrow_G \cdots \Rightarrow_G \mu_n = \delta$$

Píšeme: $\gamma \Rightarrow_G^* \delta$

Jazyk generovaný gramatikou

Jazyk generovaný bezkontextovou gramatikou

$G = (\Pi, \Sigma, S, P)$:

$$L(G) = \{w \in \Sigma^* \mid S \Rightarrow_G^* w\}$$


Jazyk L je **bezkontextový**, pokud existuje bezkontextová gramatika G taková, že $L(G) = L$.

Příklady bezkontextových grammatik

$$L = \{a^i b^i \mid i \geq 0\}$$

$$S \rightarrow \varepsilon$$

$$S \rightarrow aSb$$



$$L = \{ww^R \mid w \in \{a,b\}^*\}$$

$$S \rightarrow \varepsilon$$

$$S \rightarrow aSa$$

$$S \rightarrow bSb$$

Jaké jazyky generují tyto gramatiky?

1. $S \rightarrow aSbS$

$$S \rightarrow \varepsilon$$

2. $S \rightarrow bSbb \mid A \mid \varepsilon$

$$A \rightarrow aA \mid \varepsilon$$

Redukovaná gramatika

Z technických důvodů je užitečné, že bezkontextové gramatiky lze převádět do různých **normálních forem**.

Redukovaná gramatika – eliminuje pravidla obsahující

1. Neterminály, ze kterých nelze odvodit žádné terminální slovo.
2. Neterminály, které nejsou dosažitelné z počátečního neterminálu.

Příklad: $S \rightarrow aSb \mid aAbb \mid \varepsilon$

$A \rightarrow aAB \mid bB$

$B \rightarrow aAb \mid BB$

$C \rightarrow CC \mid cS$

Konstrukce redukované gramatiky

$$S \rightarrow aSb \mid aAbb \mid \varepsilon \quad B \rightarrow aAb \mid BB$$

$$A \rightarrow aAB \mid bB \quad C \rightarrow CC \mid cS$$

Neterminály generující terminální slova:

$$1. \mathbf{T}_1 = \{S\} \quad S \rightarrow \varepsilon$$

$$2. \mathbf{T}_2 = \{S, C\} \quad C \rightarrow cS$$

$$S \rightarrow aSb \mid \varepsilon$$

$$C \rightarrow CC \mid cS$$

Dosažitelné neterminály:

$$1. \mathbf{D}_1 = \{S\}$$

$$S \rightarrow aSb \mid \varepsilon$$

Chomského normální forma

Chomského normální forma (CNF):

$$N \rightarrow AB$$

A, B, N ... neterminály

$$N \rightarrow a$$

a ... terminál

$$S \rightarrow \varepsilon$$

S ... počáteční neterminál

- CNF obsahuje pouze jednoduché tvary pravidel, minimalizuje délku řetězců na pravé straně.

Věta: Každou bezkontextovou gramatiku lze převést na ekvivalentní bezkontextovou gramatiku v CNF.

Převod do CNF

Zadání:

$$S \rightarrow A \mid bSA$$

$$A \rightarrow aA \mid a \mid \varepsilon$$

1. Nahradíme pravidla typu $N \rightarrow \varepsilon$, kde $N \in \Pi - \{S\}$

$$S \rightarrow A \mid bSA \mid \varepsilon \mid bS$$

$$A \rightarrow aA \mid a$$

2. Nahradíme pravidla typu $N \rightarrow M$, kde $N, M \in \Pi$

$$S \rightarrow aA \mid a \mid bSA \mid \varepsilon \mid bS$$

$$A \rightarrow aA \mid a$$

Převod do CNF

3. Pro každý terminál c zavedeme nový neterminál N_c a přidáme pravidlo $N_c \rightarrow c$. Pokud jsou na pravé straně nějakého pravidla aspoň 2 symboly, pak použijeme N_c místo c .

$$\begin{aligned} S &\rightarrow N_a A \mid a \mid N_b SA \mid \varepsilon \mid N_b S \\ A &\rightarrow N_a A \mid a \\ N_a &\rightarrow a, \quad N_b \rightarrow b \end{aligned}$$


4. Upravíme řetězce neterminálů délky 3 a více.

$$X \rightarrow Y_1 Y_2 \dots Y_n \text{ nahradíme: } X \rightarrow Y_1 Z \text{ a } Z \rightarrow Y_2 \dots Y_n$$

$$\begin{aligned} S &\rightarrow N_a A \mid a \mid N_b Z \mid \varepsilon \mid N_b S \\ A &\rightarrow N_a A \mid a \\ N_a &\rightarrow a, \quad N_b \rightarrow b, \quad Z \rightarrow SA \end{aligned}$$

Pumping lemma – náhled k odvození


Uvažujme derivační strom popisující odvození slova z .
Pokud je $|z|$ dostatečně velké, musí nastat situace
vyjádřená schématem:




Neterminálů je konečný počet, proto existuje cesta, na které se zopakuje stejný neterminál.

Pumping lemma

uvw



uv^2wx^2y



Pumping lemma

Věta: Necht' L je bezkontextový jazyk. Potom existuje konstanta n taková, že každé slovo $z \in L, |z| \geq n$, lze psát ve tvaru $z = uvwxy$, kde $|vx| \geq 1$, $|vwx| \leq n$ a pro všechna $i \in \mathbf{N}$ je $uv^iwx^iy \in L$.

Použití:

$L = \{a^i b^i c^i \mid i \in \mathbf{N}\}$ není bezkontextový jazyk

sporem, vezmeme slovo $a^n b^n c^n$

$a^n b^n c^n = uvwxy$, kde $|vwx| \leq n$

tzn. vwx nemůže obsahovat všechny tři znaky a, b, c

tzn. $uvw \notin L$ (zkrátíme délku některých ze tří úseků, ne ale všech)

Obecná (generativní) gramatika

$$G = (\Pi, \Sigma, S, P)$$

- Zobecníme tvar pravidel:

$$\alpha \rightarrow \beta \quad \alpha \in (\Pi \cup \Sigma)^* \Pi (\Pi \cup \Sigma)^*, \beta \in (\Pi \cup \Sigma)^*$$

- Přímé odvození:

$$\gamma = \mu_1 \alpha \mu_2 \Rightarrow_G \mu_1 \beta \mu_2 = \delta$$

- Opět zavedeme (obecné) odvození: $\gamma \Rightarrow_G^* \delta$

- A jazyk generovaný gramatikou:

$$L(G) = \{w \in \Sigma^* \mid S \Rightarrow_G^* w\}$$

Chomského hierarchie

Rozlišíme 4 důležité typy gramatik:

- Typ 0, neboli **obecné gramatiky**
- Typ 1, neboli **kontextové gramatiky**

$$\alpha X \beta \rightarrow \alpha \gamma \beta \quad \alpha, \gamma, \beta \in (\Pi \cup \Sigma)^*, X \in \Pi, |\gamma| \geq 1$$
$$S \rightarrow \varepsilon$$


- Typ 2, neboli **bezkontextové gramatiky**
- Typ 3, neboli **regulární gramatiky**

$$X \rightarrow wY$$
$$X \rightarrow w \quad w \in \Sigma^*, X, Y \in \Pi$$

Regulární gramatiky generují regulární jazyky.

Konstrukce regulární gramatiky pro NKA

- terminály gramatiky = vstupní symboly automatu
- neterminály = stavy automatu
- počáteční neterminál = počáteční stav
- pravidla odpovídají přechodům v automatu



$$A \rightarrow xB$$

- přepis na prázdné slovo pro každý koncový stav



$$C \rightarrow \varepsilon$$