

# Gramatiky

## Definice – gramatika

Gramatikou  $G$  rozumíme čtveřici  $(N, \Sigma, P, S)$ , kde:

1.  $N \neq \emptyset$  je konečná množina tzv. **neterminálů**.
2.  $\Sigma$  je konečná množina **terminálů** (terminálních symbolů).  
[Označme  $V = N \cup \Sigma$ .]
3.  $P$  je podmnožinou  $V^*NV^* \times V^*$  je konečná množina **pravidel**.
4.  $S \in N$  je počáteční neboli startovní neterminál.

## Poznámka.

1. Neterminály označujeme velkými písmeny  $(A, B, C, \dots)$ , terminály naopak označujeme malými písmeny  $(a, b, c, \dots)$ .
2. Pro zachování přehlednosti je důležité, aby  $N \cap \Sigma = \emptyset$ , tj. abychom v gramatice nezaváděli symbol, který bude jak neterminálem, tak terminálem.
3. V definici množiny pravidel  $P$  se vyskytuje symbol  $V$ , který znamená sjednocení všech terminálních i neterminálních řetězců ( $V = N \cup \Sigma$ ). Pokud zapisujeme  $V^*$ , znamená to libovolný, tedy i nulový počet terminálů či neterminálů v jakémkoliv pořadí.
4. Prvkem množiny  $P$  je dvojice  $(\alpha, \beta)$ , kde  $\alpha$  obsahuje alespoň jeden neterminál (plyne z faktu, že  $\alpha \in V^*NV^*$ ). Místo zápisu  $(\alpha, \beta) \in P$  používáme přehlednější  $\alpha \rightarrow \beta$  a čteme „ $\alpha$  přepiš na  $\beta$ “.
5.  $\alpha \dots$  levá strana pravidla,  $\beta \dots$  pravá strana pravidla.

## Příklad 1.

Mějme gramatiku  $G = (\{S, A, B\}, \{a, b, \varepsilon\}, P, S)$ , kde množina  $P = \{$

$$\begin{aligned} S &\rightarrow aA \mid bbB \\ aA &\rightarrow aAba \\ A &\rightarrow aa \mid bBb \mid aAa \\ bB &\rightarrow bbBa \\ B &\rightarrow b \mid \varepsilon \mid BB \} \end{aligned}$$

Všimněte si, že se v zápisu vyskytuje symbol  $|$ . Ten slouží k oddělení dvou pravidel, které mají stejnou levou stranu. Například: pokud pravidla  $S \rightarrow aA$ ,  $S \rightarrow bbB$  mají na levé straně stejný neterminál  $S$ , zapisujeme to zjednodušeně  $S \rightarrow aA \mid bbB$ .

## Definice – přímé odvození v gramatice

Bud'  $G = (N, \Sigma, P, S)$  gramatika. Definujeme binární relaci  $\Rightarrow_G$  na množině  $V^+$ , tj.  $\Rightarrow_G \subseteq V^+ \times V^+$ . Pro libovolné dva „řetězce“ terminálních i neterminálních symbolů  $\gamma, \delta$  platí, že  $\gamma \Rightarrow_G \delta$ , právě když

1. existuje pravidlo  $\alpha \rightarrow \beta \in P$  a
2. „řetězce“ terminálních i neterminálních symbolů  $\varphi, \psi \in V^*$

tak, že  $\gamma = \varphi\alpha\psi, \delta = \varphi\beta\psi$ . Relaci  $\Rightarrow_G$  nazýváme **přímé odvození**.

### Příklad 2.

Mějme stejnou gramatiku jako v **Příkladu 1**, tedy  $G = (\{S, A, B\}, \{a, b, \varepsilon\}, P, S)$ , kde množina  $P = \{$

$$\begin{aligned} S &\rightarrow aA \mid bB \\ aA &\rightarrow aAba \\ A &\rightarrow aa \mid bBb \mid aAa \\ bB &\rightarrow bbBa \\ B &\rightarrow b \mid \varepsilon \mid BB \} \end{aligned}$$

Řetězec  $aAbaB$  můžeme odvodit na řetězec  $abBbbaB$ , tj.

$$\begin{aligned} aAbaB &\Rightarrow_G abBbbaB \\ a\{A\}baB &\Rightarrow_G a\{bBb\}baB \end{aligned}$$

Mohli jsme tak učinit, protože v řetězci  $aAbaB$  jsme neterminál  $A$  nahradili řetězcem  $bBb$  a vznikl výsledek odvození  $abBbbaB$ . Tedy použili jsme pravidlo  $A \rightarrow bBb$ , „vyměnili“ neterminál  $A$  za řetězec  $bBb$  a ostatní symboly v řetězci  $aAbaB$  ponechali beze změny a v původním pořadí!

### Poznámka.

Všimněte si, že stejně jako u pravidel zapisujeme i odvození „infixově“, tj. symbol přímého odvození  $\Rightarrow_G$  vkládáme mezi oba řetězce a **nepíšeme** např.  $(aAbaB, abBbbaB) \in \Rightarrow_G$ . Určitě jste zaregistrovali proč.

## Definice – odvození v $k$ krocích

Bud'  $k \in \mathbb{N}_0$ . Odvození v  $k$  krocích značíme  $\Rightarrow_G^k$  a definujeme induktivně takto:

1.  $\Rightarrow_G^0$  je odvození v 0 krocích (např.  $bB \Rightarrow_G^0 bB$ ) – tj. neprovede se žádné odvození.
2.  $\Rightarrow_G^1 = \Rightarrow_G$  je přímé odvození (tj. odvození v jednom kroku).
3.  $\Rightarrow_G^{k+1} = \Rightarrow_G^k \circ \Rightarrow_G$ .

### Příklad 3.

Znovu použijeme stejnou gramatiku jako v **Příkladu 1**, tedy  $G = (\{S, A, B\}, \{a, b, \varepsilon\}, P, S)$ , kde množina  $P = \{$

$$\begin{aligned} S &\rightarrow aA \mid bbB \\ aA &\rightarrow aAba \\ A &\rightarrow aa \mid bBb \mid aAa \\ bB &\rightarrow bbBa \\ B &\rightarrow b \mid \varepsilon \mid BB \} \end{aligned}$$

Ukázali jsme (v **Příkladu 2**) odvození  $aAbaB \Rightarrow_G abBbbaB$ . Můžeme ale pokračovat dále, tj.

$$aAbaB \Rightarrow_G abBbbaB \Rightarrow_G abbbbaB \Rightarrow_G abbbba$$

Všechna tři odvození se však dají souhrně zapsat

$$aAbaB \Rightarrow_G^3 abbbba$$

Provedli jsme tři odvození, tedy odvození ve 3 krocích.

*Úkol:* Podle jakých pravidel jsme provedli odvození ve 2. a 3. kroku?

### Poznámka.

1. Pokud bude z kontextu zřejmé, o jakou gramatiku se jedná, nebudeme v symbolu odvození používat symbol  $G$ , tj. místo  $\Rightarrow_G$  budeme psát pouze  $\Rightarrow$ .
2. V praxi či jiných materiálech se můžete setkat s tím, že se místo pojmu odvození v gramatice používá **derivace** v gramatice. Jedná se o dvojitý pojmenování stejné věci.

### Příklad 4.

Naši oblíbenou gramatiku snad už ani nemusíme představovat, přesto buď  $G = (\{S, A, B\}, \{a, b, \varepsilon\}, P, S)$ , kde množina  $P = \{$

$$\begin{aligned} S &\rightarrow aA \mid bbB \\ aA &\rightarrow aAba \\ A &\rightarrow aa \mid bBb \mid aAa \\ bB &\rightarrow bbBa \\ B &\rightarrow b \mid \varepsilon \mid BB \} \end{aligned}$$

*Úkol:* Zapište odvození slov  $bb, aaa, bbb, bbba, aaaba, abbbba$  z počátečního neterminálu  $S$ . U každého slova uveďte, jaká pravidla jste použili.

### Řešení.

1.  $S \Rightarrow bbB \Rightarrow bb$ , v 1. kroku jsme použili pravidlo  $S \rightarrow bbB$ , ve 2. kroku pravidlo  $B \rightarrow \varepsilon$ .
2.  $S \Rightarrow aA \Rightarrow aaa$ , v 1. kroku jsme použili pravidlo  $S \rightarrow aA$ , ve 2. kroku pravidlo  $A \rightarrow aa$ .
3.  $S \Rightarrow bbB \Rightarrow bbb$ , v 1. kroku jsme použili pravidlo  $S \rightarrow bbB$ , ve 2. kroku pravidlo  $B \rightarrow b$ .
4.  $S \Rightarrow bbB \Rightarrow bbBa \Rightarrow bbba$ , v 1. kroku jsme použili pravidlo  $S \rightarrow bbB$ , ve 2. kroku pravidlo  $bB \rightarrow bbBa$  a ve 3. kroku pravidlo  $B \rightarrow \varepsilon$ .
5.  $S \Rightarrow aA \Rightarrow aAba \Rightarrow aaaba$ , v 1. kroku jsme použili pravidlo  $S \rightarrow aA$ , ve 2. kroku pravidlo  $aA \rightarrow aAba$  a ve 3. kroku pravidlo  $A \rightarrow aa$ .
6.  $S \Rightarrow aA \Rightarrow aAba \Rightarrow abBba \Rightarrow abbba$ , v 1. kroku jsme použili pravidlo  $S \rightarrow aA$ , ve 2. kroku pravidlo  $aA \rightarrow aAba$ , ve 3. kroku pravidlo  $A \rightarrow bBb$  a ve 4. kroku pravidlo  $B \rightarrow \varepsilon$ .

### Definice – další druhy odvození

Bud'  $k \in \mathbb{N}_0$  a necht'  $G$  je libovolná gramatika.

- Odvození v nejvýše  $k$  krocích:

$$\Rightarrow^{\leq k} = \bigcup_{i=0}^k \Rightarrow^i$$

- reflexivní a tranzitivní uzávěr  $\Rightarrow^*$ :

$$\Rightarrow^* = \bigcup_{i=0}^{\infty} \Rightarrow_G^i$$

- tranzitivní uzávěr  $\Rightarrow^+$ :

$$\Rightarrow^+ = \bigcup_{i=1}^{\infty} \Rightarrow^i$$

### Definice – větná forma, věta

Bud'  $G = (N, \Sigma, P, S)$  gramatika. **Větnou formou** rozumíme řetězec  $\alpha \in V^*$  takový, že  $S \Rightarrow^* \alpha$ . Jsou-li všechny symboly řetězce  $\alpha$  terminály, pak  $\alpha$  nazýváme **větou**.

### Příklad 5.

V **Příkladu 4** jsme našli odvození slov  $bb, aaa, bbb, bbba, aaaba, abbba$  v gramatice  $G$ . Jsou to tedy věty. Při odvození slova  $abbba$  jsme postupovali takto:  $S \Rightarrow aA \Rightarrow aAba \Rightarrow abBba \Rightarrow abbba$ . Řetězce  $aA, aAba, abBba$  jsou tedy větné formy gramatiky  $G$ . V **Příkladu 3** jsme zkoumali řetězec  $aAbaB$ . Zkuste sami říct, zda se jedná o větnou formu gramatiky  $G$  nebo ne, tj. dá se  $aAbaB$  odvodit z počátečního neterminálu  $S$ ?

## Definice – jazyk generovaný gramatikou

Bud'  $G$  gramatika nad abecedou  $\Sigma$ . Jazyk generovaný gramatikou  $G$  je množina  $L(G) = \{w \in \Sigma^* \mid S \Rightarrow^* w\}$ , tj. množina všech slov, které lze odvodit z počátečního neterminálu  $S$ .

## Definice – ekvivalence gramatik

Gramatiky  $G_1$  a  $G_2$  jsou jazykově ekvivalentní, když  $L(G_1) = L(G_2)$ , tj. když generují stejný jazyk.

### Příklad 6.

Mějme gramatiku  $G$  zadanou takto:  $G = (\{S, A\}, \{a, b\}, P, S)$ , kde  $P = \{$

$$\begin{aligned} S &\rightarrow aAa \mid bAb \\ A &\rightarrow a \mid b \mid aA \mid bA \mid \varepsilon \end{aligned}$$

Jaká slova generuje gramatika  $G$ ? Popište přesně jazyk  $L(G)$ .

**Řešení.** Vždy nejdříve začneme tím, že si vygenerujeme dostatečně velký počet slov, abychom pochopili „fungování“ gramatiky. Sami tedy asi zjistíte, že

$$L(G) = \{aaa, aa, bb, bab, aba, bbb, aaaa, bbbb, baab, babb, \dots\}.$$

Pozornější řešitel si uvědomí fakt, že v 1. kroku každého odvození musíme použít buď pravidlo  $S \rightarrow aAa$  nebo  $S \rightarrow bAb$  a potom už se k neterminálu  $S$  v dalším odvozování nemůžeme vrátit. Co to znamená? Na začátku i na konci slova jsou stejné symboly, slovo tedy buď začíná a končí symbolem  $a$  nebo začíná a končí symbolem  $b$ .

Větné formy  $aAa, bAb$  poté upravujeme tak, že měníme pouze prostřední neterminál  $A$ . Ten můžeme odvozovat libovolným způsobem. Výsledkem tedy je jazyk

- $L(G) = \{w \in \Sigma^* \mid w = axa \vee w = bxb, x \in \{a, b\}^*\}$
- $L(G)$  obsahuje slova, která začínají a končí stejným symbolem.

### Příklad 7.

Navrhněte gramatiky, které budou generovat jazyky

1.  $L_1 = \{w \in \{a, b\}^* \mid w \text{ obsahuje podslovo } abb\}$
2.  $L_2 = \{w \in \{a, b\}^*; |w| = 2k, k \in \mathbb{N}_0\}$
3.  $L_3 = \{w.w^R \mid w \in \{a, b\}^*\}$

### Řešení.

1. Pro lepší pochopení si neterminály budeme značit jiným způsobem než jak jsme byli zvyklí. Buď  $G = (\{S, N_a, N_{ab}, N_{abb}\}, \{a, b\}, P, S)$ , kde  $P = \{$

$$\begin{aligned} S &\rightarrow bS \mid aN_a \\ N_a &\rightarrow aN_a \mid bN_{ab} \\ N_{ab} &\rightarrow aN_a \mid bN_{abb} \\ N_{abb} &\rightarrow aN_{abb} \mid bN_{abb} \mid a \mid b \mid \varepsilon \end{aligned}$$

Všimněte si, že názvy neterminálů uchovávají informaci o tom, v jaké fázi odvození jsme. V momentě, kdy větná forma obsahuje

- neterminál  $N_a$ , víme, že je před ním symbol  $a$ ;
- neterminál  $N_{ab}$ , víme, že je před ním podslovo  $ab$ ;
- neterminál  $N_{abb}$ , víme, že je před ním podslovo  $abb$ , tudíž v tuto chvíli už větná forma obsahuje  $abb$ , gramatika může generovat cokoliv a vždy odvodíme větu – slovo patří do  $L_1$ .

Podívejme se třeba na odvození slova  $ababba$ , které obsahuje podslovo  $abb$ :

$$S \Rightarrow aN_a \Rightarrow abN_{ab} \Rightarrow abaN_a \Rightarrow ababN_{ab} \Rightarrow ababbN_{abb} \Rightarrow ababba$$

2. Jazyk  $L_2 = \{\varepsilon, aa, ab, ba, bb, aaaa, \dots\}$ . Je tedy nutné, aby se startovní neterminál  $S$  mohl být přepsán na  $\varepsilon$ . Má-li být délka slova sudá, pak libovolné slovo vznikne řetězením  $aa, ab, ba, bb$  za sebou v libovolném pořadí libovolně krát. Gramatika  $G = (\{S\}, \{a, b\}, P, S)$  s pravidly

$$P = \{S \rightarrow \varepsilon \mid aaS \mid abS \mid baS \mid bbS\}$$

je určitě možným řešením, tj. generuje jazyk  $L_2$ .

3. Jazyk  $L_3$  obsahuje slova jako  $\varepsilon, aa, bb, abba, baab, aaaa, bbbb, \dots$ . Když si tato slova rozpůlíme:  $a|a, b|b, ab|ba, ba|ab, aa|aa, bb|bb$ , zjistíme, že vznikají „obalování“ symbolů z obou stran  $|$ . Např. slovo  $abaaba$  vznikne tak, že

- symbol  $|$  obalíme nejdříve z obou stran  $a$ -čkem, tj.  $a|a$ ,
- poté  $|$  obalíme  $b$ -čkem: tj.  $ab|ba$  („obalování“ probíhá bezprostředně u symbolu  $|$ ),
- naposledy  $|$  znovu obalíme  $a$ -čkem:  $aba|aba$ .

Roli  $|$  může hrát např. neterminál  $S$ , tj. gramatika

$$G = (\{S\}, \{a, b\}, \{S \rightarrow \varepsilon \mid aSa \mid bSb\}, S)$$

je řešením úkolu, tj. generuje jazyk  $L_3$ .