

7. Gramatiky a Chomského hierarchie

Formální jazyky a automaty

Jiří Balun

Obsah

1 Gramatika

- Pojem gramatiky
- Derivace řetězce
- Jazyk generovaný gramatikou

2 Regulární gramatika (RG)

- Popis RG
- Ekvivalence RG a DFA

3 Bezkontextová gramatika (CFG)

- Popis CFG
- Derivační stromy
- Víceznačnost CFG a CFL
- CFG v praxi

Gramatika

Gramatika

Intuice: gramatika je struktura, která formálně popisuje jazyk pravidly, s jejichž pomocí lze generovat řetězce daného jazyka.

Definice

Formální **gramatika** je reprezentována uspořádanou čtveřicí $\mathcal{G} = (N, \Sigma, P, S)$, kde:

- 1 N je konečná množina neterminálů,
- 2 Σ je konečná množina terminálů (abeceda), platí $\Sigma \cap N = \emptyset$,
- 3 P je množina přepisovacích pravidel ve tvaru $P \subseteq V^*NV^* \times V^*$, kde $V = N \cup \Sigma$,
- 4 S je počáteční neterminál (platí $S \in N$).

- gramatiky popisují mnohem komplexnější jazyky než konečné automaty a RE
- pravidla v P se místo uspořádaných dvojic většinou zapisují ve tvaru $\alpha \rightarrow \beta$
 - pravidlo $\alpha \rightarrow \beta$ chápeme tak, že při jeho aplikaci se α přepíše na β
 - levá strana pravidla musí obsahovat alespoň jeden neterminál

Příklad: gramatika pro zápis celých čísel

Příklad

Mějme gramatiku $\mathcal{G} = (N, \Sigma, P, S)$ pro zápis celých čísel s pravidly:

$$S \rightarrow -I \mid +I \mid I$$

$$I \rightarrow DI \mid D$$

$$D \rightarrow 0 \mid 1 \mid 2 \mid 3 \mid 4 \mid 5 \mid 6 \mid 7 \mid 8 \mid 9$$

- $N = \{S, I, D\}$, kde neterminály obvykle značíme velkými písmeny,
- $\Sigma = \{0, \dots, 9, +, -\}$, terminály zde reprezentují číslice a znaménka,
- $P = \{\langle S, -I \rangle, \langle S, +I \rangle, \dots, \langle D, 9 \rangle\}$, kde předchozí zápis P čteme jako:
 - pravidla se stejnou levou stranou sloučíme na jeden řádek, pak namísto $A \rightarrow \alpha_1, \dots, A \rightarrow \alpha_n$ píšeme jen $A \rightarrow \alpha_1 \mid \dots \mid \alpha_n$ (pravidla oddělujeme pomocí „|“),
 - první řádek je vyhrazen pro pravidla startovního neterminálu,
- S obvykle označuje startovní neterminál.

Relace přímého odvození

Intuice: na řetězec obsahující alespoň jeden neterminál aplikujeme pravidlo gramatiky, čímž provedeme jeden krok odvození.

Definice

Binární relaci **přímého odvození** $\gamma \Rightarrow_{\mathcal{G}} \delta$ v CFG $\mathcal{G}$ definujeme jako aplikaci konkrétního pravidla na řetězec $\gamma = \eta\alpha\rho$, jehož výsledkem je řetězec $\delta = \eta\beta\rho$, neboli:

$$\eta\alpha\rho \Rightarrow_{\mathcal{G}} \eta\beta\rho$$

kde $\eta, \rho \in (\Sigma \cup N)^*$ a $\alpha \rightarrow \beta$ je právě aplikované pravidlo gramatiky $\mathcal{G}$.

- pokud je gramatika zřejmá z kontextu, pak můžeme psát jen $\Rightarrow$ namísto $\Rightarrow_{\mathcal{G}}$
- **větná forma** je libovolný řetězec terminálů a neterminálů
- **derivace** označuje proces, kdy na řetězec aplikujeme konečný počet kroků odvození
 - běžně máme na výběr z několika pravidel, které lze v daném kroku odvození aplikovat
 - jeden řetězec může mít více různých způsobů odvození

Příklad: přímé odvození

Příklad

Mějme gramatiku $\mathcal{G} = (N, \Sigma, P, S)$ pro zápis celých čísel s pravidly:

$$S \rightarrow -I \mid +I \mid I$$

$$I \rightarrow DI \mid D$$

$$D \rightarrow 0 \mid 1 \mid 2 \mid 3 \mid 4 \mid 5 \mid 6 \mid 7 \mid 8 \mid 9$$

V $\mathcal{G}$ lze například přímo odvodit:

- $S \Rightarrow -I$, kde z počátečního neterminálu S odvodíme $-I$ pravidlem $S \rightarrow -I$,
- $-I \Rightarrow -DI$, kde na neterminál I aplikujeme pravidlo $I \rightarrow DI$,
- $-DD \Rightarrow -4D$, kde na první výskyt D aplikujeme pravidlo $D \rightarrow 4$,
- $DDD \Rightarrow D6D$, kde na druhý výskyt D aplikujeme pravidlo $D \rightarrow 6$,
- a tak dále...

Obecná relace odvození

Definice

Odvození v k krocích v $\mathcal{G}$, kde $k \in \mathbb{N}_0$, definujeme induktivně jako relaci $\Rightarrow_{\mathcal{G}}^k$:

- $\Rightarrow_{\mathcal{G}}^0$ je identita,
- $\Rightarrow_{\mathcal{G}}^{k+1} = \Rightarrow_{\mathcal{G}}^k \circ \Rightarrow_{\mathcal{G}}$.

Pomocí relace $\Rightarrow_{\mathcal{G}}^k$ můžeme definovat další užitečné relace:

- relace **odvození v nejvýše k krocích**:

$$\Rightarrow_{\mathcal{G}}^{\leq k} = \bigcup_{i=0}^k \Rightarrow_{\mathcal{G}}^i$$

- relace **odvození** $\Rightarrow_{\mathcal{G}}^*$ (v konečném počtu kroků) a **netriviálního odvození** $\Rightarrow_{\mathcal{G}}^+$:

$$\Rightarrow_{\mathcal{G}}^* = \bigcup_{i=0}^{\infty} \Rightarrow_{\mathcal{G}}^i$$

$$\Rightarrow_{\mathcal{G}}^+ = \bigcup_{i=1}^{\infty} \Rightarrow_{\mathcal{G}}^i$$

Příklad: derivace řetězce

Příklad

Mějme gramatiku $\mathcal{G} = (N, \Sigma, P, S)$ pro zápis celých čísel s pravidly:

$$S \rightarrow -I \mid +I \mid I$$

$$I \rightarrow DI \mid D$$

$$D \rightarrow 0 \mid 1 \mid 2 \mid 3 \mid 4 \mid 5 \mid 6 \mid 7 \mid 8 \mid 9$$

V $\mathcal{G}$ lze například odvodit:

1 $S \Rightarrow -I \Rightarrow -DI \Rightarrow -DD \Rightarrow -4D \Rightarrow -42$

- platí tedy $S \Rightarrow^5 -42$ (a tedy platí i $S \Rightarrow^* -42$) nebo $S \Rightarrow^3 -DD$
- naopak -42 nelze odvodit v méně jak 5 krocích (tj. například $S \Rightarrow^4 -42$ už neplatí)

2 $S \Rightarrow -I \Rightarrow -DI \Rightarrow -4I \Rightarrow -4D \Rightarrow -42$

- odvozujeme stejný řetězec jako v **1**, ale změním pořadí aplikování pravidel

3 $S \Rightarrow I \Rightarrow DI \Rightarrow DDI \Rightarrow DDD \Rightarrow 6DD \Rightarrow 66D \Rightarrow 666$

4 $S \Rightarrow^* w$, kde $w \in \Sigma^*$ (obsahuje jen terminály), pak w je zápis celého čísla

Jazyk generovaný gramatikou


Intuice: gramatika popisuje všechny řetězce terminálů, které jsme schopni odvodit pomocí jejich pravidel v konečném počtu kroků.

Definice

Jazyk generovaný gramatikou $\mathcal{G}$ definujeme jako $L(\mathcal{G}) = \{w \in \Sigma^* \mid S \Rightarrow_{\mathcal{G}}^* w\}$.

- řetězce z jazyka $L(\mathcal{G})$ už neobsahují neterminály
 - přítomnost neterminálu ve větné formě značí, že proces generování ještě neskončil
 - řetězce odvozené z gramatiky $\mathcal{G}$, které obsahují pouze terminály, se označují jako **věty** $\mathcal{G}$
- gramatika sama o sobě nedává návod, jak rozhodnout problém náležení $w \in L(\mathcal{G})$
 - v některých případech je tento problém dokonce neřešitelný
 - existují i jazyky/problémy (rozumně definované), které nelze popsat gramatikou

Chomského hierarchie



- vytvořil ji lingvista Noam Chomsky v roce 1956
- gramatiky rozdělujeme do čtyř skupin podle tvaru jejich pravidel (a struktury jazyka):
 - **regulární gramatiky** (typ 3) jsou ekvivalentní s DFA
 - **bezkontextové gramatiky** (typ 2) generují jazyky zásobníkových automatů
 - **kontextové gramatiky** (typ 1) generují jazyky lineárně ohraničených automatů
 - **gramatiky bez omezení** (typ 0) generují jazyky *rozponávané* Turingovými stroji
- kromě toho rozdělujeme gramatiky i podle jejich popisné síly

Regulární gramatika (RG)

Regulární gramatika (typ 3)

Intuice: vhodným omezením tvaru pravidel gramatiky získáme další model, který popisuje/generuje regulární jazyky.

Definice

Regulární gramatika (RG z *regular grammar*) $\mathcal{G} = (N, \Sigma, P, S)$ má všechna pravidla v jednom z těchto tvarů (kde $A, B, S \in N$ a $a \in \Sigma$):

- 1 $A \rightarrow aB$ (neterminál generuje jeden terminál následovaný jedním neterminálem),
- 2 $A \rightarrow a$ (neterminál generuje pouze jeden terminál),
- 3 $S \rightarrow \varepsilon$, pokud se S nevyskytuje na pravé straně jakéhokoliv pravidla (pouze počáteční neterminál může generovat generovat prázdný řetězec).

- takto definovaná regulární gramatika je **pravolineární** (podle tvaru pravidel v 1)
 - analogicky lze definovat **levolineární** RG s pravidly 1 ve tvaru $A \rightarrow Ba$
 - levolineární a pravolineární gramatiky jsou ekvivalentní
 - v RG nesmíme míchat levolineární a pravolineární pravidla, tím zvýšíme sílu gramatiky

Příklady: regulární gramatika a protipříklad

Příklad

RG $\mathcal{G}_1 = (\{S, D\}, \{0, \dots, 9, +, -\}, P, S)$ pro popis celých čísel s pravidly:

$$\begin{aligned} S &\rightarrow +D \mid -D \mid 0D \mid \dots \mid 9D \mid 0 \mid \dots \mid 9 \\ D &\rightarrow 0D \mid \dots \mid 9D \mid 0 \mid \dots \mid 9 \end{aligned}$$

Příklad

Gramatika $\mathcal{G}_2 = (\{S, A, B\}, \{a, b\}, P, S)$, která **není regulární**:

$$\begin{aligned} S &\rightarrow aA \mid aB \\ A &\rightarrow Sb \\ B &\rightarrow b \end{aligned}$$

$\mathcal{G}_2$ není regulární, protože používá zároveň levolineární i pravolineární pravidla. Kombinací těchto pravidel můžeme vygenerovat neregulární jazyk $L(\mathcal{G}_2) = \{a^n b^n \mid n \in \mathbb{N}\}$.

Ekvivalence RG a DFA

Věta

Ke každé RG $\mathcal{G}$ existuje DFA A takový, že $L(A) = L(\mathcal{G})$.

Idea důkazu

Mějme RG $\mathcal{G} = (N, \Sigma, P, S)$ a sestojíme NFA $A = (N \cup \{q_f\}, \Sigma, \delta, S, F)$, kde:

- A má jeden stav pro každý neterminál $B \in N$ a navíc jeden stav q_f ,
- počáteční stav S odpovídá počátečnímu neterminálu,
- F obsahuje stav q_f , a pokud $\mathcal{G}$ obsahuje pravidlo $S \rightarrow \varepsilon$, pak i $S \in F$,
- pro každé pravidlo $A \rightarrow aB$ přidáme přechod $\delta(A, a) = B$ a pro pravidla ve tvaru $A \rightarrow a$ přidáme přechod $\delta(A, a) = q_f$.

Lze ukázat, že platí $S \Rightarrow_{\mathcal{G}}^* w$ právě tehdy, když $\delta(S, w) \in F$, a tedy $L(\mathcal{G}) = L(A)$. □

Věta

Ke každému DFA A existuje RG $\mathcal{G}$ taková, že $L(A) = L(\mathcal{G})$. □

Příklad: převod RG na NFA

Příklad

Mějme gramatiku $\mathcal{G} = (N, \Sigma, P, S)$ s jazykem $L(\mathcal{G}) = \{w \in \Sigma^* \mid \#_b(w) \geq 3\}$ a pravidly:


$$S \rightarrow aS \mid bX$$

$$X \rightarrow aX \mid bY$$

$$Y \rightarrow aY \mid bZ \mid b$$

$$Z \rightarrow aZ \mid bZ \mid a \mid b$$

Zkonstruujeme NFA $A = (\{S, X, Y, Z, q_f\}, \{a, b\}, \delta, S, \{q_f\})$ takový, že $L(A) = L(\mathcal{G})$:



Bezkontextová gramatika (CFG)

Motivační příklad: bezkontextová gramatika

Příklad

Formálně popíšeme lispové výrazy, které obsahují `if` a aritmetiku na celých číslech:

$$\langle exprs \rangle \rightarrow \langle expr \rangle \mid \langle expr \rangle \langle exprs \rangle \mid \varepsilon$$

$$\langle expr \rangle \rightarrow \langle num \rangle \mid (\langle func \rangle \langle exprs \rangle) \mid (\langle if \rangle)$$

$$\langle if \rangle \rightarrow \text{if } \langle expr \rangle \langle expr \rangle \mid \text{if } \langle expr \rangle \langle expr \rangle \langle expr \rangle$$

$$\langle func \rangle \rightarrow = \mid < \mid > \mid <= \mid >= \mid + \mid - \mid * \mid /$$

$$\langle num \rangle \rightarrow 0 \langle num \rangle \mid \dots \mid 9 \langle num \rangle \mid 0 \mid \dots \mid 9$$

Příklad odvození:

- $\langle exprs \rangle \Rightarrow^* (/ 5 7)$
- $\langle exprs \rangle \Rightarrow^* (+ 12 34 56 78)$
- $\langle exprs \rangle \Rightarrow^* (\text{if } (= 1 1) 42)$
- $\langle exprs \rangle \Rightarrow^* (\text{if } (\text{if } (< 0 (* 6 6 6)) 100 (- 100)) 1 0)$

$\langle exprs \rangle \Rightarrow \langle expr \rangle$

$\Rightarrow (\langle if \rangle)$

$\Rightarrow (\text{if } \langle expr \rangle \langle expr \rangle)$

$\Rightarrow (\text{if } (\langle func \rangle \langle exprs \rangle) \langle expr \rangle)$

$\Rightarrow (\text{if } (= \langle exprs \rangle) \langle expr \rangle)$

$\Rightarrow (\text{if } (= \langle expr \rangle \langle exprs \rangle) \langle expr \rangle)$

$\Rightarrow (\text{if } (= \langle expr \rangle \langle expr \rangle) \langle expr \rangle)$

$\Rightarrow (\text{if } (= \langle num \rangle \langle expr \rangle) \langle expr \rangle)$

$\Rightarrow (\text{if } (= 1 \langle expr \rangle) \langle expr \rangle)$

$\Rightarrow (\text{if } (= 1 \langle num \rangle) \langle expr \rangle)$

$\Rightarrow (\text{if } (= 1 1) \langle expr \rangle)$

$\Rightarrow (\text{if } (= 1 1) \langle num \rangle)$

$\Rightarrow (\text{if } (= 1 1) 4 \langle num \rangle)$

$\Rightarrow (\text{if } (= 1 1) 42)$

$\langle expr \rangle \rightarrow (\langle if \rangle)$

$\langle if \rangle \rightarrow \text{if } \langle expr \rangle \langle expr \rangle$

$\langle expr \rangle \rightarrow (\langle func \rangle \langle exprs \rangle)$

$\langle func \rangle \rightarrow =$

$\langle exprs \rangle \rightarrow \langle expr \rangle \langle exprs \rangle$

$\langle exprs \rangle \rightarrow \langle expr \rangle$

$\langle expr \rangle \rightarrow \langle num \rangle$

$\langle num \rangle \rightarrow 1$

$\langle expr \rangle \rightarrow \langle num \rangle$

$\langle num \rangle \rightarrow 1$

$\langle expr \rangle \rightarrow \langle num \rangle$

$\langle num \rangle \rightarrow 4 \langle num \rangle$

$\langle num \rangle \rightarrow 2$

Bezkontextová gramatika (typ 2)

Intuice: pravidla bezkontextových gramatik umožňují z jednoho neterminálu odvodit libovolný řetězec terminálů a neterminálů.

Definice

Bezkontextová gramatika (CFG z *context-free grammar*) $\mathcal{G} = (N, \Sigma, P, S)$ má všechna pravidla ve tvaru (kde $A \in N$):

- $A \rightarrow (\Sigma \cup N)^*$
- název *bezkontextová* vychází z přepisování neterminálu bez ohledu na kontext, tedy symboly/řetězce v okolí přepisovaného neterminálu (to umí až kontextové gramatiky)
- L je **bezkontextový jazyk** pokud existuje CFG $\mathcal{G}$ taková, že $L(\mathcal{G}) = L$
 - bezkontextové jazyky budeme značit CFL (z *context-free language*)
- gramatika je bezkontextová jen na základě tvaru svých pravidel
 - musíme rozlišovat typ gramatiky a typ jejího jazyka
 - jazyk CFG totiž může být regulární (pak existuje regulární gramatika se stejným jazykem)

Příklady: CFG a jejich jazyky

Příklad

CFG $\mathcal{G}_1 = (\{S, A\}, \{a, b\}, P, S)$ s pravidly:

$$S \rightarrow \varepsilon \mid AbAbAS$$

$$A \rightarrow AA \mid a \mid \varepsilon$$

generuje jazyk $L(\mathcal{G}_1) = \{w \in \Sigma^* \mid w \text{ obsahuje sudý počet znaků } b\}$, který je regulární.

Příklad

CFG $\mathcal{G}_2 = (\{S\}, \{a, b\}, P, S)$ s pravidly $S \rightarrow \varepsilon \mid aSb$ a jazykem $L(\mathcal{G}_2) = \{a^n b^n \mid n \in \mathbb{N}_0\}$.

Příklad

CFG $\mathcal{G}_3 = (\{S\}, \{a, \dots, z\}, P, S)$ s pravidly:

$$S \rightarrow \varepsilon \mid aSa \mid \dots \mid zSz \mid a \mid \dots \mid z$$

generuje jazyk palindromů, tj. $L(\mathcal{G}_3) = \{w \in \Sigma^* \mid w = w^R\}$.

Nejlevější derivace

Definice

Derivaci nazveme **nejlevější**, pokud ve větné formě přepisujeme vždy nejlevější neterminál.

- nejlevější derivaci značíme $\Rightarrow_{lm}$ (jeden krok) a $\Rightarrow_{lm}^k$ (více kroků)
- analogicky můžeme definovat i nejpravější derivaci $\Rightarrow_{rm}$

Příklad

Mějme CFG $\mathcal{G}_1 = (\{S, A\}, \{a, b\}, P, S)$ s pravidly

$$S \rightarrow \varepsilon \mid AbAbAS$$

$$A \rightarrow AA \mid a \mid \varepsilon$$

- $S \Rightarrow_{lm} AbAbAS \Rightarrow_{lm} abAbAS \Rightarrow_{lm} abbAS \Rightarrow_{lm} abbaS \Rightarrow_{lm} abba$
- $S \Rightarrow_{rm} AbAbAS \Rightarrow_{rm} AbAbA \Rightarrow_{rm} AbAb a \Rightarrow_{rm} Abba \Rightarrow_{rm} abba$
- $S \Rightarrow AbAbAS \Rightarrow AbbAS \Rightarrow AbbA \Rightarrow Abb \Rightarrow bb$ (není ani nejlevější ani nejpravější derivace řetězce bb)

Derivační strom

Intuice: derivační strom je datová struktura reprezentující proces odvození nějakého řetězce v CFG.

Definice

Strom T nazveme **derivačním stromem** řetězce $\alpha \in (\Sigma \cup N)^*$ v CFG $\mathcal{G} = (N, \Sigma, P, S)$ právě tehdy, když platí:

- 1 každý uzel je označen symbolem z $N \cup \Sigma \cup \{\varepsilon\}$, přičemž kořen je označen S ,
- 2 nelistové (vnitřní) uzly jsou označeny pouze neterminály,
- 3 pokud má nelistový uzel označení $A \in N$ a jeho potomci zleva doprava jsou označení $\beta_1, \dots, \beta_k$, kde $\beta_1, \dots, \beta_k \in \Sigma \cup N$, pak v $\mathcal{G}$ existuje pravidlo $A \rightarrow \beta_1 \dots \beta_k$,
- 4 pokud je uzel označen ε , pak je list a nemá žádné sourozence,
- 5 zřetěžením listových uzlů dostaneme α , neboli α je **derivace** stromu T .

- pro $\alpha \in (N \cup \Sigma)^*$ platí, že $S \Rightarrow_{\mathcal{G}}^* \alpha$ právě tehdy, když existuje strom v $\mathcal{G}$ s derivací α
- každému derivačnímu stromu odpovídá jediná levá (případně pravá) derivace

Příklad: derivační strom

Příklad


Mějme CFG $\mathcal{G}_1 = (\{S, A\}, \{a, b\}, P, S)$ s pravidly

$$S \rightarrow \varepsilon \mid AbAbAS$$

$$A \rightarrow AA \mid a \mid \varepsilon$$

a derivaci řetězce $aabba \in L(\mathcal{G}_1)$ a k ní sestavený derivační strom:

$$S \Rightarrow AbAbAS \Rightarrow AAbAbAS \Rightarrow aAbAbAS \Rightarrow aabAbAS \Rightarrow aabbAS \Rightarrow aabbaS \Rightarrow aabba$$



Víceznačnost CFG a CFL

Motivace: pro určení významu nebo korektnosti některých vět je potřeba analyzovat jejich derivační strom, proto dělíme CFL a CFG na základě unikátnosti jejich derivačních stromů.

Definice

Bezkontextová gramatika $\mathcal{G}$ je **víceznačná** (nejednoznačná) pokud existuje $w \in L(\mathcal{G})$, které má v $\mathcal{G}$ dva různé derivační stromy. V opačném případě je $\mathcal{G}$ **jednoznačná**.

Definice

Bezkontextový jazyk L je **dědičně víceznačný** pokud je víceznačná každá gramatika, která generuje L .

- příkladem dědičně víceznačného jazyka je jazyk $\{a^i b^j c^k \mid i = j \vee j = k\}$
- je potřeba rozlišovat mezi víceznačností jazyka a gramatiky
- neexistuje způsob jak algoritmicky ověřit, že CFG je víceznačná

Příklad: víceznačnost

Příklad

Mějme víceznačnou gramatiku $\mathcal{G} = (\{E\}, \{+, -, a, (,)\}, P, S)$ s pravidly:



$$E \rightarrow E + E \mid E \times E \mid (E) \mid a$$

Řetězec $a \times a + a \in L(\mathcal{G})$ má dvě různé derivace, a tedy i dva derivační stromy:

1 $E \Rightarrow E + E \Rightarrow E \times E + E \Rightarrow a \times E + E \Rightarrow a \times a + E \Rightarrow a \times a + a$

2 $E \Rightarrow E \times E \Rightarrow E \times E + E \Rightarrow a \times E + E \Rightarrow a \times a + E \Rightarrow a \times a + a$

Jazyk $L(\mathcal{G})$ není dědičně víceznačný, tj. existuje jednoznačná gramatika, která jej generuje.



Backus-Naurova forma (BNF)

- BNF a její varianty umožňují formální zápis gramatik programovacích jazyků
- oproti formálním gramatikám jsou pravidla obvykle psána za operátor ::= namísto $\rightarrow$
- neterminální symboly jsou většinou psány do zkosených závorek, například <expr>
- terminální symboly/řetězce jsou uzavřeny do uvozovek, například "0"
- tzv. rozšířená BNF (zkráceně EBNF) umožňuje na pravou stranu pravidel psát RE:
 - výraz ve složených závorkách lze libovolně opakovat
 - výraz v hranatých závorkách je volitelný, tj. jeden nebo nula výskytů
 - kulaté závorky používáme standardně pro změnu precedence operací

Příklad

Příklad gramatiky v EBNF pro zápis aritmetických operací na celých číslech:

```
<expr> ::= <term> { ("+" | "-") <term> }  
<term> ::= <factor> { ("*" | "/" ) <factor> }  
<factor> ::= <number> | "(" <expr> ")"  
<number> ::= [ "-" ] <digit> { <digit> }  
<digit> ::= "0" | "1" | "2" | "3" | "4" | "5" | "6" | "7" | "8" | "9"
```

Příklad: použití CFG v překladačích

BNF a ENBF se používají v generátorech parserů při psaní překladačů:

- pomocí CFG specifikujeme jazyk, ke kterému generátor vytvoří syntaktický analyzátor
- příklady generátorů: Yacc, GNU Bison, ANTLR atd.

Překladače (například jazyka C do assembleru) postupují v několika krocích:

- **lexikální analýza** – převod z textu na tzv. *lexémy* (samostatné tokeny pro klíčová slova, identifikátory proměnných, čísla atd.) pomocí konečných automatů
- **syntaktická analýza** – na základě CFG se z lexémů sestaví derivační strom daného zdrojového kódu (v tomto kroku jsou odhaleny syntaktické chyby programu)
- **sémantická analýza** – na derivačním stromu se poté provádí kontrola a analýza významu kódu (například určení rozsahu platnosti proměnných, typová kontrola atd.)
- **optimalizace** – derivační strom se často převádí do lineárního mezikódu, na kterém se provádějí optimalizace (například rozvinutí cyklů, výpočet konstantních výrazů atd.)
- **generování kódu** – z výsledného mezikódu se vygeneruje finální kód

Příklad: gramatika jazyka C

- na webu jsou dostupné celé gramatiky jazyka C (zapsané v různých notacích)
- gramatika v EBNF: <https://cs.wmich.edu/~gupta/teaching/cs4850/sumII06/The%20syntax%20of%20C%20in%20Backus-Naur%20form.htm>
- varianta BNF pro Yacc: <https://www.quut.com/c/ANSI-C-grammar-y.html>

```
primary_expression
: IDENTIFIER
| constant
| string
| '(' expression ')'
| generic_selection
;

constant
: I_CONSTANT /* includes character_constant */
| F_CONSTANT
| ENUMERATION_CONSTANT /* after it has been defined as such */
;

enumeration_constant /* before it has been defined as such */
: IDENTIFIER
;

...
```