

Kapitola 6

LL gramatiky

6.1 Definice LL(k) gramatik

Definice 6.1. Nechť $G = (N, \Sigma, P, S)$ je CFG, $k \geq 1$ je celé číslo. Definujme funkci $FIRST_k^G : (N \cup \Sigma)^+ \rightarrow \mathcal{P}(\{w \in \Sigma^* \mid |w| \leq k\})$ předpisem

$$FIRST_k^G(\alpha) = \{w \in \Sigma^* \mid (\alpha \Rightarrow^* w \wedge |w| \leq k) \vee (\alpha \Rightarrow^* wx \wedge |w| = k \wedge x \in \Sigma^*)\}$$

a funkci $FOLLOW_k^G : N \rightarrow \mathcal{P}(\{w \in \Sigma^* \mid |w| \leq k\})$ předpisem

$$FOLLOW_k^G(A) = \{w \in \Sigma^* \mid S \Rightarrow_L^* \gamma A \alpha, w \in FIRST_k^G(\alpha)\}.$$

Nechť dále $w = a_1 a_2 \dots a_n$ je libovolný řetěz. Pak klademe

$$k : w = \begin{cases} a_1 \dots a_k & k < n \\ w & k \geq n \end{cases}$$

Poznámka 6.2. Nechť relace \Rightarrow_L značí levou derivaci, \Rightarrow_L^* jako obvykle její transitivní a reflexivní uzávěr. Není těžké ukázat, že pokud bychom v definicích funkcí $FIRST$ a $FOLLOW$ použili \Rightarrow_L^* namísto \Rightarrow^* , obdržíme tytéž množiny terminálních řetězů, tj. například platí: $FOLLOW_k^G(A) = \{w \in \Sigma^* \mid S \Rightarrow_L^* x A \alpha, w \in FIRST_k^G(\alpha)\}$. K tomu stačí indukcí ověřit následující dvě tvrzení (při obvyklém značení a $X, Y \in (N \cup \Sigma)^*$):

- (1) $\{w \in \Sigma^* \mid \gamma \Rightarrow_L^n w\} = \{w \in \Sigma^* \mid \gamma \Rightarrow^n w\}$ a
- (2) je-li $Y \Rightarrow^n \gamma X \beta \wedge \gamma \Rightarrow^* x \wedge \beta \Rightarrow^* y$, pak $Y \Rightarrow_L^n x X \alpha \wedge \alpha \Rightarrow^* y$ pro nějaké α .

Úmluva: V dalším textu budeme i levé derivace značit symbolem \Rightarrow resp. \Rightarrow^* , pokud nebude řečeno jinak.

Definice 6.3. Nechť $G = (N, \Sigma, P, S)$ je CFG, $k \geq 1$ je celé číslo. Řekneme, že G je LL(k) gramatika, právě když pro libovolné dvě nejlevější derivace ($w \in \Sigma^*$)

$$(1) \quad S \Rightarrow^* w A \alpha \Rightarrow w \beta \alpha \Rightarrow^* w x \tag{6.1}$$

$$(2) \quad S \Rightarrow^* w A \alpha \Rightarrow w \gamma \alpha \Rightarrow^* w y, \text{ podmínka} \tag{6.2}$$

$$(3) \quad k : x = k : y \tag{6.3}$$

$$\text{implikuje rovnost } \beta = \gamma. \tag{6.4}$$

Řekneme, že gramatika G je LL právě když je LL(k) pro nějaké $k \in \mathbb{N}$, jazyk L je LL(k) právě když existuje LL(k) gramatika G taková, že $L = L(G)$.

6.2 Vlastnosti LL gramatik

Věta 6.4. *Každá LL(k) gramatika je jednoznačná.*

Důkaz: Předpokládejme, že G není jednoznačná. Pak existuje věta $u \in L(G)$, která má alespoň dvě různé levé derivace:

$$(1) \quad S \Rightarrow^* wA\alpha \Rightarrow w\beta\alpha \Rightarrow^* wx = u$$

$$(2) \quad S \Rightarrow^* wA\alpha \Rightarrow w\gamma\alpha \Rightarrow^* wy = u$$

kde $A \rightarrow \beta \mid \gamma$ jsou dvě různá pravidla. Pak $k : x = k : y =$, ale $\beta \neq \gamma$, a tedy G není LL(k). \square

Věta 6.5. *Je-li G levorekurzivní, pak není LL(k) pro žádné k .*

Důkaz: Nechť $G = (N, \Sigma, P, S)$. Bud' $A \in N$ levorekursivní neterminál, tj. $A \Rightarrow^* A\alpha$ pro nějaké α . Jestliže $\alpha \Rightarrow^* \varepsilon$, pak G není jednoznačná, a tedy ani LL(k).

Jestliže $\alpha \not\Rightarrow^* \varepsilon$, nechť $\alpha \Rightarrow^* v, v \in \Sigma^+$, a $A \Rightarrow^+ \beta \Rightarrow^* u$, kde $\beta \not\Rightarrow^* A\alpha$ (použití pravidla, které již nevede k levé rekurzi $A \Rightarrow^* A\alpha$). Pak existují levé derivace:

$$(1) \quad S \Rightarrow^* wA\alpha' \Rightarrow^* wA\alpha^k\alpha' \Rightarrow^+ w\beta\alpha^k\alpha' \Rightarrow^* wuv^k\alpha'$$

$$(2) \quad S \Rightarrow^* wA\alpha' \Rightarrow^* wA\alpha^k\alpha' \Rightarrow^+ wA\alpha^{k+1}\alpha' \Rightarrow^* wuv^{k+1}\alpha' ,$$

kde $k : uv^k = k : uv^{k+1}$. Současně však muselo být (viz kroky \Rightarrow^+) v jistém kroku derivace (1), konkrétně v části $A \Rightarrow^+ \beta$, použito nějakého pravidla p_1 , které již nemůže vést na levou rekurzi; v odpovídajícím kroku derivace (2), konkrétně v části $A \Rightarrow^+ A\alpha$, ale bylo použito jiného pravidla p_2 , které k levé rekuzi vede. Tedy $p_1 \neq p_2$ a G není LL(k). \square

Věta 6.6. *Nechť $G = (N, \Sigma, P, S)$ je CFG. Pak G je LL(k) právě když platí podmínka: Jsou-li $A \rightarrow \beta$ a $A \rightarrow \gamma$ dvě libovolná různá pravidla v P , pak pro všechny nejlevější větné formy $wA\alpha$ platí:*

$$\text{FIRST}_k(\beta\alpha) \cap \text{FIRST}_k(\gamma\alpha) = \emptyset.$$

Důkaz: Předpokládejme, že existují $w, A, \alpha, \beta, \gamma$ tak, jak uvedeno výše, ale $\text{FIRST}_k(\beta\alpha) \cap \text{FIRST}_k(\gamma\alpha) \neq \emptyset$. Nechť $x \in \text{FIRST}_k(\beta\alpha) \cap \text{FIRST}_k(\gamma\alpha)$. Odtud (a z předpokladu o $wA\alpha$ a z definice funkce FIRST) plyne existence dvou derivací

$$\begin{aligned} S &\Rightarrow^* wA\alpha \Rightarrow w\beta\alpha \Rightarrow^* wxy \\ S &\Rightarrow^* wA\alpha \Rightarrow w\gamma\alpha \Rightarrow^* wxz \end{aligned}$$

a současně $k : xy = k : xz$, protože $x \in \text{FIRST}_k(\beta\alpha) \cap \text{FIRST}_k(\gamma\alpha)$ (je-li $|x| < k$, pak $y = \varepsilon = z$). Jelikož máme $\beta \neq \gamma$, pak G není LL(k).

Naopak, předpokládejme, že G není LL(k). To jest, existují dvě různé derivace

$$\begin{aligned} S &\Rightarrow^* wA\alpha \Rightarrow w\beta\alpha \Rightarrow^* wx \\ S &\Rightarrow^* wA\alpha \Rightarrow w\gamma\alpha \Rightarrow^* wy \end{aligned}$$

takové, že $k : x = k : y$, ale $\beta \neq \gamma$. Tedy $A \rightarrow \beta$ a $A \rightarrow \gamma$ jsou dvě různá pravidla, ale množiny $\text{FIRST}_k(\beta\alpha)$ a $\text{FIRST}_k(\gamma\alpha)$ nejsou disjunktní – obě obsahují řetěz $k : x$. \square

Důsledek 6.7. Nechť $G = (N, \Sigma, P, S)$ je CFG bez ε -pravidel. Pak G je LL(1) právě když $\forall A \in N$ a pro každá dvě různá A -pravidla $A \rightarrow \beta$, $A \rightarrow \gamma$ z P platí

$$FIRST_1(\beta) \cap FIRST_1(\gamma) = \emptyset.$$

Důkaz: Jelikož $\beta \not\Rightarrow^* \varepsilon$ a $\gamma \not\Rightarrow^* \varepsilon$, pak

$$\forall \alpha. FIRST_1(\beta\alpha) \cap FIRST_1(\gamma\alpha) = FIRST_1(\beta) \cap FIRST_1(\gamma). \quad \square$$

Věta 6.8. Nechť $G = (N, \Sigma, P, S)$ je CFG. G je LL(1) gramatika právě když $\forall A \in N$ a pro každá dvě různá A -pravidla $A \rightarrow \beta$, $A \rightarrow \gamma$ z P platí

$$FIRST_1(\beta FOLLOW_1(A)) \cap FIRST_1(\gamma FOLLOW_1(A)) = \emptyset \quad (6.5)$$

Důkaz: Pro $\beta \neq \gamma$ provedeme rozbor po případech:

- je-li $\beta \Rightarrow^* \varepsilon$ a $\gamma \Rightarrow^* \varepsilon$, pak G není jednoznačná. Tedy G není LL(k) a současně průnik (6.5) je neprázdný: je roven $FOLLOW_1(A)$.
- je-li $\beta \not\Rightarrow^* \varepsilon$ a $\gamma \not\Rightarrow^* \varepsilon$, pak tvrzení platí díky důsledku 6.7.
- je-li $\beta \not\Rightarrow^* \varepsilon$ a $\gamma \Rightarrow^* \varepsilon$, pak z věty 6.6 pro tento případ plyne, že G není LL(1), právě když existuje levá větná forma $wA\alpha$ tavová, že $FIRST_1(\beta) \cap FIRST_1(\alpha) \neq \emptyset$, právě když $FIRST_1(\beta FOLLOW_1(A)) \cap FIRST_1(\gamma FOLLOW_1(A)) = \emptyset$, protože $FIRST_1(\alpha) \subseteq FOLLOW_1(A)$. Identicky pro případ $\beta \Rightarrow^* \varepsilon$ a $\gamma \not\Rightarrow^* \varepsilon$.

\square

6.3 Syntaktická analýza LL(1) gramatik

Syntaktickou analýzu LL(k) gramatik lze provádět deterministickým zásobníkovým automatem automatem (DPDA). Požadujeme však, aby v případě, že vstupní slovo patří do jazyka, automat navíc poskytl informaci o struktuře věty (například její levé odvození, či derivační strom, resp. jednoznačné zakódování tohoto stromu). Proto automat rozšíříme o možnost zápisu výstupního symbolu na (přidanou) výstupní pásku Formální definici takového automatu s výstupem ponecháváme čtenáři.

Syntaktickou analýzu ukážeme nejprve pro LL(1) gramatiky, přičemž přímo vycházíme z tvrzení věty 6.8.

Nechť je dána LL(1) gramatika $G = (N, \Sigma, P, S)$, kde pravidla z P jsou očíslována $i = 1, \dots, card(P)$. Je-li $w \in L(G)$, pak *levým rozbořem* w nazveme posloupnost čísel pravidel použitých v levém odvození věty w .

DPDA A provádějící LL(1) syntaktickou analýzu vět z $L(G)$ má jeden stav, počáteční obsah zásobníku je $S\$$, kde S je kořen gramatiky G a $\$$ je symbol nevyskytující se v gramatice. Automat akceptuje prázdným zásobníkem. Označme M přechodovou funkci¹ typu $M : (N \cup \Sigma \cup \{\$\}) \times (\Sigma \cup \varepsilon) \rightarrow \{<\alpha, i> \mid A \rightarrow \alpha \text{ je } i\text{-té pravidlo v } P\} \cup \{\text{odstraň, přijmi, chyba}\}$,

a je definována takto:

1. Protože automat má jen jeden stav, v definici přechodové funkce ho neuvádíme.

1. Je-li $A \rightarrow \alpha$ i-té pravidlo, klademe $M(A, a) = <\alpha, i>$ pro všechna $a \in FIRST_1(\alpha)$.
Je-li též $\varepsilon \in FIRST_1(\alpha)$, pak $M(A, b) = <\alpha, i>$ pro všechna $b \in FOLLOW_1(A)$.
V obou případech: je-li
 2. $M(a, a) = \text{odstraň}$, pro všechna $a \in \Sigma$.
 3. $M(\$, \varepsilon) = \text{příjmi}$. Automat vymaže ze zásobníku symbol $\$$ a akceptuje.
 4. $M(x, a) = \text{chyba}$, pro $x \in \Sigma, x \neq a$.

Uvedená přechodová funkce M se též někdy nazývá *LL(1) tabulkou* pro G , její část zkonztruovaná dle bodu 1 pak *redukovanou LL(1) tabulkou*. Díky Větě 6.8 se snadno nahléne, že M je přechodovou funkcí *deterministického PDA* (s výstupem), a to právě když G je $LL(1)$; v opačném případě by $M(A, a)$ obsahovala dvě různé položky $<\alpha, i>$ a $<\beta, j>$ pro nějaká $A \in N, a \in \Sigma \cup \{\varepsilon\}$. Činnost automatu lze neformálně popsát takto:

1. Je-li na vrcholu zásobníku neterminál, řekněme A , pak automat má (v obou pod-případech) udělat krok dle bodu 1 definice funkce M . Nechť první symbol ještě nezpracované části vstupu je a : automat provede ε -krok, nahradí A na vrcholu zásobníku řetězem α a na výstup zapíše i , tj. číslo použitého pravidla $A \rightarrow \alpha$.
2. Je-li na vrcholu zásobníku terminál, řekněme a a na vstupu je rovněž a , pak (tak jako u nedeterministické analýzy shora dolů) automat přečte ze vstupu a a z vrcholu zásobníku a odstraní.
3. Je-li na vrcholu zásobníku symbol $\$$ (indikující „prázdný“ zásobník) a na vstupu je (již jen) ε (indikující *eof* vstupního souboru), automat akceptuje (vymaže zásobník).
4. ve všech ostatních případech automat ukončí výpočet a neakceptuje.

Výše uvedené úvahy lze formalizovat takto: množinu konfigurací K automatu \mathcal{A} definujeme jako $(N \cup \Sigma \cup \{\$\})^* \times (\Sigma \cup \varepsilon)^* \times \{1, \dots, card(P)\}^*$ reprezentující obsah zásobníku, dosud nepřečteno část vstupního slova a dosud vyprodukovaný výstup. Počáteční konfigurací pro vstupní slovo w je $(\$w, w, \varepsilon)$. Na K definujeme binární relaci (krok výpočtu) \vdash takto:

1. $(ax, A\gamma, \pi) \vdash (ax, \alpha\gamma, \pi i)$ jestliže $M(A, a) = <\alpha, i>$.
2. $(ax, a\gamma, \pi) \vdash (x, \gamma, \pi)$ (pozn.: v tomto případě je $M(a, a) = \text{odstraň}$).
3. $(\varepsilon, \$, \pi) \vdash (\varepsilon, \varepsilon, \pi)$, kde $(\varepsilon, \varepsilon, \pi)$ je akceptující konfigurace a π je levý rozbor $w \in L(G)$.

Pro ostatní konfigurace není krok výpočtu definován. Případně je možné K rozšířit o konfiguraci „chyba“ a definovat:

4. $(ax, X\gamma, \pi) \vdash \text{chyba}$

Tvrzení obsažené v bodě 3 je třeba dokázat:

Věta 6.9. Necht' $G = (N, \Sigma, P, S)$ je $LL(1)$ gramatika, jejíž pravidla jsou očíslována $i = 1, \dots, card(P)$ a necht' \mathcal{A} s přechodovou funkcí M jsou takové, jak definováno výše. Pak platí: $(\$w, w, \varepsilon) \vdash^* (\varepsilon, \varepsilon, \pi) \iff w \in L(G)$ a π je levý rozbor w .

Důkaz: Idea důkazu: nechť \mathcal{N} je PDA provádějící nedeterministickou syntaktickou analýzu vět z $L(G)$ zkonztruovaný dle lemmatu o nedeterministické syntaktické analýze shora dolů. Lze ověřit, že každý úspěšný výpočet automatu \mathcal{N} lze simulovat výpočtem v \mathcal{A} a též i obráceně, že ke každému akceptujícímu výpočtu v \mathcal{A} existuje úspěšný výpočet automatu \mathcal{N} (po případech dle definice přechodových funkcí automatů \mathcal{N} a \mathcal{A}). Jelikož nahrazování neterminálů na vrcholu zásobníku odpovídá levé derivaci, je π je levým rozboorem w . \square

6.4 SLL(k) gramatiky a jejich analýza

Pozorný čtenář si jistě položil otázku, zda tvrzení Věty 6.6 nejde z případu $k = 1$ zobecnit na $k > 1$. Ukážeme, že tomu tak není. Nejprve se zabývejme podmínkou (6.5) z Věty 6.6 zobecněnou pro $k \geq 1$.

Věta 6.10. Pro libovolnou redukovanou CFG $G = (N, \Sigma, P, S)$ a libovolné $k \geq 1$ celé jsou následující dvě tvrzení (6.6) a (6.7) ekvivalentní:

$$\left. \begin{array}{l} \forall A \in N. \forall A \rightarrow \beta \mid \gamma. \beta \neq \gamma : \\ FIRST_k(\beta FOLLOW_k(A)) \cap FIRST_k(\gamma FOLLOW_k(A)) = \emptyset \end{array} \right\} \quad (6.6)$$

$$\left. \begin{array}{ll} \text{Pro libovolné dvě levé derivace} & (1) \quad S \Rightarrow^* wA\alpha \Rightarrow w\beta\alpha \Rightarrow^* wx \\ & (2) \quad S \Rightarrow^* w'A\alpha' \Rightarrow w'\gamma\alpha' \Rightarrow^* w'y \\ & (3) \quad \text{podmínka } k : x = k : y \\ & \quad \text{implikuje rovnost } \beta = \gamma. \end{array} \right\} \quad (6.7)$$

Důkaz: Negace tvrzení (6.6) je ekvivaletní s tvrzením:

$$\begin{aligned} & \exists A \in N. \exists A \rightarrow \beta \mid \gamma. \beta \neq \gamma : \\ & \exists y \in FIRST_k(\beta FOLLOW_k(A)) \cap FIRST_k(\gamma FOLLOW_k(A)), \end{aligned}$$

které je ekvivaletní tvrzení:

$$\begin{aligned} & \exists A \in N. \exists A \rightarrow \beta \mid \gamma : \\ & S \Rightarrow_L^* wA\delta_1, \quad y \in FIRST_k(\beta\delta_1), \\ & S \Rightarrow_L^* w'A\delta_2, \quad y \in FIRST_k(\gamma\delta_2) \text{ a } \beta \neq \gamma, \end{aligned}$$

což je ekvivalentní negaci tvrzení (6.7) – viz definice $FIRST$, $FOLLOW$ a poznámka 6.2. \square

Je tedy vidět, že každá gramatika splňující podmínu (6.7) je LL(k) gramatikou, ale obrácené tvrzení neplatí: lze ukázat (viz níže), že pro každé $k > 1$ existuje LL(k) gramatika taková, že nesplňuje podmínu (6.7). Má tedy smysl definovat tzv. SLL(k) gramatiky, a to (například) takto:

Definice 6.11. Nechť $G = (N, \Sigma, P, S)$ je redukovaná CFG, $k \geq 1$ je celé číslo. řekneme, že G je SLL(k) gramatika, právě když pro libovolné dvě nejlevější derivace ($w \in \Sigma^*$)

$$\begin{aligned} (1) \quad & S \Rightarrow^* wA\alpha \Rightarrow w\beta\alpha \Rightarrow^* wx \\ (2) \quad & S \Rightarrow^* w'A\alpha' \Rightarrow w'\gamma\alpha' \Rightarrow^* w'y, \text{ podmínka} \\ (3) \quad & k : x = k : y \\ & \text{implikuje rovnost } \beta = \gamma. \end{aligned}$$

Řekneme, že gramatika G je SLL právě když je SLL(k) pro nějaké $k \in \mathbb{N}$, jazyk L je SLL(k) právě když existuje SLL(k) gramatika G taková, že $L = L(G)$.

Je tedy vidět, že syntaktická analýza SLL(k) gramatik je přímočarým rozšírením syntaktické analýzy LL(1) gramatik. Detailey (zatím) ponecháváme čtenáři.

6.5 Příloha: algoritmy pro výpočet funkcí FIRST a FOLLOW

Nechť Σ je abeceda, $L_1, L_2 \subseteq \Sigma^*$, $k \geq 1$. Definujeme funkci $\oplus_k : \Sigma^* \times \Sigma^* \rightarrow \Sigma^*$ takto:
 $L_1 \oplus_k L_2 = \{w \mid w = k : xy \text{ pro nějaká } x \in L_1, y \in L_2\}$.

Je dána gramatika $G = (N, \Sigma, P, S)$ a řetězec $\alpha = Y_1 \cdot Y_2 \cdots \cdot Y_l$, kde $Y_x = N \cup \Sigma$.

- 1) $FI_k(x) = \{x\}$ pro $x \in \Sigma$
- 2) Výpočet $FI_k(x)$ pro $x \in N$:

Nechť $N = \{X_1, X_2, \dots, X_n\}$. Budeme počítat hodnotu $FI_k(X_i)$ současně pro všechny neterminály ($i = 1, \dots, n$). Nechť všechna pravidla pro neterminál X_i jsou tato:

$$X_i \rightarrow Y_1^1 \dots Y_{k_1}^1 \mid Y_1^2 \dots Y_{k_2}^2 \mid \dots \mid Y_1^j \dots Y_{k_j}^j$$

Potom

$$\begin{aligned} FI_k(X_i) = & [FI_k(Y_1^1) \oplus_k FI_k(Y_2^1) \oplus_k \dots \oplus_k FI_k(Y_{k_1}^1)] \\ & \cup \dots \cup \\ & [FI_k(Y_1^1) \oplus_k FI_k(Y_2^1) \oplus_k \dots \oplus_k FI_k(Y_{k_1}^1)]. \end{aligned}$$

Hodnoty $FI_k(X_i)$ jsou pevnými body uvedené soustavy rekurzivních rovnic. Počáteční hodnoty jsou $FI_k(X_i) = \emptyset$.

- 3) $FIRST_k(\alpha) = FI_k(Y_1) \oplus_k FI_k(Y_2) \oplus_k \dots \oplus_k FI_k(Y_l)$
-

Je dána gramatika $G = (N, \Sigma, P, S)$. Funkce FO je definována pro $A \in N$.

Postupně počítáme hodnoty: $FO_1(A)$ pro všechny $A \in N$,

$$\begin{aligned} FO_2(A) \text{ pro všechny } A \in N \\ \vdots \\ FO_k(A) \text{ pro všechny } A \in N \end{aligned}$$

Při výpočtu $FO_i(A)$ postupujeme následovně:

- 1) $FO_i(S) := \{\epsilon\}$ pro počáteční neterminál S .
 $FO_i(A) := \emptyset$ pro ostatní neterminály.
- 2) Pro každé pravidlo tvaru: $B \rightarrow \alpha A \beta \in P$, kde $\beta \neq \epsilon$

$$FO_i(A) := FO_i(A) \cup [(FI_i(\beta) - \{\epsilon\}) \oplus_i FO_{i-1}(B)]$$

- 3) OPAKUJ

Pro každé pravidlo tvaru: $B \rightarrow \alpha A \beta \in P$, kde $\beta = \epsilon$ nebo $\epsilon \in FI_1(\beta)$

$$FO_i(A) := FO_i(A) \cup FO_i(B)$$

Tak dlouho, dokud se nedosáhne pevného bodu.

6.6 Transformace gramatik do LL(1) tvaru

- odstranění levé rekurze
- levá substituce — odstranění konfliktu FIRST-FIRST
- pohlcení pravého kontextu — odstranění konfliktu FIRST-FOLLOW