

# Intuice pro analýzu zdola nahoru

# Intuice pro analýzu zdola nahoru

$S \rightarrow XY$

$X \rightarrow ab$

$Y \rightarrow c$

# Nedeterministická syntaktická analýza zdola nahoru

**Věta 3.55.** Necht'  $\mathcal{G}$  je libovolná CFG, pak lze zkonstruovat rozšířený PDA  $\mathcal{R}$  takový, že  $L(\mathcal{G}) = L(\mathcal{R})$ .

**Důkaz. Vrchol zásobníku píšeme vpravo.**

Konstruujeme rozšířený PDA  $\mathcal{R}$ , který simuluje pravou derivaci v  $\mathcal{G}$  v obráceném pořadí.

PDA  $\mathcal{R}$  má kroky dvojího typu:

- 1 může kdykoli načíst do zásobníku symbol ze vstupu
- 2 (**redukce**) je-li na vrcholu zásobníku řetězec tvořící pravou stranu nějakého pravidla v  $\mathcal{G}$ , může ho nahradit odpovídajícím levostranným neterminálem (a ze vstupu nic nečte)

Nechť  $\mathcal{G} = (N, \Sigma, P, S)$ .

Položme  $\mathcal{R} = (\{q, r\}, \Sigma, N \cup \Sigma \cup \{\perp\}, \delta, q, \perp, \{r\})$ , kde  $\perp$  je nově přidaný symbol a kde  $\delta$  je definována takto:

- 1  $\delta(q, a, \varepsilon) = \{(q, a)\}$  pro všechna  $a \in \Sigma$
- 2 je-li  $A \rightarrow \alpha$  pravidlo v  $P$ , pak  $\delta(q, \varepsilon, \alpha)$  obsahuje  $(q, A)$
- 3  $\delta(q, \varepsilon, \perp S) = \{(r, \varepsilon)\}$

	krok výpočtu	odpovídající pravidlo z $\mathcal{G}$
$(q, i + i * i, \perp)$	$\frac{i}{\vdash} (q, +i * i, \perp i)$	$F \rightarrow i$
	$\frac{\varepsilon}{\vdash} (q, +i * i, \perp F)$	$T \rightarrow F$
	$\frac{\varepsilon}{\vdash} (q, +i * i, \perp T)$	$E \rightarrow T$
	$\frac{\varepsilon}{\vdash} (q, +i * i, \perp E)$	
	$\frac{+}{\vdash} (q, i * i, \perp E +)$	
	$\frac{i}{\vdash} (q, *i, \perp E + i)$	$F \rightarrow i$
	$\frac{\varepsilon}{\vdash} (q, *i, \perp E + F)$	$T \rightarrow F$
	$\frac{\varepsilon}{\vdash} (q, *i, \perp E + T)$	
	$\frac{*}{\vdash} (q, i, \perp E + T*)$	
	$\frac{i}{\vdash} (q, \varepsilon, \perp E + T * i)$	$F \rightarrow i$
	$\frac{\varepsilon}{\vdash} (q, \varepsilon, \perp E + T * F)$	$T \rightarrow T * F$
	$\frac{\varepsilon}{\vdash} (q, \varepsilon, \perp E + T)$	$E \rightarrow E + T$
	$\frac{\varepsilon}{\vdash} (q, \varepsilon, \perp E)$	
	$\frac{\varepsilon}{\vdash} (r, \varepsilon, \varepsilon)$	

# Korektnost

$$S \Rightarrow^* \alpha A y \xRightarrow{n} xy \iff (q, xy, \perp) \vdash^* (q, y, \perp \alpha A),$$

kde  $S \Rightarrow^* \alpha A y \xRightarrow{n} xy$  je pravá derivace a  $A$  je nejpravější neterminál.

( $\implies$ ) indukcí k délce odvození

( $\impliedby$ ) indukcí k délce výpočtu

Pro  $A = S$  a  $\alpha, y = \varepsilon$  dostáváme:

$$S \Rightarrow^* x \iff (q, x, \perp) \vdash^* (q, \varepsilon, \perp S) \quad \left[ \vdash (r, \varepsilon) \right]$$

"Výstupem" je pravá derivace v obráceném pořadí. □

# Efektivnost syntaktické analýzy

Nedeterministický PDA  $\implies$  nedeterministický algoritmus  
 $\implies$  exponenciální deterministický algoritmus

## Řešení:

- deterministický algoritmus složitosti  $\mathcal{O}(n^3)$ , kde  $n = |w|$   
(algoritmus Cocke - Younger - Kasami)
- deterministické zásobníkové automaty  
a deterministické bezkontextové jazyky
- lineární algoritmy pro speciální třídy deterministických  
bezkontextových jazyků

# Vlastnosti bezkontextových jazyků

**Věta 3.58. (a 3.61.)** Třída bezkontextových jazyků ( $\mathcal{L}_2$ ) **je** uzavřena vzhledem k operacím:

- 1 sjednocení
- 2 zřetězení
- 3 iterace
- 4 pozitivní iterace
- 5 průnik s regulárním jazykem

**Věta 3.60.** Třída bezkontextových jazyků ( $\mathcal{L}_2$ ) **není** uzavřena vzhledem k operacím:

- 1 průnik
- 2 doplněk



# Sjednocení

$L_1$  je generován CFG  $\mathcal{G}_1 = (N_1, \Sigma_1, P_1, S_1)$  a  
 $L_2$  je generován CFG  $\mathcal{G}_2 = (N_2, \Sigma_2, P_2, S_2)$ .

Bez újmy na obecnosti můžeme předpokládat  $N_1 \cap N_2 = \emptyset$ .

Definujeme  $\mathcal{G} = (N_1 \cup N_2 \cup \{S\}, \Sigma_1 \cup \Sigma_2, P, S)$ , kde  $S$  je nový symbol a

$$P = P_1 \cup P_2 \cup \{S \rightarrow S_1, S \rightarrow S_2\}.$$

Každá derivace v  $\mathcal{G}$  začne použitím buď  $S \rightarrow S_1$  nebo  $S \rightarrow S_2$ . Podmínka  $N_1 \cap N_2 = \emptyset$  zaručí, že při použití  $S \rightarrow S_1$  (resp.  $S \rightarrow S_2$ ) lze v dalším derivování používat jen pravidla z  $P_1$  (resp.  $P_2$ ).

Jazyk  $L = L_1 \cup L_2$  je generován gramatikou  $\mathcal{G}$ .

# Zřetězení

$L_1$  je generován CFG  $\mathcal{G}_1 = (N_1, \Sigma_1, P_1, S_1)$  a  
 $L_2$  je generován CFG  $\mathcal{G}_2 = (N_2, \Sigma_2, P_2, S_2)$ .

Bez újmy na obecnosti můžeme předpokládat  $N_1 \cap N_2 = \emptyset$ .

Definujeme  $\mathcal{G} = (N_1 \cup N_2 \cup \{S\}, \Sigma_1 \cup \Sigma_2, P, S)$ , kde  $S$  je nový symbol a

$$P = P_1 \cup P_2 \cup \{S \rightarrow S_1 S_2\}.$$

Jazyk  $L = L_1.L_2$  je generován gramatikou  $\mathcal{G}$ .

# Iterace a pozitivní iterace

$L_1$  je generován CFG  $\mathcal{G}_1 = (N_1, \Sigma_1, P_1, S_1)$ .

Definujeme  $\mathcal{G} = (N_1 \cup \{S\}, \Sigma_1, P, S)$ , kde  $S$  je nový symbol a

$$P = P_1 \cup \{S \rightarrow SS_1 \mid \varepsilon\}.$$

Jazyk  $L = L_1^*$  je generován gramatikou  $\mathcal{G}$ .

---

Definujeme  $\mathcal{G} = (N_1 \cup \{S\}, \Sigma_1, P, S)$ , kde  $S$  je nový symbol a

$$P = P_1 \cup \{S \rightarrow SS_1 \mid S_1\}.$$

Jazyk  $L = L_1^+$  je generován gramatikou  $\mathcal{G}$ .

# Korektnost konstrukce pro iteraci

Dokážeme  $L(\mathcal{G}) = L_1^*$ .

# Průnik a doplněk

$$L_1 = \{a^n b^n c^m \mid m, n \geq 1\} \quad L_2 = \{a^m b^n c^m \mid m, n \geq 1\}$$

Oba tyto jazyky jsou CFL.

Kbyby  $\mathcal{L}_2$  byla uzavřena vzhledem k operaci průniku, pak by i  $L_1 \cap L_2 = \{a^n b^n c^n \mid n \geq 1\}$  musel být bezkontextový, což však není.

---

Neuzavřenost  $\mathcal{L}_2$  vůči doplňku plyne z její uzavřenosti na sjednocení, neuzavřenosti na průnik a z De Morganových pravidel:

$$L_1 \cap L_2 = \text{co-}(\text{co-}L_1 \cup \text{co-}L_2),$$

tj., kdyby  $\mathcal{L}_2$  byla uzavřena na doplněk, musela by být uzavřena i na průnik, což však není.

# Průnik s regulárním jazykem

$L = L(\mathcal{P})$ , kde  $\mathcal{P}$  je PDA  $\mathcal{P} = (Q_1, \Sigma, \Gamma, \delta_1, q_1, Z_0, F_1)$

$R = L(\mathcal{A})$ , kde  $\mathcal{A}$  je deterministický FA  $\mathcal{A} = (Q_2, \Sigma, \delta_2, q_2, F_2)$

Sestrojíme PDA  $\mathcal{P}'$  takový, že  $L(\mathcal{P}') = L \cap R$ .

$\mathcal{P}' = (Q, \Sigma, \Gamma, \delta, q_0, Z_0, F)$ , kde

- $Q = Q_1 \times Q_2$

- $q_0 = \langle q_1, q_2 \rangle$

- $F = F_1 \times F_2$

- $\delta$  : pro každé  $p \in Q_1$ ,  $q \in Q_2$ ,  $a \in \Sigma \cup \{\varepsilon\}$ ,  $Z \in \Gamma$  platí:

$$\delta(\langle p, q \rangle, a, Z) = \{(\langle p', q' \rangle, \gamma) \mid (p', \gamma) \in \delta_1(p, a, Z) \text{ a } \hat{\delta}_2(q, a) = q'\}$$

Zřejmě platí  $w \in L(\mathcal{P}') \iff w \in L(\mathcal{P}) \cap L(\mathcal{A})$ .

# Rozhodnutelné problémy pro bezkontextové jazyky

## Problém příslušnosti

Existuje algoritmus, který pro libovolnou danou CFG  $\mathcal{G}$  a slovo  $w$  rozhoduje, zda  $w \in L(\mathcal{G})$  či nikoliv.

## Problém prázdnoty

Existuje algoritmus, který pro libovolnou danou CFG  $\mathcal{G}$  rozhoduje, zda  $L(\mathcal{G}) = \emptyset$  či nikoliv.

## Problém konečnosti

Existuje algoritmus, který pro libovolnou danou CFG  $\mathcal{G}$  rozhoduje, zda  $L(\mathcal{G})$  je konečný či nikoliv.

# Konečnost

**Věta 3.68.** Ke každé CFG  $\mathcal{G}$  lze sestavit čísla  $m, n$  taková, že  $L(\mathcal{G})$  je nekonečný právě když existuje slovo  $z \in L(\mathcal{G})$  takové, že  $m < |z| \leq n$ .

**Důkaz.** Předpokládejme, že  $\mathcal{G}$  je v CNF.

Nechť  $p, q$  jsou čísla s vlastnostmi popsanými v Lemmatu o vkládání.  
Položme  $m = p$  a  $n = p + q$ .

( $\Leftarrow$ ) Jestliže  $z \in L(\mathcal{G})$  je takové slovo, že  $|z| > p$ , pak existuje rozdělení  $z = uvwxy$  splňující  $vx \neq \varepsilon$  a  $uv^iwx^iy \in L(\mathcal{G})$  pro všechna  $i \geq 0$ . Tedy jazyk  $L(\mathcal{G})$  obsahuje nekonečně mnoho slov tvaru  $uv^iwx^iy$ , je tedy nekonečný.



( $\implies$ ) Necht'  $L(\mathcal{G})$  je nekonečný. Pak obsahuje i nekonečně mnoho slov délky větší než  $p$  – tuto množinu slov označme  $M$ . Zvolme z  $M$  libovolné takové slovo  $z$ , které má minimální délku a ukažme, že musí platit  $p < |z| \leq p + q$ .

Kdyby  $|z| > p + q$ , pak (opět dle Pumping lemmatu pro CFL) lze  $z$  psát ve tvaru  $z = uvwxy$ , kde  $vx \neq \varepsilon$ ,  $|vwx| \leq q$  a  $uv^iwx^iy \in L(\mathcal{G})$  pro všechna  $i \geq 0$ .

Pro  $i = 0$  dostáváme, že  $uwy \in L(\mathcal{G})$  a současně  $|uwy| < |uvwxy|$ .

Z nerovností  $|uvwxy| > p + q$  a  $|vwx| \leq q$  plyne, že  $|uwy| > (p + q) - q = p$ . Tedy  $uwy \in M$ , což je spor s volbou  $z$  jako slova z  $M$  s minimální délkou. Celkem tedy musí být  $|z| \leq p + q$ .  $\square$

# Vlastnost sebevložení

**Definice 3.70.** Necht'  $\mathcal{G} = (N, \Sigma, P, S)$  je CFG. Řekneme, že  $\mathcal{G}$  má **vlastnost sebevložení**, jestliže existují  $A \in N$  a  $u, v \in \Sigma^+$  taková, že  $A \Rightarrow^+ uAv$ .

CFL  $L$  má **vlastnost sebevložení**, jestliže každá bezkontextová gramatika, která jej generuje, má vlastnost sebevložení.

**Věta 3.71.** CFL  $L$  má vlastnost sebevložení, právě když  $L$  není regulární.

**Důkaz.** Viz skriptu.

# Nerozhodnutelné problémy pro bezkontextové jazyky

## Problém regularity

Neexistuje algoritmus, který pro libovolnou danou CFG  $\mathcal{G}$  rozhoduje, zda  $L(\mathcal{G})$  je regulární či nikoliv.

(Tedy není rozhodnutelné, zda  $L(\mathcal{G})$  má vlastnost sebevložení či nikoliv.)

## Problém univerzality

Neexistuje algoritmus, který pro libovolnou danou CFG  $\mathcal{G}$  rozhoduje, zda  $L(\mathcal{G}) = \Sigma^*$  či nikoliv.

**Problémy ekvivalence a inkluze** také nejsou rozhodnutelné (plyne z nerozhodnutelnosti problému univerzality).

# Deterministické zásobníkové automaty

**Definice 3.72.** Řekneme, že PDA  $\mathcal{M} = (Q, \Sigma, \Gamma, \delta, q_0, Z_0, F)$  je **deterministický** (DPDA), jestliže jsou splněny tyto podmínky:

- 1 pro všechna  $q \in Q$  a  $Z \in \Gamma$  platí:  
kdykoliv  $\delta(q, \varepsilon, Z) \neq \emptyset$ , pak  $\delta(q, a, Z) = \emptyset$  pro všechna  $a \in \Sigma$
- 2 pro žádné  $q \in Q$ ,  $Z \in \Gamma$  a  $a \in \Sigma \cup \{\varepsilon\}$  neobsahuje  $\delta(q, a, Z)$  více než jeden prvek

Řekneme, že  $L$  je **deterministický bezkontextový jazyk** (DCFL), právě když existuje DPDA  $\mathcal{M}$  takový, že  $L = L(\mathcal{M})$ .

# Vlastnosti deterministických bezkontextových jazyků

**Věta 3.82.** Třída DCFL je uzavřena na doplňek.

**Intuice:** DPDA má nad každým slovem právě jeden výpočet. Pro doplňek stačí zaměnit koncové a nekoncové stavy.

**Komplikace 1:** DPDA nemusí dočíst vstupní slovo do konce, protože se vyprázdní zásobník nebo přechod není definován.

**Řešení:**

**Komplikace 2:** DPDA nemusí dočíst vstupní slovo do konce, protože přestane číst vstup a neustále provádí  $\varepsilon$ -kroky pod kterými zásobník neomezeně roste.

**Řešení:**  $s = |Q|$ ,  $t = |\Gamma|$   
 $r = \max\{|\gamma| \mid (p', \gamma) \in \delta(p, \varepsilon, Z), p, p' \in Q, Z \in \Gamma\}$

zásobník neomezeně roste při  $\varepsilon$ -krocích  $\iff$  během posloupnosti  $\varepsilon$ -kroků jeho délka vzroste o více než  $r \cdot s \cdot t$

**Komplikace 3:** DPDA nemusí dočíst vstupní slovo do konce, protože přestane číst vstup a neustále provádí  $\varepsilon$ -kroky pod kterými zásobník neroste neomezeně, tj. po jistém počtu kroků se jeho obsah opakuje.

**Řešení:**  $s = |Q|$ ,  $t = |\Gamma|$

$$r = \max\{|\gamma| \mid (p', \gamma) \in \delta(p, \varepsilon, Z), p, p' \in Q, Z \in \Gamma\}$$

**Komplikace 4:** DPDA dočte slovo, ale pak pod  $\varepsilon$ -kroky prochází koncové i nekoncové stavy (tj. některá slova jsou akceptována původním DPDA i DPDA se zaměněnými koncovými stavy).

**Řešení:**



# Průnik a sjednocení

**Věta.** Třída DCFL **není** uzavřena na průnik.

**Důkaz.**  $L_1 = \{a^n b^n c^m \mid m, n \geq 1\}$  a  $L_2 = \{a^m b^n c^m \mid m, n \geq 1\}$  jsou DCFL, ale  $L_1 \cap L_2 = \{a^n b^n c^n \mid n \geq 1\}$  není ani bezkontextový. □

**Věta.** Třída DCFL **je** uzavřena na průnik s regulárním jazykem.

**Věta.** Třída DCFL **není** uzavřena na sjednocení.

**Důkaz.** Plyne z uzavřenosti na doplněk, neuzavřenosti na průnik a z De Morganových pravidel:

$$L_1 \cap L_2 = \text{co-}(\text{co-}L_1 \cup \text{co-}L_2)$$

(Z uzavřenosti na sjednocení by plynula uzavřenost na průnik.) □

# Vztah deterministických a nedeterministických CFL

**Věta.** Třída DCFL tvoří vlastní podtřidu třídy bezkontextových jazyků. Zejména existují bezkontextové jazyky, které nejsou DCFL.

**Příklad.** Jazyk  $co-\{ww \mid w \in \{a, b\}^*\}$  je CFL, ale není DCFL.

# Aplikace (deterministických) bezkontextových jazyků

- syntaxe programovacích jazyků je definována pomocí CFG (dobře uzávorkované výrazy, *if-then-else* konstrukty)
- DTD (Document Type definition) umožňuje definovat bezkontextové jazyky – využití ve značkovacích jazycích (HTML, XML, ...)
- nástroje pro tvorbu parserů/překladačů využívají různé algoritmy pro lineární deterministickou syntaktickou analýzu:  
LALR(1) - Yacc, Bison, javacup  
LL(k) - JavaCC, ANTLR