

# 456-330/1: Teoretická informatika (TI) přednáška 4



prof. RNDr Petr Jančar, CSc.

katedra informatiky FEI VŠB-TUO  
[www.cs.vsb.cz/jancar](http://www.cs.vsb.cz/jancar)




LS 2009/2010

# (Procedury) konstrukce ZNKA k regulárnímu výrazu


## Sjednocení (Union)



## Zřetězení (Conc)





## Iterace (Iter)



# Syntaxí řízený překlad RV na ZNKA

regulární výraz  
syntaktický strom

$(1*0 + 10)*1$



lineární zápis

$Conc(Iter(Union(Conc(Iter(1), 0), Conc(1, 0))), 1)$

# Bezkontextové gramatiky

Příklad: aritmetické výrazy v abecedě  $\{a, +, \times, (, )\}$   
konkrétní řetězce:  $a + a \times a$ ,  $(a + a) \times a$   
( $a$  je zde atom, reprezentuje např. celé číslo)

$$\langle \text{EXPR} \rangle \longrightarrow a$$

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

$$\langle \text{EXPR} \rangle \longrightarrow \langle \text{EXPR} \rangle \times \langle \text{EXPR} \rangle$$

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

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

*Odvození (derivative)*, slova  $a + a \times a$ :

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


*levá derivace, pravá derivace ...*

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

A ještě příklad derivace, která není ani levá ani pravá:

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

strom odvození (derivační strom)



Těmto různým stromům odpovídají různé levé derivace:

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

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

## *Bezkontextová gramatika*

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

$\Pi$  ... konečná množina *neterminálů*,

$\Sigma$  ... konečná množina *terminálů* ( $\Pi \cap \Sigma = \emptyset$ ),

$S \in \Pi$  ... *počáteční neterminál*

$P$  ... konečná množina pravidel typu

$$A \rightarrow \beta, \text{ kde } A \in \Pi, \beta \in (\Pi \cup \Sigma)^*.$$

Relace  $\Rightarrow$  (resp.  $\Rightarrow_G$ ) na  $(\Pi \cup \Sigma)^*$ :

$$\gamma \Rightarrow \delta$$

jestliže  $(\exists \mu_1, \mu_2, A, \beta :)$

$$\gamma = \mu_1 A \mu_2, \delta = \mu_1 \beta \mu_2, (A \rightarrow \beta) \in P$$

$\Rightarrow^*$  ... reflexivní a tranzitivní uzávěr relace  $\Rightarrow$   
(nejmenší relace, která obsahuje  $\Rightarrow$  a je reflexivní a tranzitivní)

Tedy  $\gamma \Rightarrow^* \delta \iff$  ex. posloupnost  $\mu_0, \mu_1, \dots, \mu_n$  tak, že

$\gamma = \mu_0 \Rightarrow \mu_1 \Rightarrow \dots \Rightarrow \mu_n = \delta$ .

(Derivace (délky  $n$ ) slova  $\delta$  ze slova  $\gamma$ .)

Jazyk generovaný gramatikou  $G$ :  $L(G) = \{ w \in \Sigma^* \mid S \Rightarrow^* w \}$

Jazyk  $L$  je bezkontextový  $\iff_{df}$  ex. BG  $G$  tak, že  $L(G) = L$ .

Značení:

$a, b, c, \dots$  ... (proměnné, jejichž hodnoty jsou) terminály

$u, v, w, \dots$  ... řetězce terminálů

$A, B, C, \dots, X, Y, Z$  ... neterminály

$\alpha, \beta, \gamma, \dots$  ... řetězce neterminálů a terminálů (prvky z  $(\Pi \cup \Sigma)^*$ )

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

$\alpha \Rightarrow^L \beta$  ( $\beta$  vznikne z  $\alpha$  levým přepsáním)  $\Leftrightarrow_{df}$

$\exists u \in \Sigma^*, \delta \in (\Pi \cup \Sigma)^*, (X \rightarrow \gamma) \in P: \alpha = uX\delta, \beta = u\gamma\delta$

$\alpha_0 \Rightarrow \alpha_1 \Rightarrow \dots \Rightarrow \alpha_n$  je levou derivací  $\Leftrightarrow_{df} \alpha_i \Rightarrow^L \alpha_{i+1}$  ( $0 \leq i \leq n-1$ ).



*Derivační strom* (vztahující se ke  $G = (\Pi, \Sigma, S, P)$ ), je uspořádaný kořenový strom, v němž


- vrcholy ohodnoceny prvky  $\Pi \cup \Sigma$ ,
- kořen ohodnocen  $S$ ,
- vrchol ohodnocený  $X (\in \Pi)$  má následníky ohodnocené  $Y_1, Y_2, \dots, Y_n$  ( $Y_i \in \Pi \cup \Sigma$ ), kde  $(X \rightarrow Y_1 Y_2 \dots Y_n) \in P$ ,
- vrchol ohodnocený  $a (\in \Sigma)$  je listem.

Derivační strom pro  $w = a_1 a_2 \dots a_n \dots$  má listy zleva doprava ohodnoceny  $a_1, a_2, \dots, a_n$ .

**Věta.** Každému derivačnímu stromu pro slovo  $w$  (v dané gramatice  $G$ ) přirozeně odpovídá právě jedná levá derivace slova  $w$  (vyvozená z levého průchodu stromem); naopak každé levé derivaci slova  $w$  přirozeně odpovídá právě jeden derivační strom pro  $w$ .

Gramatika slouží nejen pro popis **syntaxe** jazyka; syntaktická struktura (derivační strom) konkrétního slova je obvykle základem také pro vyhodnocení **sémantiky** (významu) slova.

Tím významem může být např. hodnota z nějaké množiny (domény).  
Např. u dříve uvedených aritmetických výrazů je to (celé) číslo či program (cílový kód) k jeho výpočtu ... (interpret, kompilátor ...)



# Překlad RV na (ZN)KA na základě derivačního stromu BG


Omezme se na abecedu  $\Sigma = \{a, b\}$ . Množina regulárních výrazů nad  $\Sigma$  je dána např. následující gramatikou (symboly  $\emptyset, \epsilon$  zde neuvažujeme)

$$R \longrightarrow a \mid b \mid R + R \mid R \cdot R \mid RR \mid R^* \mid (R)$$


regulární výraz

$$(a^*b + a)$$

syntaktický strom




derivační strom



# Konstrukce (ZN)KA na základě derivačního stromu

derivační strom





pro vrchol označený

- $a, b$ : vydej příslušný (elementární) automat;
- $R$  s následníky  $R, +, R$ :  
sestav automat  $A_1$  pro 1. následníka,  $A_2$  pro 3. následníka, a pak sestav a vydej automat  $A$  pro  $L(A_1) \cup L(A_2)$ ;
- $R$  s následníky  $R, \cdot, R$  (podobně pro  $R, R$ ):  
sestav automat  $A_1$  pro 1. následníka,  $A_2$  pro 3. následníka, a pak sestav a vydej automat  $A$  pro  $L(A_1) \cdot L(A_2)$ ;
- $R$  s následníky  $R, *$ : sestav automat  $A_1$  pro 1. následníka, a pak sestav a vydej automat  $A$  pro  $L(A_1)^*$ ;
- $R$  s následníky  $(, R, )$ : vydej automat sestavený pro 2. následníka.

# Nejednoznačné gramatiky

Existence dvou různých derivačních stromů (levých derivací) pro jedno a totéž slovo ... pro překlad (vyhodnocení sémantiky) závada!

Připomeňme si



u gramatiky

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

# Jednoznačné gramatiky a jazyky

BG  $G$  je *jednoznačná*  $\Leftrightarrow_{df}$  každé slovo z  $L(G)$  má právě jeden derivační strom (tj. právě jednu levou derivaci).

V opačném případě je  $G$  *nejednoznačná* (či *víceznačná*).

*Bezkontextový jazyk*  $L$  je *jednoznačný*  $\Leftrightarrow_{df}$  ex. jednoznačná  $G$  tž.  $L(G) = L$ ; jinak se  $L$  nazývá (*vnitřně*) *nejednoznačný* (*víceznačný*).

Např.:

$L_1 = \{ a^n b^n \mid n \geq 0 \}$ :  $S \longrightarrow aSb \mid \varepsilon$  (je jednoznačný)

$L_2 = \{ a^i b^j c^k \mid (i = j) \vee (j = k) \}$ :

$S \longrightarrow S_1 C \mid A S_2$

$S_1 \longrightarrow a S_1 b \mid \varepsilon$        $S_2 \longrightarrow b S_2 c \mid \varepsilon$

$C \longrightarrow c C \mid \varepsilon$        $A \longrightarrow a A \mid \varepsilon$

Fakt: Neex. jednoznačná BG  $G$  tž.  $L(G) = L_2$ . ( $L_2$  je víceznačný.)

Pozn.: problém jednoznačnosti bezkontextové gramatiky je algoritmicky nerozhodnutelný (ukážeme později ...).

K (nejednoznačné) gramatice

$$R \longrightarrow a \mid b \mid R + R \mid RR \mid R^* \mid (R)$$

Ize sestrojít ekvivalentní gramatiku, která je jednoznačná:

$$R \longrightarrow T + R \mid T$$

$$T \longrightarrow FT \mid F$$

$$F \longrightarrow F^* \mid (R) \mid C$$

$$C \longrightarrow a \mid b$$

# Gramatika pro booleovské formule (cvičení)

Uvažujme jazyk sestávající ze všech booleovských formulí s proměnnými  $x_1, x_2, \dots$  a logickými spojkami  $\neg, \wedge, \vee$ ; mohou se v nich používat závorky  $(, )$ , ale není nutné plně závorkovat. Každá taková formule je tedy řetězcem v abecedě

$$\Sigma = \{ x, 0, 1, 2, 3, 4, 5, 6, 7, 8, 9, \neg, \wedge, \vee, (, ) \};$$

jako příklad může sloužit řetězec  $(\neg x_{15} \vee x_2 \wedge x_5) \wedge \neg x_{21} \vee \neg(x_2 \vee x_5)$ , který do jazyka patří. (Samozřejmě zde můžeme preferovat přehlednější zápis  $(\neg x_{15} \vee x_2 \wedge x_5) \wedge \neg x_{21} \vee \neg(x_2 \vee x_5)$ , ale to není podstatné.)

Navrhněte co nejjednodušší bezkontextovou gramatiku generující uvedený jazyk.

Takto navržená (jednoduchá) gramatika asi není jednoznačná; ověřte.

Zkonstruujte pak pro stejný jazyk jednoznačnou gramatiku, u níž derivační stromy přirozeně odpovídají obvyklé prioritě operátorů: negace váže silněji než konjunkce a konjunkce váže silněji než disjunkce.