

# Automaty a gramatiky (BI-AAG)

## 4. *Regulární výrazy*

**Jan Holub**

Katedra teoretické informatiky  
Fakulta informačních technologií  
ČVUT v Praze



© Jan Holub, 2014

# Regulární výrazy

## Definice

*Regulární výraz  $V$  nad abecedou  $\Sigma$  je definován takto:*

1.  $\emptyset, \varepsilon, a$  jsou regulární výrazy pro všechna  $a \in \Sigma$ .
2. Jsou-li  $x, y$  regulární výrazy nad  $\Sigma$ , pak:

(a)  $(x + y)$  (sjednocení, alternativa),

(b)  $(x.y)$  (zřetězení),

(c)  $(x)^*$  (iterace)

jsou regulární výrazy nad  $\Sigma$ .



# Regulární výrazy

## Definice

*Hodnota  $h(x)$  regulárního výrazu  $x$  je definována takto:*

1.  $h(\emptyset) = \emptyset, h(\varepsilon) = \{\varepsilon\}, h(a) = \{a\},$
2.  $h(x + y) = h(x) \cup h(y),$   
 $h(x.y) = h(x).h(y),$   
 $h(x^*) = (h(x))^*.$



# Regulární výrazy — Axiomy

$A_1 : x + (y + z) = (x + y) + z$	(asociativnost sjednocení),
$A_2 : x + y = y + x$	(komutativnost sjednocení),
$A_3 : x + \emptyset = x$	( $\emptyset$ je nulový prvek pro sjednocení),
$A_4 : x + x = x$	(idempotence sjednocení),
$A_5 : x.(y.z) = (x.y).z$	(asociativnost zřetězení),
$A_6 : \varepsilon x = x\varepsilon = x$	( $\varepsilon$ je jednotkový prvek pro zřetězení),
$A_7 : \emptyset x = x\emptyset = \emptyset$	( $\emptyset$ je nulový prvek pro zřetězení),
$A_8 : x.(y + z) = x.y + x.z$	(distributivnost zleva),
$A_9 : (x + y).z = x.z + y.z$	(distributivnost zprava),
$A_{10} : x^* = \varepsilon + x^*x$	
$A_{11} : x^* = (\varepsilon + x)^*$	
$A_{12} : x = x\alpha + \beta \Rightarrow x = \beta\alpha^*$	(řešení levé regulární rovnice),
$A_{13} : x = \alpha x + \beta \Rightarrow x = \alpha^*\beta$	(řešení pravé regulární rovnice).

# Regulární rovnice

## Příklad

$L = \{ \text{sudý počet jedniček následovaný příponou } 010 \}.$

$$(R) \quad x = 11x + 010.$$

řešení:  $x = (11)^*010$

$$(11)^*010 = 11(11)^*010 + 010$$

$$(11)^*010 = (11(11)^* + \varepsilon)010$$

$$(11)^*010 = (11)^*010$$

$$(x = \alpha x + \beta \Rightarrow x = \alpha^* \beta)$$

$$(xy + y = (x + \varepsilon)y)$$

$$(xx^* + \varepsilon = x^*)$$

# Regulární rovnice

## Definice

*Standardní soustava regulárních rovnic* má tvar:

$X_i = \alpha_{i0} + \alpha_{i1}X_1 + \alpha_{i2}X_2 + \dots + \alpha_{in}X_n, 1 \leq i \leq n$ , kde  $X_1, X_2, \dots, X_n$  jsou neznámé a  $\alpha_{ij}$  jsou regulární výrazy nad abecedou  $\Sigma$ , která neobsahuje  $X_1, X_2, \dots, X_n$ . □

# Regulární rovnice

## Příklad

$$\begin{aligned}A &= 1A + 1B \\ B &= 0A + 0B + 0.\end{aligned}$$

$$A = 1^*1B$$

$$B = 01^*1B + 0B + 0.$$

$$B = (01^*1 + 0)B + 0$$

$$B = (01^*1 + 0)^*0 = (0(1^*1 + \varepsilon))^*0 = (01^*)^*0.$$

Řešení:

$$A = 1^*1(01^*)^*0$$

$$B = (01^*)^*0.$$

# Derivace regulárních výrazů

## Definice

Derivace  $\frac{d}{dx}$  regulárního výrazu  $V$  podle řetězce  $x \in \Sigma^*$ :

$$\frac{dV}{dx} = V', h(V') = \{y : xy \in h(V)\}$$



# Derivace regulárních výrazů

## Definice

Derivace  $\frac{d}{dx}$  regulárního výrazu  $V$  podle řetězce  $x \in \Sigma^*$ :

1.  $\frac{dV}{d\varepsilon} = V$

2. pro  $a \in \Sigma$  platí:

$$\frac{d\varepsilon}{da} = \emptyset \quad \frac{d\emptyset}{da} = \emptyset$$

$$\frac{db}{da} = \begin{cases} \emptyset, & \text{jestliže } a \neq b \\ \varepsilon, & \text{jestliže } a = b \end{cases}$$

$$\frac{d(U+V)}{da} = \frac{dU}{da} + \frac{dV}{da}$$

$$\frac{d(UV)}{da} = \frac{dU}{da}V + \left\{ \frac{dV}{da} : \varepsilon \in h(U) \right\}$$

$$\frac{d(V^*)}{da} = \frac{dV}{da} \cdot V^*$$

3. Pro  $x = a_1 a_2 \dots a_n, a_i \in \Sigma$  platí

$$\frac{dV}{dx} = \frac{d}{da_n} \left( \frac{d}{da_{n-1}} \left( \dots \frac{d}{da_2} \left( \frac{dV}{da_1} \right) \dots \right) \right)$$



# Derivace regulárních výrazů

## Příklad

Regulární výraz  $y = (0 + 1)^*.1$ .

$$\begin{aligned}\frac{dy}{d\varepsilon} &= (0 + 1)^*.1 \\ \frac{dy}{d1} &= \frac{d(0+1)^*}{d1}.1 + \frac{d1}{d1} \\ &= \frac{d(0+1)}{d1} \cdot (0 + 1)^*.1 + \varepsilon \\ &= \left(\frac{d0}{d1} + \frac{d1}{d1}\right)(0 + 1)^*.1 + \varepsilon \\ &= (\emptyset + \varepsilon) \cdot (0 + 1)^*.1 + \varepsilon \\ &= (0 + 1)^*.1 + \varepsilon \\ \frac{dy}{d0} &= \frac{d(0+1)^*}{d0}.1 + \frac{d1}{d0} \\ &= \frac{d(0+1)}{d0} \cdot (0 + 1)^*.1 + \emptyset \\ &= (\varepsilon + \emptyset) \cdot (0 + 1)^*.1 + \emptyset \\ &= (0 + 1)^*.1\end{aligned}$$

# Integrál regulárních výrazů

## Definice

*Integrál regulárního výrazu  $V$  podle řetězce  $x \in \Sigma^*$  je definován takto:*

$$h(\int V dx) = \{xy : y \in h(V)\}.$$

Pro integrování regulárních výrazů platí tato pravidla:

1.  $\int V d\varepsilon = V$

2. pro  $a \in \Sigma$  platí:

$$\int \varepsilon da = a,$$

$$\int \emptyset da = \emptyset,$$

$$\int b da = ab,$$

$$\int (U + V) da = \int U da + \int V da,$$

$$\int (U.V) da = aUV,$$

$$\int V^* da = aV^*.$$

3. pro  $x = a_1 a_2 \cdots a_n \in \Sigma^*$  platí:

$$\int V dx = \int \cdots [\int (\int V da_n) da_{n-1}] \cdots da_1.$$

# Integrál regulárních výrazů

$$\frac{d}{dx} \int V \, dx = V,$$
$$\int \frac{dV}{dx} \, dx = V. (?)$$

Integrál zahrnující integrační konstantu  $Z$ :

$$\int V \, dx = xV + Z$$
$$\frac{dZ}{dx} = \emptyset$$

# Integrál regulárních výrazů

## Příklad

Regulární výraz  $(0 + 1)^*.1$ .

$$\begin{aligned}\int (0 + 1)^*.1 \, d1 &= 1.(0 + 1)^*.1 + Z_1, \\ \int (0 + 1)^*.1 \, d0 &= 0.(0 + 1)^*.1 + Z_0.\end{aligned}$$

# Úprava regulárních výrazů

## Definice

- (a) regulární výrazy  $x, y$  nazveme *identické* (označíme  $x \equiv y$ ), jestliže  $x$  a  $y$  jsou úplně stejné řetězce symbolů.
- (b) regulární výrazy  $x, y$  nazveme *ekvivalentní* (označíme  $x = y$ ), jestliže mají stejnou hodnotu,  $h(x) = h(y)$ , tj. regulární množiny, které tyto výrazy popisují, jsou stejné.
- (c) regulární výrazy  $x, y$  nazveme *podobné*, jestliže se dají na sebe převést pomocí následujících identit:

$$x + x = x$$

$$x + y = y + x$$

$$(x + y) + z = x + (y + z)$$

$$x + \emptyset = x$$

$$x.\emptyset = \emptyset.x = \emptyset$$

$$x.\varepsilon = \varepsilon.x = x$$

# Úprava regulárních výrazů

Věty v axiomatické teorii regulárních výrazů

$$V_1 : \quad \emptyset^* = \varepsilon$$

$$V_2 : \quad x^* + x = x^*$$

$$V_3 : \quad (x^*)^* = x^*$$

$$V_4 : \quad (x + y)^* = (x^*y^*)^*$$

$$V_5 : \quad x^*y = y + x^*xy$$

$$V_6 : \quad x^*y = y + xx^*y$$

$$V_7 : \quad x^*y = (x^n)^*.(y + xy + x^2y + \dots + x^{n-1}y)$$

$$V_8 : \quad \textbf{Jestliže } \varepsilon \in h(x), \textbf{ pak } xx^* = x^*$$

$$V_9 : \quad (xy)^*x = x(yx)^*$$

$$V_{10} : \quad (x + y)^* = (x^* + y^*)^*$$

# Úprava regulárních výrazů

## Příklad

Regulární výrazy

$$x = \varepsilon + 1^*(011)^*(1^*(011)^*)^*$$

$$y = (1 + 011)^*$$

Jsou ekvivalentní?

$$\begin{aligned} x &= \varepsilon + 1^*(011)^*(1^*(011)^*)^* \\ &= (1^*(011)^*)^* \\ &= (1 + 011)^* \\ &= y. \end{aligned}$$

$$\begin{aligned} \varepsilon + xx^* &= x^* \\ (x^*y^*)^* &= (x + y)^* \end{aligned}$$



# Úprava regulárních výrazů

## Příklad

Je výraz  $(\varepsilon + \emptyset)(0 + 1)^*1 + (0 + 1)^*\emptyset$  podobný výrazu  $(0 + 1)^*1$ ?

$$\begin{aligned} &(\varepsilon + \emptyset)(0 + 1)^*1 + (0 + 1)^*\emptyset = \\ &= (\varepsilon + \emptyset)(0 + 1)^*1 + \emptyset = \\ &= (\varepsilon + \emptyset)(0 + 1)^*1 = \\ &= \varepsilon(0 + 1)^*1 = \\ &= (0 + 1)^*1. \end{aligned}$$

$$x.\emptyset = \emptyset$$

$$x + \emptyset = x$$

$$x + \emptyset = x$$

$$\varepsilon.x = x$$



# Úprava regulárních výrazů

## Příklad


Ekvivalentní RV, které se na sebe nedají převést:

●  $B = (10^*1 + 1)^*(10^*1 + 0)$

●  $B' = 0^*(1(0 + 10^*1)^*(100^* + 1) + 0)$

# Vztahy mezi formálními systémy pro r.j.

Vztahy mezi formálními systémy pro popis regulárních jazyků



# Vztah mezi reg. gr. a koneč. automaty

**Algoritmus** Konstrukce NKA pro danou pravou reg. gr.

**Vstup:** Pravá regulární gramatika  $G = (N, T, P, S)$ .

**Výstup:** NKA  $M = (Q, T, \delta, q_0, F)$  takový, že  $L(G) = L(M)$ .

**Metoda:**

1. Množina vstupních symbolů automatu  $M$  je rovna  $T$ .
2. Množina stavů  $Q = N \cup \{A\}$ ,  $A \notin N$ .
3. Zobrazení  $\delta$ :  
je-li  $B \rightarrow aC \in P$ , pak  $\delta(B, a)$  obsahuje  $C$ ,  
je-li  $B \rightarrow a \in P$ , pak  $\delta(B, a)$  obsahuje  $A$ .
4.  $q_0 = S$ .
5.  $F = \{S, A\}$ , jestliže  $S \rightarrow \varepsilon \in P$ ,  
 $F = \{A\}$ , jestliže  $S \rightarrow \varepsilon \notin P$ .


# Vztah mezi reg. gr. a koneč. automaty

## Příklad

$$G = (\{C\}, \{d\}, \{C \rightarrow d \mid dC\}, C).$$

$$M = (\{C, A\}, \{d\}, \delta, C, \{A\}), \text{ kde } \delta:$$

$\delta$	$d$
$C$	$\{C, A\}$
$A$	



# Vztah mezi reg. gr. a koneč. automaty

## Příklad


$G = (\{ID, ZI\}, \{p, c\}, P, ID)$ , kde  $P$  obsahuje pravidla:

$ID \rightarrow p ZI \mid p$

$ZI \rightarrow p ZI \mid c ZI \mid p \mid c$ .

(Gramatika generuje identifikátory podle obvyklé definice ( $p$  – písmeno,  $c$  – číslice).)

$M = (\{ID, ZI, A\}, \{p, c\}, \delta, ID, \{A\})$ , kde  $\delta$



$\delta$	$p$	$c$
$ID$	$\{ZI, A\}$	
$ZI$	$\{ZI, A\}$	$\{ZI, A\}$
$A$		

# Vztah mezi reg. gr. a koneč. automaty

## Příklad


Jazyk, který obsahuje řetězce tvaru:  $list\ id; c; id; id; \dots; c; c; id\#$

$G = (\{S, L, R\}, \{list, id, c, ;, \#\}, P, S)$ , kde  $P$ :

$S \rightarrow list\ L, L \rightarrow id\ R \mid c\ R, R \rightarrow ;\ L \mid \#$

$M = (\{S, L, R, A\}, \{list, id, c, \#, ;\}, \delta, S, \{A\})$ , kde  $\delta$ :

$\delta$	$list$	$id$	$c$	$;$	$\#$
$S$	$L$				
$L$		$R$	$R$		
$R$				$L$	$A$
$A$					



# Vztah mezi reg. gr. a koneč. automaty

**Algoritmus** Konstrukce NKA pro levou regulární gramatiku.

**Vstup:** Levá regulární gramatika  $G = (N, T, P, S)$ .

**Výstup:** NKA  $M = (Q, T, \delta, q_0, F)$  takový, že  $L(G) = L(M)$ .

**Metoda:**

1. Množina vstupních symbolů automatu  $M$  je rovna  $T$ .
2. Množina stavů  $Q = N \cup \{q_0\}$ .
3. Zobrazení  $\delta$ :  
Je-li  $A \rightarrow Ba \in P$ , pak  $\delta(B, a)$  obsahuje  $A$ ,  
je-li  $A \rightarrow a \in P$ , pak  $\delta(q_0, a)$  obsahuje  $A$ .
4.  $q_0 \in Q$  je počáteční stav automatu  $M$ .
5. Je-li  $S \rightarrow \varepsilon \in P$ , pak  $F = \{S, q_0\}$ ,  
v opačném případě  $F = \{S\}$ .




# Vztah mezi reg. gr. a koneč. automaty

## Příklad

Levá regulární gramatika  $G = (\{S, I, N\}, \{c, p, \#\}, P, S)$ , kde  $P$ :  
 $S \rightarrow I\# \mid N\#, I \rightarrow p \mid Ip \mid Ic, N \rightarrow c \mid Nc$ .

NKA  $M = (\{S, I, N, q_0\}, \{c, p, \#\}, \delta, q_0, \{S\})$ , kde  $\delta$ :



	<i>c</i>	<i>p</i>	#
<i>S</i>			
<i>I</i>	<i>I</i>	<i>I</i>	<i>S</i>
<i>N</i>	<i>N</i>		<i>S</i>
<i>q</i> <sub>0</sub>	<i>N</i>	<i>I</i>	

# Vztah mezi koneč. automaty a reg. gr.

**Algoritmus** Konstrukce pravé reg. gramatiky pro daný NKA

**Vstup:** NKA  $M = (Q, T, \delta, q_0, F)$ .

**Výstup:** Pravá reg. gramatika  $G = (N, T, P, S)$ ,  $L(M) = L(G)$ .


**Metoda:**

1.  $N = Q$ .
2.  $P$  sestrojíme takto:
  - (a) Jestliže  $\delta(B, a)$  obsahuje  $C$ , pak  $B \rightarrow aC$  dáme do  $P$ .
  - (b) Jestliže  $\delta(B, a)$  obsahuje  $C$  a  $C \in F$ , pak  $B \rightarrow a$  dáme do  $P$ .
  - (c) Symbol  $S = q_0$ .
  - (d) Jestliže  $q_0 \in F$  a  $S$  není na pravé straně, pak  $S \rightarrow \varepsilon$  dáme do  $P$  a počáteční symbol je  $S$ .
  - (e) Jestliže  $q_0 \in F$  a  $S$  je na pravé straně, pak přidáme do  $P$  pravidla tvaru  $S' \rightarrow \alpha$ , kde  $\alpha$  jsou pravé strany pravidel tvaru  $S \rightarrow \alpha$ ,  $S'$  je počáteční symbol a pravidlo  $S' \rightarrow \varepsilon$  přidáme do  $P$ .

# Vztah mezi koneč. automaty a reg. gr.

## Příklad

Sestrojíme pravou regulární gramatiku pro NKA:




Výsledná regulární gramatika  $G = (\{ID, ZI, A\}, \{p, c\}, P, ID)$ , kde  $P$ :

$$ID \rightarrow pZI \mid p \mid pA$$
$$ZI \rightarrow pZI \mid pA \mid cZI \mid cA \mid p \mid c.$$

# Vztah mezi koneč. automaty a reg. gr.

## Příklad

Sestrojíme pravou regulární gramatiku pro NKA:



$G = (\{A, B, C\}, \{a, b\}, P, A)$ , kde  $P$ :

$A \rightarrow aA \mid aB \mid bA$

$B \rightarrow bC \mid b.$