

# Automaty a gramatiky (BI-AAG)

## *8. Vlastnosti regulárních jazyků*

**Jan Holub**

Katedra teoretické informatiky  
Fakulta informačních technologií  
ČVUT v Praze



© Jan Holub, 2014

# Pumping lemma – podstata problému

Předpokládejme, že by jazyk  $L = \{0^n 1^n : n \geq 1\}$  byl regulární.

V takovém případě by jazyk  $L$  byl přijímaný konečným automatem  $\mathcal{A}$  s  $k$  stavy.

# Pumping lemma – podstata problému

Nechť automat  $\mathcal{A}$  čte posloupnost  $0^k$ . Při čtení této posloupnosti je průchod jednotlivými stavy následující:

$\varepsilon$        $p_0$

0       $p_1$

00       $p_2$

...      ...

$0^k$        $p_k$

t.j.,  $\exists i < j : p_i = p_j$ . Označme takový stav  $q$ .

# Pumping lemma – vyřešení problému

Předpokládejme dále, že přečtením vstupní posloupnosti  $1^i$  se automat dostane ze stavu  $q$  do stavu  $r$ .

Platí, že:

- Pokud by stav  $r$  byl koncovým stavem, pak by automat přijímal větu  $0^j 1^i$ , což nechceme.
- Pokud by stav  $r$  nebyl koncovým stavem, pak by automat nepřijal větu  $0^i 1^i$ , což také ale nechceme.

Proto jazyk  $L = \{0^n 1^n : n \geq 1\}$  nemůže být regulární.

# Pumping lemma formálně


## Pumping lemma

Nechť  $L$  je regulární jazyk. Pak pro jazyk  $L$  existuje konstanta  $p \geq 1$  taková, že pro každou větu  $w \in L$  platí: Jestliže  $|w| \geq p$ , pak  $w$  lze zapsat ve tvaru  $w = xyz$  tak, že:

- $y \neq \varepsilon$  (t.j.  $|y| \geq 1$ ),
- $|xy| \leq p$ ,
- $\forall i \geq 0$  platí, že  $xy^iz \in L$ .

# Pumping lemma neformálně

Pro jazyk  $L$  existuje konečný automat a v něm je smyčka. Tato smyčka čte neprázdný podřetěz  $y$ . Platí, že tato smyčka se může libovolně-krát „pumpovat“. Pokud je  $z \in L$ , pak i pro každé  $i$ -násobné „pumpování“ pro  $i \geq 0$  platí, že  $xy^iz \in L$ .



# Použití PL k důkazu, že $L$ není reg.

**Důkaz, že jazyk  $L = \{0^n 1^n : n \geq 1\}$  není regulární**

Předpokládejme, že  $L$  je regulární. Pak pomocí pumping lemmatu musí platit, že existuje konstanta  $p \geq 1$  taková, že pro každou větu  $w \in L$  platí, že:

Jestliže  $|w| \geq p$ , pak  $w$  lze zapsat ve tvaru  $w = xyz$  tak, že:

- $y \neq \varepsilon$  (t.j.  $|y| \geq 1$ ),
- $|xy| \leq p$ ,
- $\forall i \geq 0$  platí, že  $xy^i z \in L$ .

Věta  $w = 0^p 1^p \in L$  je zřejmě delší než  $p$  a tudíž musí splňovat požadavky PL. K důkazu, že  $L$  není regulární, zkusíme všechna možná rozdělení věty  $w$  na  $xyz$ . Musíme pak dokázat, že PL neplatí pro žádné z nich.

# Použití PL k důkazu, že $L$ není reg.

**Důkaz, že jazyk  $L = \{0^n 1^n : n \geq 1\}$  není regulární**

Podle prvních dvou podmínek musí platit:

- $xy$  je neprázdná posloupnost nul,
- $y$  je neprázdná posloupnost nul,
- $z$  obsahuje všechny jedničky.

Ale pak  $xy^0z$  (čili odstraníme  $y$  z  $w = xyz$ ) nepatří do  $L$  (protože počet nul v  $xy^0z$  je určitě menší než počet jedniček)!

Proto pumping lemma neplatí pro  $L$  a  $L$  není regulární jazyk.



# Použití PL k důkazu, že $L$ není reg.

**Důkaz, že jazyk  $L = \{1^m : m \text{ je prvočíslo}\}$  není regulární**

Předpokládejme, že  $L$  je regulární. Pak pomocí pumping lemmatu musí platit, že existuje konstanta  $p \geq 1$  taková, ... (viz Pumping Lemma):

Předpokládejme větu  $w = 1^m$  pro prvočíslo  $m \geq p + 2$ .

Nyní předpokládejme rozdělení  $w = xyz$  a „napumpovanou“ větu  $w_1 = xy^{m-|y|}z$ . Ukážeme, že  $w_1$  nepatří do  $L$ , což rozporuje Pumping lemma.

# Použití PL k důkazu, že $L$ není reg.

**Důkaz, že jazyk  $L = \{1^m : m \text{ je prvočíslo}\}$  není regulární**

Uvažujme délku věty  $w_1 = xy^{m-|y|}z$ . Pak platí, že

$$\begin{aligned} |xy^{m-|y|}z| &= \\ |xz| + (m - |y|) * |y| &= \\ (m - |y|) + (m - |y|) * |y| &= \\ (m - |y|) * (1 + |y|). \end{aligned}$$

$w_1$  by bylo prvočíslem, pouze kdyby buďto  $(m - |y|)$  nebo  $(1 + |y|)$  byly rovné jedné.

# Použití PL k důkazu, že $L$ není reg.

**Důkaz, že jazyk  $L = \{1^m : m \text{ je prvočíslo}\}$  není regulární**

- $(1 + |y|) \neq 1$ , protože  $|y| \geq 1$ .
- $m \geq p + 2$ ,  $|y| \leq |xy| \leq p$ , proto  $m - |y| \geq p + 2 - p = 2$ .

Pumping Lemma neplatí pro jazyk  $L$ , neboť pro libovolné rozdělení  $w = xyz \in L$  podle první ze dvou podmínek PL platí, že  $xy^{m-|y|}z$  nepatří do  $L$ .

Proto,  $L$  **není regulární**.

# PL pouze k důkazu, že $L$ není reg.

Příklad jazyka, který splňuje podmínky PL, ale není regulární.

●  $L = \{u \mid u = a^+b^ic^i \vee u = b^ic^j\}$

# Kontrolní otázka

Jak velká je konstanta  $p$  v Pumping lemmatu pro *konečný* jazyk?

(Poznámka: Každý konečný jazyk je regulární, a proto pro něj musí platit podmínky Pumping Lemmatu.)

# Myhill-Nerodova věta: motivace

- MNv charakterizuje některé zásadní vztahy mezi konečnými automaty nad abecedou  $\Sigma$  a jistými ekvivalenčními relacemi nad řetězci ze  $\Sigma^*$ ,
- MNv popisuje některé z nutných a postačujících podmínek pro to, aby daný jazyk byl jazykem regulárním (používá se často k důkazu neregularity jazyka),
- MNv poskytuje formální bázi pro elegantní důkaz existence unikátního (až na isomorfismus) minimálního DKA k danému regulárnímu jazyku.

# Ekvivalence

## Definice

*Ekvivalence*  $\sim$  je binární relace, která je *reflexivní*, *symetrická* a *tranzitivní*.

## Definice

*Třída ekvivalence* prvku  $a$  na množině  $X$  je podmnožina  $X$ , obsahující prvky ekvivalentní s  $a$ .

## Definice

Množina všech tříd ekvivalence v  $X$  se nazývá *rozklad množiny*  $X$  podle  $\sim$  a značí se  $X / \sim$ .

## Definice

*Index ekvivalence*  $\sim$  je počet tříd ekvivalence v  $\Sigma / \sim$ . Jestliže existuje nekonečně mnoho tříd ekvivalence, definujeme index jako  $\infty$ .

# Pravá kongruence a prefixová ekv.

## Definice

Nechť  $\Sigma$  je abeceda a  $\sim$  je ekvivalence na  $\Sigma^*$ . Ekvivalence  $\sim$  je *pravou kongruencí*, jestliže pro každé  $u, v, w \in \Sigma^*$  platí, že:

$$u \sim v \Rightarrow uw \sim vw$$

## Definice

Nechť  $L$  je libovolný (ne nutně regulární) jazyk nad abecedou  $\Sigma$ .

Definujeme *prefixovou ekvivalenci* pro  $L$ , jako relaci  $\sim_L$  na množině  $\Sigma^*$  následovně:

$$u \sim_L v \Leftrightarrow \forall w \in \Sigma^* : uw \in L \Leftrightarrow vw \in L$$



# Myhill-Nerodova věta

## Myhill-Nerodova věta

Nechť  $L$  je jazyk nad  $\Sigma$ . Pak následující tvrzení jsou ekvivalentní:

1.  $L$  je jazyk přijímaný deterministickým konečným automatem.
2.  $L$  je sjednocením některých tříd rozkladu určeného pravou kongruencí na  $\Sigma^*$  s konečným indexem.
3. Relace  $\sim_L$  má konečný index.

*Důkaz.* Dokážeme následující implikace:

●  $1 \Rightarrow 2.$

●  $2 \Rightarrow 3.$

●  $3 \Rightarrow 1.$

# Myhill-Nerodova věta: $1 \Rightarrow 2$

Je-li  $L$  přijímán DKA, pak  $L$  je sjednocením některých tříd rozkladu určeného pravou kongruencí na  $\Sigma^*$  s konečným indexem.

Zaved'me si pro DKA  $M = (Q, \Sigma, \delta, q_0, F)$  zobecněnou přechodovou funkci  $\hat{\delta}$ .

$\hat{\delta} : Q \times \Sigma^* \rightarrow Q$  tak, že

$\forall q_1, q_2 \in Q, w \in \Sigma^* : \hat{\delta}(q_1, w) = q_2 \Leftrightarrow (q_1, w) \vdash_M^* (q_2, \varepsilon).$

# Myhill-Nerodova věta: $1 \Rightarrow 2$

*Důkaz.* Pro daný jazyk  $L$  přijímaný DKA  $M$  zkonstruujeme  $\sim$  s potřebnými vlastnostmi:

- Necht'  $M = (Q, \Sigma, \delta, q_0, F)$  a  $\delta$  je úplná.
- Zvolíme  $\sim$  jako binární relaci na  $\Sigma^*$  takovou, že  $u \sim v \Leftrightarrow \hat{\delta}(q_0, u) = \hat{\delta}(q_0, v)$ .
- Ukážeme, že  $\sim$  má potřebné vlastnosti:
  - $\sim$  je ekvivalence: je reflexivní, tranzitivní a symetrická.
  - $\sim$  má konečný index: třídy rozkladu odpovídají stavům DKA.
  - $\sim$  je pravá kongruence: Necht'  $u \sim v$  a  $a \in \Sigma$ . Pak  $\hat{\delta}(q_0, ua) = \delta(\hat{\delta}(q_0, u), a) = \delta(\hat{\delta}(q_0, v), a) = \hat{\delta}(q_0, va)$  a tedy  $ua \sim va$ .
  - $L$  je sjednocením některých tříd ekvivalence  $\Sigma^* / \sim$  – těch, které odpovídají  $F$ .

# Myhill-Nerodova věta: $2 \Rightarrow 3$

Existuje-li relace  $\sim$  splňující podmínku 2, pak  $\sim_L$  má konečný index.

*Důkaz.*

- Pro všechny  $u, v \in \Sigma^*$  takové, že  $u \sim v$ , platí  $u \sim_L v$ :
  - Nechť  $u \sim v$ . Ukážeme, že také  $u \sim_L v$ , tj.  
 $\forall w \in \Sigma^* : uw \in L \Leftrightarrow vw \in L$ .
  - Víme, že  $uw \sim vw$  a protože  $L$  je sjednocením některých tříd rozkladu  $\Sigma^* / \sim$ , platí také  $uw \in L \Leftrightarrow vw \in L$ .
- Víme tedy, že  $\sim \subseteq \sim_L$  (tj.  $\sim_L$  je největší pravá kongruence s danými vlastnostmi).
- Každá třída  $\sim$  je obsažena v nějaké třídě  $\sim_L$ .
- Index  $\sim_L$  nemůže být větší než index  $\sim$ .
- $\sim$  má konečný index a tedy i  $\sim_L$  má konečný index.

# Myhill-Nerodova věta: $3 \Rightarrow 1$

Má-li  $\sim_L$  konečný index, pak  $L$  je přijímán nějakým konečným automatem.

*Důkaz.*

- Vytvoříme  $M = (Q, \Sigma, \delta, q_0, F)$  přijímající  $L$ :
  - $Q = \Sigma^* / \sim_L$  (stavy jsou třídy rozkladu  $\Sigma^*$  relací  $\sim_L$ ),
  - $\forall u \in \Sigma^*, a \in \Sigma : \delta([u], a) = [ua]$ ,
  - $q_0 = [\varepsilon]$ ,
  - $F = \{[x] \mid x \in L\}$ .
- Uvedená konstrukce je korektní, tj.  $L = L(M)$ :
  - Indukcí nad délkou slova  $v$  ukážeme, že
$$\forall v \in \Sigma^* : \hat{\delta}([\varepsilon], v) = [v].$$
  - $v \in L \Leftrightarrow [v] \in F \Leftrightarrow \hat{\delta}([\varepsilon], v) \in F$ .

# Důkaz neregularity pomocí M.-N. věty

Dokažte, že jazyk  $L = \{0^n 1^n : n \geq 1\}$  není regulární.

*Důkaz.*

- Žádné řetězce  $\varepsilon, 0, 0^2, 0^3, \dots$  nejsou  $\sim_L$ -ekvivalentní, protože  $0^i 1^i \in L$ , ale  $0^i 1^j \notin L$  pro  $i \neq j$ .
- $L$  má tedy nekonečně mnoho tříd (neboli nekonečný index).
- Podle Myhill-Nerodovy věty tedy nemůže být jazyk  $L$  přijímán žádným konečným automatem.

# M.-N. věta a minimalita DKA

## Věta (2. varianta M.-N. věty)

Počet stavů libovolného minimálního DKA přijímajícího jazyk  $L$  je roven indexu  $\sim_L$ . (Takový DKA existuje právě tehdy, když je index  $\sim_L$  konečný.)

*Důkaz.*

- Každý DKA (bez nedosažitelných stavů) určuje jistou pravou kongruenci s konečným indexem a naopak.
- Je-li  $L$  regulární,  $\sim_L$  je největší pravou kongruencí s konečným indexem takovou, že  $L$  je sjednocením některých tříd příslušného rozkladu.
- Konečný automat, který odpovídá  $\sim_L$  (viz důkaz  $3 \Rightarrow 1$  M.-N. věty), je tedy minimální konečný automat přijímající  $L$ .