

# Obsah přednášky

## Základy matematiky a statistiky pro humanitní obory

|

Pavel Rychlý Vojtěch Kovář

Fakulta informatiky, Masarykova univerzita  
Botanická 68a, 602 00 Brno, Czech Republic  
 {par, xkovar3}@fi.muni.cz

část 7

### Formální lingvistika

- ▶ Matematické modely jazyka
  - ▶ jazyk = množina slov nad nějakou abecedou
  - ▶ prvky abecedy mohou být znaky, slova, ...
  - ▶ původně navrženy k popisu přirozených jazyků
  - ▶ dnes rozlišujeme tzv. **formální jazyky**
- ▶ Cíl přednášky
  - ▶ seznámit se se základními konstrukcemi teorie formálních jazyků
  - ▶ → schopnost používat je v dalších kurzech

### Formální lingvistika – základní pojmy

- ▶ abeceda
  - ▶ množina symbolů  $\Sigma$  (např.  $\{a, b\}$ )
- ▶ slovo
  - ▶ libovolná konečná posloupnost prvků  $\Sigma$
  - ▶ např.  $aabab$
- ▶ délka slova  $|v|$ 
  - ▶ počet prvků této posloupnosti
  - ▶ např.  $|aabab| = 5$
- ▶ prázdné slovo  $\epsilon$ 
  - ▶ slovo nulové délky

## Formální lingvistika – základní pojmy (II)

- ▶ množina  $\Sigma^*$ 
  - ▶ množina všech slov nad abecedou  $\Sigma$
  - ▶ např.  $\{a, b\}^* = \{\epsilon, a, b, aa, bb, ab, ba, aab, abb, \dots\}$
- ▶ operace zřetězení slov „.“
  - ▶ pro slova  $u, v$ :  $u.v = uv$
  - ▶ např.  $aab.ab = aabab$
- ▶ mocnina slova  $u^i$ 
  - ▶ definována induktivně:  $u^0 = \epsilon; u^{i+1} = u.u^i$
  - ▶ např.  $(ab)^3 = ababab$
- ▶ Jazyk
  - ▶ množina (některých) slov nad danou abecedou
  - ▶ pro každý jazyk  $L$  platí  $L \subseteq \Sigma^*$

## Formální gramatika

- ▶ Čtveřice  $(N, \Sigma, P, S)$ 
  - ▶  $N$  – množina neterminálů
  - ▶  $\Sigma$  – množina terminálů (symbolů abecedy)
  - ▶  $\rightarrow N \cap \Sigma = \emptyset$
  - ▶  $\rightarrow N \cup \Sigma$  označíme  $V$  (množina symbolů)
  - ▶  $P \subseteq (V^*.N.V^*)x(V^*)$  – množina pravidel
  - ▶  $S$  – počáteční symbol gramatiky
- ▶ Pravidla gramatiky
  - ▶  $(\alpha, \beta)$  zapisujeme jako  $\alpha \rightarrow \beta$
  - ▶  $\alpha, \beta$  jsou slova nad  $V$  (řetězce terminálů a neterminálů)
  - ▶ kde  $\alpha$  obsahuje alespoň jeden neterminál

## Formální lingvistika – základní pojmy (III)

- ▶ zřetězení jazyků
  - ▶  $L_1.L_2 = \{u.v \mid u \in L_1 \wedge v \in L_2\}$
- ▶ podobně i další operace nad jazyky

## Odvození z gramatiky

- ▶ Gramatika je model, který generuje jazyk
  - ▶ začneme počátečním neterminálem
  - ▶ používáme pravidla gramatiky jako přepisovací systém
  - ▶  $\rightarrow$  tj. levou stranu pravidla nahradíme pravou
  - ▶ přepisujeme tak dlouho, dokud nedostaneme řetězec terminálů
- ▶ Vztah jazyka a gramatiky
  - ▶ **gramatika  $G$  generuje jazyk  $L$** , pokud existuje odvození každého slova jazyka  $L$  z gramatiky  $G$
  - ▶ značíme  $L(G)$

## Odvození z gramatiky – příklad

### ► Gramatika

- $\Sigma = \{a, b\}$ ,  $N = \{S, A\}$
- $P = \{ S \rightarrow A, \quad A \rightarrow AA, \quad A \rightarrow a \}$

### ► Příklady odvození

- $S \Rightarrow A \Rightarrow a$
- $S \Rightarrow A \Rightarrow AA \Rightarrow aA \Rightarrow aAA \Rightarrow aaA \Rightarrow aaa$
- kolik slov obsahuje jazyk generovaný touto gramatikou?

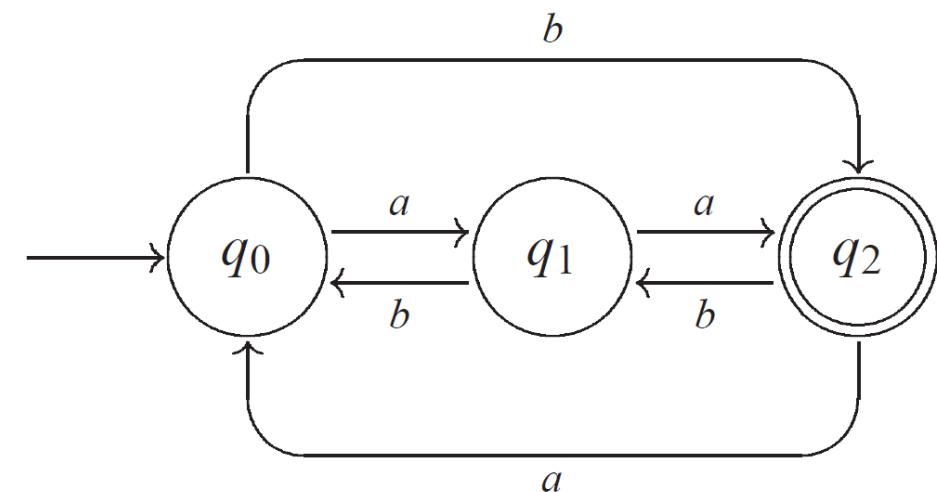
## Konečný automat

- Jiný model charakterizující jazyky
- Pětice  $(Q, \Sigma, \delta, q_0, F)$ 
  - $Q$  – neprázdná konečná množina stavů
  - $\Sigma$  – konečná množina vstupních symbolů (abeceda)
  - $\delta : Q \times \Sigma \rightarrow Q$  – přechodová funkce
  - $q_0$  – počáteční stav
  - $F$  – množina koncových stavů
- Automat necháváme běžet nad vstupním slovem
  - začneme v počátečním stavu
  - podle dalšího symbolu na vstupu a aktuálního stavu se přesuneme do jiného stavu
  - opakujeme, dokud není slovo dočteno do konce

## Chomského hierarchie gramatik

- Typy gramatik podle omezení na pravidla
- typ 0
  - žádná omezení
- typ 1
  - pro každé pravidlo  $\alpha \rightarrow \beta$  je  $|\alpha| \leq |\beta|$
  - též kontextová gramatika
- typ 2
  - každé pravidlo je tvaru  $A \rightarrow \beta$  ( $A \in N$ )
  - též bezkontextová gramatika
- typ 3
  - každé pravidlo je tvaru  $A \rightarrow aB$  nebo  $A \rightarrow a$  ( $A, B \in N; a \in \Sigma$ )
  - též regulární gramatika

## Konečný automat



## Automaty a jazyky

### ► Automaty a jazyky

- ▶ automat akceptuje slovo, pokud po jeho zpracování skončí v akceptujícím stavu
- ▶ automat akceptuje jazyk, pokud akceptuje právě slova jazyka

### ► Automaty a gramatiky

- ▶ pro každou regulární gramatiku  $G$  existuje automat, který akceptuje jazyk  $L(G)$  (důkaz existuje :))
- ▶ platí i naopak → **ekvivalentní formalismy**

### ► Co se nevešlo

- ▶ existují i další typy automatů
- ▶ některé ekvivalentní s jinými typy gramatik
- ▶ např. zásobníkový automat, Turingův stroj