

Obsah přednášky

Základy matematiky a statistiky pro humanitní obory

|

Pavel Rychlý Vojtěch Kovář

Fakulta informatiky, Masarykova univerzita
Botanická 68a, 602 00 Brno, Czech Republic
 {parry, 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

Formální gramatika

Konečný automat

Formální lingvistika – základní pojmy

► abeceda

- ▶ množina symbolů Σ (např. $\{a, b\}$)

► slovo

- ▶ libovolná konečná posloupnost prvků Σ
- ▶ např. $aabab$

► délka slova $|v|$

- ▶ počet prvků této posloupnosti
- ▶ např. $|aabab| = 5$

► prázdné slovo ϵ

- ▶ slovo nulové délky

Formální lingvistika – základní pojmy (II)

► množina Σ^*

- ▶ množina všech slov nad abecedou Σ
- ▶ 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, Σ, P, S)

- ▶ N – množina neterminálů
- ▶ Σ – 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

- ▶ (α, β) zapisujeme jako $\alpha \rightarrow \beta$
- ▶ α, β jsou slova nad V (řetězce terminálů a neterminálů)
- ▶ kde α 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?

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 $A \rightarrow aB$ ($A, B \in N; a \in \Sigma$)
- ▶ též **regulární gramatika**

Konečný automat Konečný automat

Konečný automat

► Jiný model charakterizující jazyky

► Pětice $(Q, \Sigma, \delta, q_0 F)$

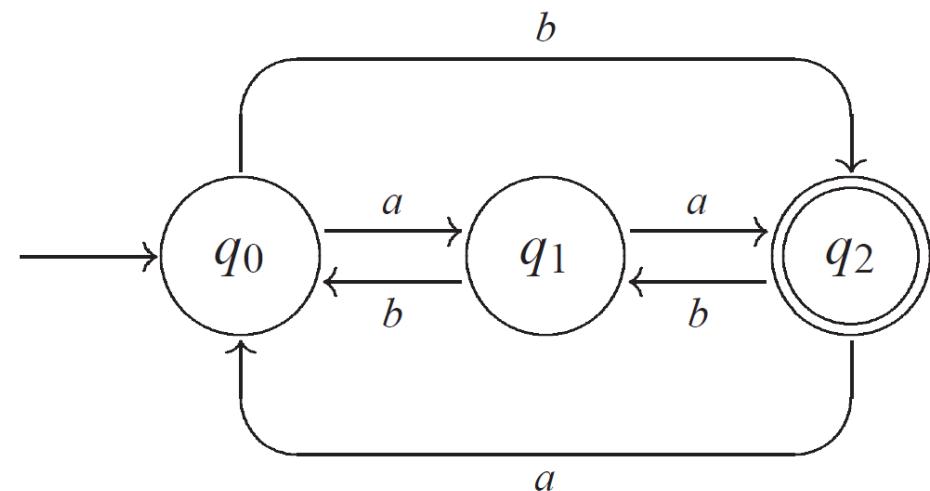
- ▶ Q – neprázdná konečná množina stavů
- ▶ Σ – konečná množina vstupních symbolů (abeceda)
- ▶ $\delta : Q \times \Sigma \rightarrow Q$ – přechodová funkce
- ▶ q_0 – počáteční stav
- ▶ F – množina koncových stavů

► 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

Konečný automat Konečný automat

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