

Obsah přednášky

Základy matematiky a statistiky pro humanitní obory

I

Pavel Rychlý Vojtěch Kovář

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

část 7

Formální lingvistika

Formální gramatika

Konečný automat

Formální lingvistika	Formální lingvistika – základní pojmy
<ul style="list-style-type: none"> ▶ Matematické modely jazyka <ul style="list-style-type: none"> ▶ 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 <ul style="list-style-type: none"> ▶ seznámit se se základními konstrukcemi teorie formálních jazyků ▶ → schopnost používat je v dalších kurzech 	<ul style="list-style-type: none"> ▶ abeceda <ul style="list-style-type: none"> ▶ množina symbolů Σ (např. $\{a, b\}$) ▶ slovo <ul style="list-style-type: none"> ▶ libovolná konečná posloupností prvků Σ ▶ např. $aabb$ ▶ délka slova v <ul style="list-style-type: none"> ▶ počet prvků této posloupnosti ▶ např. $aabab = 5$ ▶ prázdné slovo ϵ <ul style="list-style-type: none"> ▶ slovo nulové délky

Formální lingvistika – základní pojmy (II)	Formální lingvistika – základní pojmy (III)
<ul style="list-style-type: none"> ▶ množina Σ^* <ul style="list-style-type: none"> ▶ množina všech slov nad abecedou Σ ▶ např. $\{a, b\}^* = \{\epsilon, a, b, aa, bb, ab, ba, aab, abb, \dots\}$ ▶ operace zřetězení slov „.“ <ul style="list-style-type: none"> ▶ pro slova u, v: $u.v = uv$ ▶ např. $aab.ab = aabab$ ▶ mocnina slova u^i <ul style="list-style-type: none"> ▶ definována induktivně: $u^0 = \epsilon; u^{i+1} = u.u^i$ ▶ např. $(ab)^3 = ababab$ ▶ Jazyk <ul style="list-style-type: none"> ▶ množina (některých) slov nad danou abecedou ▶ pro každý jazyk L platí $L \subseteq \Sigma^*$ 	<ul style="list-style-type: none"> ▶ zřetězení jazyků <ul style="list-style-type: none"> ▶ $L_1.L_2 = \{u.v \mid u \in L_1 \wedge v \in L_2\}$ ▶ podobně i další operace nad jazyky

Formální gramatika	Odvození z gramatiky
<ul style="list-style-type: none"> ▶ Čtverice (N, Σ, P, S) <ul style="list-style-type: none"> ▶ N – množina neterminálů ▶ Σ – množina terminálů (symbolů abecedy) ▶ $\rightarrow N \cap \Sigma = \emptyset$ ▶ $\rightarrow N \cup \Sigma$ označíme V (množina symbolů) ▶ $P \subseteq (V^*.N.V^*)^*$ – množina pravidel ▶ S – počáteční symbol gramatiky ▶ Pravidla gramatiky <ul style="list-style-type: none"> ▶ (α, β) zapisujeme jako $\alpha \rightarrow \beta$ ▶ α, β jsou slova nad V (řetězce terminálů a neterminálů) ▶ kde α obsahuje alespoň jeden neterminál 	<ul style="list-style-type: none"> ▶ Gramatika je model, který generuje jazyk <ul style="list-style-type: none"> ▶ začneme počátečním neterminálem ▶ používáme pravidla gramatiky jako přepisovací systém ▶ → tj. levou stranu pravidla nahradíme pravou ▶ přepisujeme tak dlouho, dokud nedostaneme řetězec terminálů ▶ Vztah jazyka a gramatiky <ul style="list-style-type: none"> ▶ 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

- ▶ $S \Rightarrow A \Rightarrow a$
- ▶ $S \Rightarrow A \Rightarrow AA \Rightarrow aA \Rightarrow aaA \Rightarrow aaa$
- ▶ 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 $A \rightarrow aB$ nebo $A \rightarrow a$ ($A, B \in N; a \in \Sigma$)
- ▶ též **regulární gramatika**

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

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 neveslo

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

Konečný automat

