

Automaty a gramatiky

Roman Barták, KTIML

bartak@ktiml.mff.cuni.cz
http://ktiml.mff.cuni.cz/~bartak

Co bylo minule

Automaty s výstupem

- Mooreovův stroj (značuje stavy)
- Mealyho stroj (vypisuje přechody)
- převody mezi stroji

Iterační (pumping) lemma

Úvod do formálních gramatik

- prepisovací systémy (abeceda + pravidla $u \rightarrow v$)
- gramatiky (neterminály (start) + terminály + pravidla)
- Chomského hierarchie (dle tvaru pravidel)
jazyky typu 0,1,2,3 - značíme L_0, L_1, L_2, L_3



Automaty a gramatiky, Roman Barták

Uspořádanost Chomského hierarchie

Chomského hierarchie definuje uspořádání tříd jazyků:

$$L_0 \supseteq L_1 \supseteq L_2 \supseteq L_3$$

Dokonce vlastní podmnožiny (později):

$$L_0 \supseteq L_1 \supseteq L_2 \supseteq L_3$$

$L_0 \supseteq L_1$ (rekurzivně spočetné jazyky zahrnují kontextové jazyky)

obecná pravidla \supseteq pravidla tvaru $\alpha X \beta \rightarrow \alpha \omega \beta$

$L_2 \supseteq L_3$ (bezkontextové jazyky zahrnují regulární jazyky)

„ $X \rightarrow w$, $w \in (V_N \cup V_T)^*$ “ \supseteq „ $X \rightarrow wY$, $X \rightarrow w$, $Y \in V_N$, $w \in V_T^*$ “

$L_1 \supseteq L_2$ (kontextové jazyky zahrnují bezkontextové jazyky)

$\alpha X \beta \rightarrow \alpha \omega \beta$, $|w| > 0$ vs. $X \rightarrow w$, $|w| \geq 0$

problém s pravidly tvaru $X \rightarrow \lambda$

Můžeme z bezkontextových gramatik vyřadit pravidla $X \rightarrow \lambda$?

Automaty a gramatiky, Roman Barták

Nevypouštějící bezkontextové gramatiky

Bezkontextová gramatika G je *nevypouštějící* právě tehdy, když nemá pravidla ve tvaru $X \rightarrow \lambda$.

Věta: Ke každé bezkontextové gramatice G existuje nevypouštějící bezkontextová gramatika G_1 taková, že $L(G_1) = L(G) - \{\lambda\}$ (jazyky se liší maximálně o prázdné slovo).

Je-li $\lambda \in L(G)$, potom existuje BKG G_2 tak, že $L(G_2) = L(G)$ a jediné pravidlo s λ na pravé straně je $S' \rightarrow \lambda$ a S' (počáteční neterminál) se nevyskytuje na pravé straně žádného pravidla G_2 (tedy $L_1 \supseteq L_2$).

Příklad:

$G: S \rightarrow 0S1 \mid \lambda$

$G_1: S \rightarrow 0S1 \mid 01$

$G_2: S' \rightarrow S \mid \lambda, S \rightarrow 0S1 \mid 01$



Automaty a gramatiky, Roman Barták

Převod na nevypouštějící BKG

... aneb, jak se zbavit pravidel ve tvaru $X \rightarrow \lambda$?

Základní myšlenka:

- pravidlo $X \rightarrow \lambda$ se používá pro vyhození X ze slova
- co když X do slova vůbec nezařadíme?
- ..., $Y \rightarrow uXv$, $X \rightarrow \lambda$, ... \Rightarrow ..., $Y \rightarrow uv$, ...

1) Nejprve zjistíme neterminály, které se prepisují na λ :

$$U = \{X \mid X \in V_N \text{ a } X \Rightarrow^* \lambda\}$$

Proč tak silně (nestačilo by $X \rightarrow \lambda$ místo $X \Rightarrow^* \lambda$)?

Řešení derivací $X \Rightarrow^{X \rightarrow Y} Y \Rightarrow^{Y \rightarrow Z} Z \Rightarrow^* \lambda$

Iterační algoritmus pro získání U :

- $U_1 = \{X \mid X \in V_N \text{ a } (X \rightarrow \lambda) \in P\}$ přímý prepis
- $U_{i+1} = \{X \mid X \in V_N \text{ a } (X \rightarrow w) \in P, w \in U_i^*\}$ prepis po $i+1$ krocích
- $U_1 \subseteq U_2 \subseteq \dots \subseteq V_N$ + stabilizace ($\exists k U_k = U_{k+1} = \dots$) + $U = U_k$

Automaty a gramatiky, Roman Barták

Převod na nevypouštějící BKG - pokračování

2) Úprava pravidel

do P_1 dáme pravidla tvaru $X \rightarrow u$ taková, že:

- $u \neq \lambda$
- v P je pravidlo $X \rightarrow v_1 Y_1 v_2 \dots v_m Y_m v_{m+1}$, $Y_i \in U$, $v \in ((V_N \cup U) \cup V_T)^*$ a u vzniká z $(v_1 Y_1 v_2 \dots v_m Y_m v_{m+1})$ vypuštěním některých (všech, žádného) symbolů Y_i .

3) Ještě $L(G_1) = L(G) - \{\lambda\}$

zřejmé: G_1 je nevypouštějící BKG, $L(G_1) \subseteq L(G)$, $\lambda \notin L(G_1)$

necht' $w \in L(G)$ a $w \neq \lambda$, tj. $S \Rightarrow^* w$,

pokud se použilo pravidlo z P_1 , pak má tvar $X \rightarrow u$

v derivaci před ním muselo být užito pravidlo $Y \rightarrow uXv$

uděláme novou derivaci s $Y \rightarrow uv$ a bez $X \rightarrow \lambda$

4) Zbývá situace $\lambda \in L(G)$

$$G_2 = (V_N \cup \{S'\}, V_T, S', P_1 \cup \{S' \rightarrow \lambda, S' \rightarrow S\})$$

Automaty a gramatiky, Roman Barták

Příklad - nevyužitelní BKG

$S \rightarrow aSc \mid A$
 $A \rightarrow bAc \mid \lambda$

1) Nejprve zjistíme neterminály, které se přepisují na λ :
 $U = \{A, S\}$

2) Upravíme pravidla:

$S \rightarrow aSc \mid A$
 $S \rightarrow ac$ (vzniklo z $S \rightarrow aSc$ vypuštěním S)
 $A \rightarrow bAc$ (pravidlo $A \rightarrow \lambda$ nepřevádíme)
 $A \rightarrow bc$ (vzniklo z $A \rightarrow bAc$ vypuštěním A)

Původní gramatika přijímá jazyk $\{a^i b^j c^k \mid i+j=k\}$.
 Převedená gramatika přijímá jazyk $\{a^i b^j c^k \mid i+j=k, k>0\}$.

Automaty a gramatiky, Roman Barišák

Gramatiky typu 3 a regulární jazyky

pouze pravidla ve tvaru $X \rightarrow wY, X \rightarrow w, X, Y \in V_N, w \in V_T^*$

Podívejme se na derivace generované gramatikami typu 3

$P: S \rightarrow 0S \mid 1A \mid \lambda, A \rightarrow 0A \mid 1B, B \rightarrow 0B \mid 1S$
 $S \Rightarrow 0S \Rightarrow 01A \Rightarrow 011B \Rightarrow 0110B \Rightarrow 01101S \Rightarrow 01101$

Pozorování:

- každé slovo derivace obsahuje právě jeden neterminál
- tento neterminál je vždy umístěn zcela vpravo
- aplikaci pravidla $X \rightarrow w$ se derivace uzavírá
- krok derivace = generuje symbol(y) + změni neterminál

Idea převodu gramatiky na automat:

neterminál = stav konečného automatu
 pravidla = přechodová funkce

Automaty a gramatiky, Roman Barišák

Převod konečného automatu na gramatiku

$L \in \mathcal{F} \Rightarrow L \in \mathcal{L}_3$

Důkaz:

$L = L(A)$ pro nějaký konečný automat $A = (Q, X, \delta, q_0, F)$
 definujeme gramatiku $G = (Q, X, q_0, P)$, kde pravidla mají tvar

$p \rightarrow aq$, když $\delta(p, a) = q$
 $p \rightarrow \lambda$, když $p \in F$

ještě $L(A) = L(G)$?

- $\lambda \in L(A) \Leftrightarrow q_0 \in F \Leftrightarrow (q_0 \rightarrow \lambda) \in P \Leftrightarrow \lambda \in L(G)$
- $a_1 \dots a_n \in L(A) \Leftrightarrow \exists q_0, \dots, q_n \in Q$ tž. $\delta(q_i, a_{i+1}) = q_{i+1}, q_n \in F$
 $\Leftrightarrow (q_0 \rightarrow a_1 q_1 \rightarrow \dots \rightarrow a_1 \dots a_n q_n \rightarrow \lambda)$ je derivace pro $a_1 \dots a_n$
 $\Leftrightarrow a_1 \dots a_n \in L(G)$

QED


A co naopak?

- pravidla $X \rightarrow aY$ kódujeme do přechodové funkce $X \rightarrow \lambda$ je konec
- ale co pravidla $X \rightarrow a_1 \dots a_n Y, X \rightarrow Y, X \rightarrow a_1 \dots a_n$?

Automaty a gramatiky, Roman Barišák

Příklad převodu KA na gramatiku

$A \rightarrow 1B \mid 0A \mid \lambda$
 $B \rightarrow 0C \mid 1D$
 $C \rightarrow 0E \mid 1A$
 $D \rightarrow 0B \mid 1C$
 $E \rightarrow 0D \mid 1E$



Příklady derivací:

$A \Rightarrow 0A \Rightarrow 0$ (0)
 $A \Rightarrow 1B \Rightarrow 10C \Rightarrow 101A$ (5)
 $A \Rightarrow 1B \Rightarrow 10C \Rightarrow 101A \Rightarrow 1010A \Rightarrow 1010$ (10)
 $A \Rightarrow 1B \Rightarrow 11D \Rightarrow 111C \Rightarrow 1111A \Rightarrow 1111$ (15)

$L = \{w \mid w \in \{0,1\}^* \text{ \& } w \text{ je binární zápis čísla dělitelného } 5\}$

Automaty a gramatiky, Roman Barišák

Standardizace pravidel regulární gramatiky

Ke každé gramatice $G = (V_N, V_T, S, P)$ typu 3 existuje ekvivalentní gramatika G' , které obsahuje pouze pravidla ve tvaru: $X \rightarrow aY$ a $X \rightarrow \lambda$.

Důkaz:

definujeme $G' = (V'_N, V_T, S, P')$, kde pravidla P' získáme takto

P	P'
$X \rightarrow aY$	$X \rightarrow aY$
$X \rightarrow \lambda$	$X \rightarrow \lambda$
$X \rightarrow a_1 \dots a_n Y$	$X \rightarrow a_1 Y_1, Y_1 \rightarrow a_2 Y_2, \dots, Y_n \rightarrow a_n Y$
$Z \rightarrow a_1 \dots a_n$	$Z \rightarrow a_1 Z_1, Z_1 \rightarrow a_2 Z_2, \dots, Z_n \rightarrow \lambda$

($Y_2, \dots, Y_n, Z_1, \dots, Z_n$ jsou nové neterminály - pro každé pravidlo jiná sada)

zbývá $X \rightarrow Y$


definujeme $U(X) = \{Y \mid Y \in V_N \text{ \& } X \Rightarrow^* Y\}$
 efektivní postup $U_i = \{Y \mid (X \rightarrow Y) \in P\}, U_{i+1} = U_i \cup \{Y \mid (Z \rightarrow Y) \in P, Z \in U_i\}$

$(X \rightarrow Y)$	$X \rightarrow w$ pro všechna $Y \rightarrow w$ z P' a $Y \in U(X)$
---------------------	---

Automaty a gramatiky, Roman Barišák

Příklad standardizace regulární gramatiky

Originální	Převedená
$S \rightarrow babaX$	$S \rightarrow bS_1$ $S_1 \rightarrow aS_2$ $S_2 \rightarrow bS_3$ $S_3 \rightarrow aX$
$S \rightarrow Y$	$S \rightarrow aY \mid bY \mid aY_1 \mid bZ_1$
$Y \rightarrow aY \mid bY$	$Y \rightarrow aY \mid bY$
$Y \rightarrow abbX$	$Y \rightarrow aY_1$ $Y_1 \rightarrow bY_2$ $Y_2 \rightarrow bX$
$Y \rightarrow baa$	$Y \rightarrow bZ_1$ $Z_1 \rightarrow aZ_2$ $Z_2 \rightarrow aZ_3$ $Z_3 \rightarrow \lambda$
$X \rightarrow aX \mid bX \mid \lambda$	$X \rightarrow aX \mid bX \mid \lambda$



$L = \{w \mid w = babau \vee w = uabbb \vee w = ubaa, u, v \in \{a, b\}^*\}$

Automaty a gramatiky, Roman Barišák

Převod gramatiky na konečný automat

$L \in \mathcal{L}_3 \Rightarrow L \in \mathcal{F}$

Důkaz:

$L=L(G)$ pro nějakou gramatiku $G=(V_N, V_T, S, P)$ typu 3 obsahující pouze pravidla ve tvaru: $X \rightarrow aY$ a $X \rightarrow \lambda$

definujeme nedeterministický konečný automat

$A=(V_N, V_T, \delta, \{S\}, F)$, kde:

$F=\{X \mid (X \rightarrow \lambda) \in P\}$

$\delta(X, a) = \{Y \mid (X \rightarrow aY) \in P\}$

ještě $L(G)=L(A)$?

1) $\lambda \in L(G) \Leftrightarrow (S \rightarrow \lambda) \in P \Leftrightarrow S \in F \Leftrightarrow \lambda \in L(A)$

2) $a_1 \dots a_n \in L(G)$

\Leftrightarrow existuje derivace $(S \Rightarrow a_1 X_1 \Rightarrow \dots \Rightarrow a_1 \dots a_n X_n \Rightarrow a_1 \dots a_n)$

$\Leftrightarrow \exists X_0, \dots, X_n \in V_N$ tž. $\delta(X_i, a_{i+1}) \ni X_{i+1}$, $X_0=S$, $X_n \in F \Leftrightarrow a_1 \dots a_n \in L(A)$

Automaty a gramatiky, Roman Barišák

Levé (a pravé) lineární gramatiky

Gramatiky typu 3 nazýváme také *pravé lineární* (neterminál je vždy vpravo).

Obdobně - gramatika G je *levá lineární*, jestliže má pouze pravidla tvaru $X \rightarrow Yw$, $X \rightarrow w$, $X, Y \in V_N$, $w \in V_T^*$ (neterminál je vždy vlevo).

Věta: Jazyky generované levou lineární gramatikou jsou právě regulární jazyky.

Důkaz:

- otočením pravidel dostaneme pravou lineární gramatiku

$X \rightarrow Yw, X \rightarrow w$ převedeme na $X \rightarrow w^R Y, X \rightarrow w^R$

- získaná gramatika generuje jazyk L^R

- víme, že regulární jazyky jsou uzavřené na reverzi

tu dříve protože L^R je regulární, je i $L=(L^R)^R$ regulární

- takto lze získat všechny regulární jazyky

Automaty a gramatiky, Roman Barišák

Lineární gramatiky (a jazyky)

Můžeme levě a pravě lineární pravidla používat najednou?

Další zobecnění - *gramatika je lineární*, jestliže má pouze pravidla tvaru $X \rightarrow uYv$, $X \rightarrow w$, $X, Y \in V_N$, $u, v, w \in V_T^*$ (na pravé straně vždy maximálně jeden neterminál).

Lineární jazyky jsou právě jazyky generované lineárními gramatikami.

Zřejmé: regulární jazyky \subseteq lineární jazyky

Platí také: regulární jazyky \supseteq lineární jazyky?

NE!

$\{0^n 1^n \mid n \geq 1\}$ není regulární jazyk, ale je lineární ($S \rightarrow 0S1 \mid 01$)

Pozorování:

lineární pravidla lze rozložit na levě a pravě lineární pravidla

$S \rightarrow 0A, A \rightarrow S1$

Automaty a gramatiky, Roman Barišák

Bezkontextové gramatiky

pouze pravidla ve tvaru $X \rightarrow w$, $X \in V_N$, $w \in (V_N \cup V_T)^*$ velký praktický význam

- definování syntaxe vyšších programovacích jazyků
- konstrukce kompilátorů

Příklad:

$\langle \text{Program} \rangle \rightarrow \langle \text{Příkaz} \rangle \mid \langle \text{Příkaz} \rangle \langle \text{Program} \rangle$
 $\langle \text{Příkaz} \rangle \rightarrow \langle \text{IF-příkaz} \rangle \mid \langle \text{WHILE-příkaz} \rangle \mid \langle \text{Přiřazení} \rangle$
 $\langle \text{IF-příkaz} \rangle \rightarrow \text{if } \langle \text{Test} \rangle \text{ then } \langle \text{Příkaz} \rangle \text{ else } \langle \text{Příkaz} \rangle$
 $\langle \text{WHILE-příkaz} \rangle \rightarrow \text{while } \langle \text{Test} \rangle \text{ do } \langle \text{Příkaz} \rangle$
 $\langle \text{Přiřazení} \rangle \rightarrow \langle \text{Proměnná} \rangle := \langle \text{Výraz} \rangle$

Bude nás zajímat:

- jednoznačnost gramatiky (kvůli překladu)
- analýza pomocí zásobníkových automatů
- vlastnosti BKG obecně

Automaty a gramatiky, Roman Barišák

Redukované bezkontextové gramatiky

Redukce (gramatiky) = vyřazení zbytečností

u konečných automatů:

- dosažitelné stavy, které nejsou ekvivalentní
- redukt určen jednoznačně

u bezkontextových gramatik:

- dosažitelné neterminály, které něco generují
- zde slabší význam (nemáme jednoznačnost)

Bezkontextová gramatika G (taková, že $L(G) \neq \emptyset$) se nazývá *redukovaná*, jestliže:

- 1) pro každý neterminál X existuje alespoň jedno terminální slovo w takové, že $X \Rightarrow^* w$
- 2) pro každý neterminál X různý od S existují slova u, v tak, že $S \Rightarrow^* uXv$ (dosažitelnost).

Automaty a gramatiky, Roman Barišák

Redukce bezkontextových gramatik

Příklad:

$S \rightarrow aA \mid ab$	Zjevně stačí pravidlo
$A \rightarrow BC$	$S \rightarrow ab$,
$B \rightarrow ba$	ostatní pravidla (neterminály) jsou
$D \rightarrow ab \mid \lambda$	zbytečná

Tvrzení: Ke každé bezkontextové gramatice G takové, že $L(G) \neq \emptyset$ lze sestavit ekvivalentní redukovanou gramatiku.

Důkaz (idea):

- 1) vyhod' neterminály, které negenerují terminální slovo
- 2) vyhod' nedosažitelné neterminály

Poznámka: pořadí akcí nelze prohodit!

$S \rightarrow ab \mid A$
 $A \rightarrow BC$
 $B \rightarrow b$

~~$S \rightarrow ab$~~
 ~~$B \rightarrow b$~~



Automaty a gramatiky, Roman Barišák

Algoritmus redukce - krok 1

hledáme $V = \{X \mid X \in V_N, \exists w \in V_T^* X \Rightarrow^* w\}$

obvyklý postup (iterace po krocích):

$$V_0 = V_T$$

$$V_{i+1} = V_i \cup \{X \mid X \in V_N, \exists w \in V_i^* (X \rightarrow w) \in P\}$$

$$V_0 \subseteq V_1 \subseteq \dots \subseteq V_T \cup V_N + \text{stabilizace } (\exists k V_k = V_{k+1} = \dots) + V = V_k \cap V_N$$

Zároveň víme, zda $L(G) \neq \emptyset$ ($L(G) \neq \emptyset \Leftrightarrow S \in V$)

Nyní z gramatiky odstraníme všechna pravidla obsahující na levé či pravé straně neterminál nepatřící do V .

a) máme splněn bod 1) definice redukované gramatiky

pro $X \in V$ víme: $\exists w \in V_T^* X \Rightarrow^* w$ + použitá pravidla nebyla odstraněna

b) získaná gramatika G' je ekvivalentní s původní gramatikou G
 $L(G') \subseteq L(G)$ zřejmé, $L(G) \subseteq L(G')$ lze ukázat sporem

Příklad:

$S \rightarrow aA \mid ab, A \rightarrow BC, B \rightarrow ba, D \rightarrow ab \mid \lambda$

$V = \{S, B, D\}$

redukována pravidla: $S \rightarrow ab, B \rightarrow ba, D \rightarrow ab \mid \lambda$



Automaty a gramatiky, Roman Bařák

Algoritmus redukce - krok 2 (dosazitelnost)

hledáme $U = \{X \mid X \in V_N, S \Rightarrow^* uXv\}$

obvyklý postup (iterace po krocích):

$$U_0 = \{S\}$$

$$U_{i+1} = U_i \cup \{X \mid X \in V_N, \exists Y \in U_i (Y \rightarrow uXv) \in P\}$$

$$U_0 \subseteq U_1 \subseteq \dots \subseteq V_N + \text{stabilizace } (\exists k U_k = U_{k+1} = \dots) + U = U_k$$

Podobně jako v kroku 1 odstraníme z gramatiky všechna pravidla obsahující na levé či pravé straně neterminál nepatřící do U .

a) máme splněn bod 2) definice redukované gramatiky

pro $X \in U$ víme: $S \Rightarrow^* uXv$ + použitá pravidla nebyla odstraněna

b) získaná gramatika G'' je ekvivalentní s gramatikou G'

$L(G'') \subseteq L(G')$ zřejmé, $L(G') \subseteq L(G'')$ lze ukázat sporem

c) platnost bodu 1) definice redukované gramatiky nebyla narušena spojením $X \Rightarrow^* w$ a $S \Rightarrow^* uXv$

Příklad:

$S \rightarrow ab, B \rightarrow ba, D \rightarrow ab \mid \lambda$

$U = \{S\}$

finální redukovaná pravidla: $S \rightarrow ab$



Automaty a gramatiky, Roman Bařák