

Automaty a gramatiky



Roman Barták, KTIML

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

Co bylo minule

Determinismus vs. nedeterminismus

- deterministický ZA - každý krok je jednoznačně určen
 - $\forall p \in Q, \forall a \in X \cup \{\lambda\}, \forall Z \in Y \quad |\delta(p, a, Z)| \leq 1$
 - $\forall p \in Q, \forall Z \in Y \quad (\delta(p, \lambda, Z) \neq \emptyset \Rightarrow \forall a \in X \delta(p, a, Z) = \emptyset)$
- determinismus oslabuje ZA (ww^R)
- determinismus rozlišuje přijímání z zásobníkem a stavem
 - deterministické BK jazyky (přijímání stavem)
 - bezprefixové BK jazyky (přijímání zásobníkem)

Zásobníkové automaty a bezkontextové gramatiky

- převod BKG na ZA
 - pravidla gramatiky \rightarrow pravidla automatu
 - + pravidla pro krácení terminálů
- převod ZA na BKG
 - pro jednostavové ZA jednoduché
 - pro vícestavové ZA - stavy simulovány v neterminálech

Jak na bezprefixové jazyky?

Jak se od deterministického jazyka dostaneme k bezprefixovému?
Co nám vadí?
po přečtení prefixu, který patří do jazyka, máme prázdný zásobník.

Řešení:
přidáme speciální znak na konec slova (až po přečtení tohoto znaku vyprázdníme zásobník)

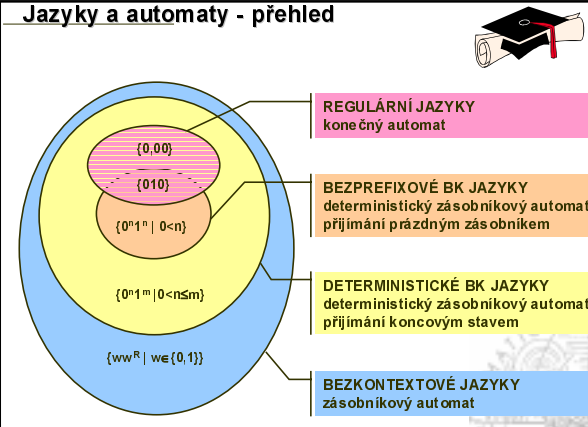
Necht' $L \subseteq X^*$ je deterministický jazyk a $\# \notin X$, potom $L\#$ je bezprefixový jazyk.

opraví nedeterministické λ -kroky při převodu automatů

Příklad: $\{0^n 1^m \# \mid 0 < n \leq m\}$

$\delta(p, 0, Z) = \{(p, AZ)\}$... čte první symbol 0
$\delta(p, 0, A) = \{(p, AA)\}$... čte další symboly 0
$\delta(p, 1, A) = \{(q, \lambda)\}$... čte první symbol 1
$\delta(q, 1, A) = \{(q, \lambda)\}$... čte další symboly 1
$\delta(q, \lambda, Z) = \{(q_0, \lambda, Z)\}$... nyní se počet 0 a 1 vyrovnal
$\delta(q_0, \lambda, Z) = \{(q_0, \lambda, Z)\}$... dále čteme jen 1
$\delta(q_0, \#, Z) = \{(q_0, \#, \lambda)\}$... na konci vyprázdníme zásobník

Jazyky a automaty - přehled



- REGULÁRNÍ JAZYKY**
konečný automat
- BEZPREFIXOVÉ BK JAZYKY**
deterministický zásobníkový automat přijímání prázdným zásobníkem
- DETERMINISTICKÉ BK JAZYKY**
deterministický zásobníkový automat přijímání koncovým stavem
- BEZKONTEXTOVÉ JAZYKY**
zásobníkový automat

Od gramatiky k automatu

$G = (V_N, V_T, S, P) \rightarrow M = (\{p\}, V_T, V_N \cup V_T, \delta, p, S, \{\})$

$\delta(p, \lambda, X) = \{(p, w) \mid (X \rightarrow w) \in P\} \quad \forall X \in V_N$... opracování zásobníku
 $\delta(p, a, a) = \{(p, \lambda)\} \quad \forall a \in V_T$... krácení terminálů

Příklad: $L = \{a^i b^j c^k \mid i+j=k\}$

Gramatika	Zásobníkový automat
$S \rightarrow aSc \mid A$	$\delta(p, \lambda, S) = \{(p, aSc), (p, A)\}$
$A \rightarrow bAc \mid \lambda$	$\delta(p, \lambda, A) = \{(p, bAc), (p, \lambda)\}$
	$\delta(p, x, x) = \{(p, \lambda)\} \quad \forall x \in \{a, b, c\}$

$S \Rightarrow aSc \Rightarrow aAc \Rightarrow abAcc \Rightarrow abbAcc \Rightarrow abbcc$

$(p, abbcc, S) \vdash (p, abbcc, aSc) \vdash (p, bbccc, S) \vdash (p, bbccc, Ac) \vdash (p, bbccc, bAc) \vdash (p, bccc, Acc) \vdash (p, bccc, bAcc) \vdash (p, ccc, Acc) \vdash (p, ccc, cc) \vdash (p, c, c) \vdash (p, \lambda, \lambda)$

Od automatu ke gramatice

Pro jednostavový ZA, stačí reverzní proces k BKG \rightarrow ZA.
Pro vícestavový ZA:

- převést na jednostavový ZA
- přímo na gramatiku

Převod vícestavového ZA na gramatiku:
pravidla gramatiky zachycují všechny možné výpočty neterminálními symboly: $[q, Z, p]$, kde $p, q \in Q, Z \in Y$
q je stav automatu těsně před tím, než se Z přepíše
p je stav automatu, když začínáme počítat pod Z

pravidla gramatiky:
 $S \rightarrow [q_0, Z_0, q]$ nastartování výpočtu (q - nevíme, kde skončí)
 $[q, A, p] \rightarrow a [q_1, B_1, q_2] [q_2, B_2, q_3] \dots [q_m, B_m, p]$
 $\delta(q, a, A) \ni (q_1, B_1, B_2 \dots B_m)$
 q_2, \dots, q_m, p libovolné stavy - nevíme, jak výpočet vypadá
 speciálně: $[q, A, p] \rightarrow a$, pro $\delta(q, a, A) \ni (p, \lambda)$

Výpočet automatu → derivace

$$(q, w, A) \vdash^* (p, \lambda, \lambda) \Rightarrow [q, A, p] \Rightarrow^* w$$

indukcí dle délky výpočtu

k=1

$w \in X \cup \{\lambda\}$, $\delta(q, w, A) \ni (p, \lambda)$, tj. máme pravidlo $[q, A, p] \rightarrow w$

k>1 (pro výpočty kratší než k platí)

$(q, au_1 \dots u_i, A) \vdash^* (q_1, u_1 \dots u_i, B_1 \dots B_i)$, $i \geq 1$ první krok výpočtu dle přechodu $\delta(q, a, A) \ni (q_1, B_1 B_2 \dots B_i)$

u_i jsou slova nutná ke zpracování zásobníkového symbolu B_i

tj. $(q_i, u_i, B_i) \vdash^* (q_{i+1}, \lambda, \lambda)$, pro vhodná q_i ($q_{i+1} = p$)

tyto výpočty jsou nutně kratší než k

tj. dle indukčního předpokladu $[q_i, B_i, q_{i+1}] \Rightarrow^* u_i$

dohromady:

$$[q, A, p] \rightarrow a [q_1, B_1, q_2] [q_2, B_2, q_3] \dots [q_i, B_i, p]$$

$$[q, A, p] \Rightarrow^* a u_1 u_2 \dots u_i$$



Automaty a gramatiky, Roman Barišák

Derivace → výpočet automatu

$$[q, A, p] \Rightarrow^* w \Rightarrow (q, w, A) \vdash^* (p, \lambda, \lambda)$$

indukcí dle délky (levé) derivace

k=1

jediné pravidlo $[q, A, p] \rightarrow w$ muselo vzniknout z $\delta(q, w, A) \ni (p, \lambda)$

k>1 (pro derivace kratší než k platí)

$[q, A, p] \rightarrow a [q_1, B_1, q_2] [q_2, B_2, q_3] \dots [q_i, B_i, p]$ první použité pravidlo vzniklo z přechodu $\delta(q, a, A) \ni (q_1, B_1 B_2 \dots B_i)$

potom $w = a u_1 \dots u_i$, kde $[q_i, B_i, q_{i+1}] \Rightarrow^* u_i$ ($q_{i+1} = p$)

tyto derivace jsou nutně kratší než k

tj. dle indukčního předpokladu $(q_i, u_i, B_i) \vdash^* (q_{i+1}, \lambda, \lambda)$

dohromady: „slepíme“ výpočty a dostaneme

$$(q, w, A) \vdash^* (q_1, u_1 \dots u_i, B_1 B_2 \dots B_i) \vdash^* (p, \lambda, \lambda)$$

Derivace vždy začíná nějakým pravidlem $S \rightarrow [q_0, Z_0, q]$, tj. $L(G) = N(M)$.

Automaty a gramatiky, Roman Barišák

Příklad převodu automatu na gramatiku

$$\delta(q, x, A) \ni ((q_1, B^1, B^m)) \dots q A_p \rightarrow x [q_1, B^1, q_2] \dots [q_m, B^m, p]$$

Příklad: $L = \{0^n 1^n \mid n \geq 0\}$

Automat	Gramatika
	$S \rightarrow p Z_p \mid p Z_q$
$\delta(p, \lambda, Z) = \{(p, \lambda)\}$	$p Z_p \rightarrow \lambda$
$\delta(p, 0, Z) = \{(p, A)\}$	$p Z_p \rightarrow 0 p A_p$ $p Z_q \rightarrow 0 p A_q$
$\delta(p, 0, A) = \{(p, AA)\}$	$p A_p \rightarrow 0 p A_p \mid 0 p A_q$ $p A_q \rightarrow 0 p A_p \mid 0 p A_q$
$\delta(p, 1, A) = \{(q, \lambda)\}$	$p A_q \rightarrow 1$
$\delta(q, 1, A) = \{(q, \lambda)\}$	$q A_q \rightarrow 1$

$$S \Rightarrow p Z_q \Rightarrow 0 p A_q \Rightarrow 00 p A_q q A_q \Rightarrow 001 q A_q \Rightarrow 0011$$

Automaty a gramatiky, Roman Barišák

Greibachové normální forma

Co nám vadí při analýze slova?

Nevíme, jaké pravidlo vybrat!

Speciálně vadí pravidla tvaru $A \rightarrow Au$ (levá rekurze).

Definice: Říkáme, že gramatika je v **Greibachově normální formě** (tvaru), jestliže všechna pravidla mají tvar:

$$A \rightarrow au, \text{ kde } a \in V_T, u \in V^*_{N_1}$$

K čemu je tento tvar dobrý?

Srovnáním terminálu na pravé straně pravidel a čteného symbolu můžeme zjistit, jaké pravidlo použít, pokud je ovšem takové pravidlo jediné.

Věta: Ke každému bezkontextovému jazyku L existuje bezkontextová gramatika G v Greibachově normální formě taková, že $L(G) = L - \{\lambda\}$.

Automaty a gramatiky, Roman Barišák

Spojení pravidel a odstranění levé rekurze

Lemma (spojení pravidel):

Nechť $A \rightarrow uBv$ je pravidlo gramatiky G a $B \rightarrow w_1, \dots, B \rightarrow w_k$ jsou všechna pravidla pro B . Potom nahrazením pravidla $A \rightarrow uBv$ pravidly $A \rightarrow uw_1v, \dots, A \rightarrow uw_kv$ dostaneme ekvivalentní gramatiku.

Důkaz: $A \rightarrow uBv \Rightarrow^* u'Bv \Rightarrow u'w_i v$ v původní gramatice
 $A \rightarrow uw_i v \Rightarrow^* u'w_i v$ v nové gramatice

Lemma (odstranění levé rekurze):

Nechť $A \rightarrow Au_1, \dots, A \rightarrow Au_k$ jsou všechna levě rekurzivní pravidla gramatiky G pro A a $A \rightarrow v_1, \dots, A \rightarrow v_m$ jsou všechna ostatní pravidla pro A . Potom nahrazením všech těchto pravidel pravidly:

$$1) A \rightarrow v_i, A \rightarrow v_i Z, Z \rightarrow u_j, Z \rightarrow u_j Z, \text{ nebo}$$

$$2) A \rightarrow v_i Z, Z \rightarrow u_j Z, Z \rightarrow \lambda$$

(Z je nový neterminál) dostaneme ekvivalentní gramatiku.

Důkaz: $A \Rightarrow Au_i \Rightarrow \dots \Rightarrow Au_i \dots u_n \Rightarrow v_i u_{i+1} \dots u_n$ (G)
 $A \Rightarrow v_i Z \Rightarrow v_i u_{i+1} Z \Rightarrow \dots \Rightarrow v_i u_{i+1} \dots u_{i+n-1} Z \Rightarrow v_i u_{i+1} \dots u_{i+n}$ (1)
 $A \Rightarrow v_i Z \Rightarrow v_i u_{i+1} Z \Rightarrow \dots \Rightarrow v_i u_{i+1} \dots u_{i+n} Z \Rightarrow v_i u_{i+1} \dots u_{i+n}$ (2)

Automaty a gramatiky, Roman Barišák

Převod na Greibachové NF

Věta: Libovolnou bezkontextovou gramatiku lze převést na gramatiku v Greibachově normální formě.

Důkaz:

spojování pravidel a odstraňování levé rekurze

1) neterminály očísujeme $\{A_1, \dots, A_n\}$

2) rekurzivní pravidla pouze tvaru $A_i \rightarrow A_j u$, kde $i < j$ postupnou iterací od 1 do n

$$A_i \rightarrow A_j u \text{ pro } i < j \text{ odstraníme spojováním pravidel pro } j=i \text{ odstraníme levou rekurzi}$$

získáme pravidla tvaru $A_i \rightarrow A_j u$ ($i < j$), $A_i \rightarrow au$ ($a \in V_T$), $Z_i \rightarrow u$

3) pravidla s A_i (původní neterminály) pouze tvaru $A_i \rightarrow au$ postupným spojováním pravidel od n do 1 (pro n již platí)

4) pravidla s Z_i (nové neterminály) pouze tvaru $Z_i \rightarrow au$

žádné pravidlo Z_i pro nezačíná vpravo Z_i

buď je v požadovaném tvaru nebo se spojí z pravidlem $A_j \rightarrow au$

5) odstranění terminálů uvnitř pravidel

Automaty a gramatiky, Roman Barišák

Příklad převodu na Greibachové NF

Původní gramatika

$E \rightarrow E+T \mid T$
 $T \rightarrow T^*F \mid F$
 $F \rightarrow (E) \mid a$

Odstranění levé rekurze

$E \rightarrow T \mid TE'$
 $E' \rightarrow +T \mid +TE'$
 $T \rightarrow F \mid FT'$
 $T' \rightarrow *F \mid *FT'$
 $F \rightarrow (E) \mid a$

(téměř) Greibachové normální forma

$E \rightarrow (E) \mid a \mid (E)T' \mid aT' \mid (E)E' \mid aE' \mid (E)T'E' \mid aT'E'$
 $E' \rightarrow +T \mid +TE'$
 $T \rightarrow (E) \mid a \mid (E)T' \mid aT'$
 $T' \rightarrow *F \mid *FT'$
 $F \rightarrow (E) \mid a$

Automaty a gramatiky, Roman Barták

Chomského normální forma

Podívejme se nyní na derivační stromy.

Jak odhadnout výšku stromu podle délky slova?

Definice: Říkáme, že gramatika je v **Chomského normální formě** (tvaru), jestliže všechna pravidla mají tvar:
 $X \rightarrow YZ$ nebo $X \rightarrow a$, kde $a \in V_T$, $X, Y, Z \in V_N$.

K čemu je tento tvar dobrý?

Derivační strom je (skoro) binární.

Je-li maximální cesta délky k , potom terminální slovo $\leq 2^{k-1}$.

Pumping lemma pro bezkontextové jazyky

Věta: Každému bezkontextovému jazyku L existuje bezkontextová gramatika G v Chomského normální formě taková, že $L(G) = L - \{\lambda\}$.

Automaty a gramatiky, Roman Barták

Odstranění pravidel $A \rightarrow B$

Lemma (odstranění $A \rightarrow B$):

Pro každou bezkontextovou gramatiku G lze sestavit ekvivalentní gramatiku G' takovou, že neobsahuje pravidla tvaru $A \rightarrow B$.

Důkaz:

hledáme $U(X) = \{Y \mid X \Rightarrow^* Y\}$

$U_1(X) = \{Y \mid X \rightarrow Y\}$

$U_{k+1}(X) = U_k(X) \cup \{Y \mid Z \rightarrow Y, Z \in U_k(X)\}$

stabilizace po maximálně $n=|V_N|$ krocích

pravidla $A \rightarrow B$ odstraníme z gramatiky

přidáme pravidla $A \rightarrow u$,

kde $B \rightarrow u$ je přípustné pravidlo gramatiky G a $B \in U(A)$

$L(G) \supseteq L(G')$

pokud derivace obsahuje nové pravidlo $A \rightarrow u$ nahradíme ho sekvencí

$A \Rightarrow^* B \Rightarrow u$

$L(G) \subseteq L(G')$

najdeme nejdelší posloupnosti $A \Rightarrow^* B \Rightarrow u$ složené z nepřipustných pravidel a nahradíme je $A \Rightarrow u$

Automaty a gramatiky, Roman Barták

Převod na Chomského NF

Povoleno pouze $X \rightarrow YZ$ nebo $X \rightarrow a$, kde $a \in V_T$, $X, Y, Z \in V_N$.

Víme:

pravidla $A \rightarrow B$ lze odstranit (ekvivalentní gramatiky)

pravidla $A \rightarrow \lambda$ lze odstranit (maximálně přijdeme o λ)

Dále:

pravidla tvaru $X \rightarrow a$, kde $a \in V_T$ jsou v pořádku

zbývají pravidla tvaru $X \rightarrow B_1 \dots B_k$, $k \geq 2$, $B_i \in V_N \cup V_T$

vytvoříme pravidlo $X \rightarrow C_1 \dots C_k$, kde:

$C_i = B_i$ je-li $B_i \in V_N$
 $C_i = B'_i$ je-li $B_i \in V_T$ (B'_i je nový neterminál)
 + přidáme pravidla $B'_i \rightarrow B_i$

pravidlo $X \rightarrow C_1 \dots C_k$, $k \geq 3$ nahradíme pravidly:

$X \rightarrow C_1 D_1$, $D_1 \rightarrow C_2 D_2$, ..., $D_{k-2} \rightarrow C_{k-1} C_k$
 D_i jsou nové neterminály

Automaty a gramatiky, Roman Barták

Příklad převodu na Chomského NF

Původní gramatika

$A \rightarrow B \mid C$
 $B \rightarrow 0B1 \mid 01$
 $C \rightarrow D \mid E$
 $D \rightarrow 1D0 \mid 1$
 $E \rightarrow 0E \mid 0$

Po odstranění $X \rightarrow Y$

$A \rightarrow 0B1 \mid 01 \mid 1D0 \mid 1 \mid 0E \mid 0$
 $B \rightarrow 0B1 \mid 01$
 ~~$C \rightarrow 1D0 \mid 1 \mid 0E \mid 0$~~
 $D \rightarrow 1D0 \mid 1$
 $E \rightarrow 0E \mid 0$

Po nahrazení terminálů

$A \rightarrow NBJ \mid NJ \mid JDN \mid 1 \mid NE \mid 0$
 $B \rightarrow NBJ \mid NJ$
 $D \rightarrow JDN \mid 1$
 $E \rightarrow NE \mid 0$
 $N \rightarrow 0$
 $J \rightarrow 1$

Chomského normální forma

$A \rightarrow NA_1 \mid NJ \mid JA_2 \mid 1 \mid NE \mid 0$
 $A_1 \rightarrow BJ$
 $A_2 \rightarrow DN$
 $B \rightarrow NB_1 \mid NJ$
 $B_1 \rightarrow BJ$
 $D \rightarrow JD_1 \mid 1$
 $D_1 \rightarrow DN$
 $E \rightarrow NE \mid 0$
 $N \rightarrow 0$
 $J \rightarrow 1$



Automaty a gramatiky, Roman Barták