

Automaty a gramatiky

4

Roman Barták, KTIML

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

Co bylo minule

Nedeterministické automaty

- nedeterministický výpočet
- ekvivalence s konečným automatem (algoritmus převodu)
- zobecněný nedeterministický automat

Množinové operace s jazyky

- sjednocení, průnik, rozdíl, doplněk
- uzavřenost operací (algoritmus převodu)

Řetězcové operace nad jazyky

- zřetěžení, mocniny, pozitivní/obecná iterace, zrcadlový obraz
- kvocienty a derivace (zleva, zprava)
- uzavřenost operací (algoritmus převodu)

Substituce a homomorfismus jazyků

Automaty a gramatiky, Roman Barták

Trochu motivace

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

$L = L_1 \cup L_2 \cup L_3$, kde

- $L_1 = \{ w \mid w = babau, u \in \{a, b\}^* \}$,
- $L_2 = \{ w \mid w = uabbb, u, v \in \{a, b\}^* \}$
- $L_3 = \{ w \mid w = ubaa, u \in \{a, b\}^* \}$


Můžeme jít ještě dál!

- $L_1 = \{baba\} \cdot \{a, b\}^*$
- $L_2 = \{a, b\}^* \cdot \{abb\} \cdot \{a, b\}^*$
- $L_3 = \{a, b\}^* \cdot \{baa\}$

Pojďme ještě dál

- $L_3 = (\{a\} \cup \{b\})^* \cdot \{b\} \cdot \{a\} \cdot \{a\}$

Nešlo by všechny regulární jazyky „poskládat“ z nějakých triviálních jazyků?



Automaty a gramatiky, Roman Barták

Regulární jazyky

Třída regulárních jazyků $RJ(X)$ nad konečnou neprázdnou abecedou X je nejmenší třída jazyků, která:

- obsahuje prázdný jazyk \emptyset
- pro každé písmeno $x \in X$ obsahuje jazyk $\{x\}$
- $A, B \in RJ(X) \Rightarrow A \cup B \in RJ(X)$ uzavřená na sjednocení
- $A, B \in RJ(X) \Rightarrow A \cdot B \in RJ(X)$ uzavřená na zřetěžení
- $A \in RJ(X) \Rightarrow A^* \in RJ(X)$ uzavřená na iteraci

Vlastně algebraický popis jazyků!

Speciálně:

- $\{\lambda\} \in RJ(X)$ protože $\{\lambda\} = \emptyset^*$
- $X \in RJ(X)$ protože $X = \bigcup_{x \in X} \{x\}$ (pozor! je to konečné sjednocení)
- $\{x_1, \dots, x_k\} \in RJ(X)$
- $X^* \in RJ(X)$

Automaty a gramatiky, Roman Barták

Kleeneova věta

Libovolný jazyk je regulární právě když je rozpoznatelný konečným automatem.

Konečnými automaty lze rozpoznávat jen triviální jazyky (prázdný a jednopísmenné) a jazyky, které z nich lze složit operacemi sjednocení, zřetěžení a iterace.

Důkaz $RJ \Rightarrow \mathcal{F}$

regulární jazyky jsou rozpoznatelné konečnými automaty

- triviální jazyky jsou rozpoznatelné konečným automatem
- operace sjednocení, zřetěžení a iterací dávají opět jazyk rozpoznatelný konečným automatem

Automaty a gramatiky, Roman Barták

Důkaz Kleeneovy věty

jazyky rozpoznatelné konečnými automaty jsou regulární

máme automat $A = (Q, X, \delta, q_1, F)$, který definuje jazyk $L(A)$

chceme ukázat, že $L(A)$ dostaneme z elementárních jazyků a operací

definujeme $R_{ij} = \{w \in X^* \mid \delta^*(q_i, w) = q_j\}$ slova převádějící stav q_i na q_j
potom $L(A) = \bigcup_{q_i \in F} R_{1i}$ slova převádějící počáteční stav q_1 na nějaký koncový stav q_i

jsou jazyky R_{ij} regulární?

pokud ano, potom $L(A)$ je také regulární, protože \cup zachovává regulárnost

definujeme $R_{ij}^k = \{ \text{slova převádějící stav } q_i \text{ na } q_j \text{ bez mezipřechodu stavů } q_m, m > k \}$
zřejmě $R_{ij} = R_{ij}^0 \cup R_{ij}^1 \cup \dots \cup R_{ij}^n$ (n je počet stavů automatu)

jsou jazyky R_{ij}^k regulární?

- R_{ij}^0 je regulární (žádné mezistavy, tj. jen jednopísmenná slova)
- $R_{ij}^{k+1} = R_{ij}^k \cup R_{i, k+1} \cdot (R_{k+1, k+1})^* \cdot R_{k+1, j}$ je regulární (sjednocení a iterace regulárních jazyků)



Automaty a gramatiky, Roman Barták

Regulární výrazy

Množina regulárních výrazů $RV(X)$ nad konečnou neprázdnou abecedou $X=\{x_1, \dots, x_n\}$ je nejmenší množina slov v abecedě $\{x_1, \dots, x_n, \emptyset, \lambda, +, *, \cdot, ()\}$, která:

- obsahuje výraz \emptyset a výraz λ $\emptyset \in RV(X), \lambda \in RV(X)$
- pro každé písmeno $x \in X$ obsahuje výraz x $x \in RV(X)$
- $\alpha, \beta \in RV(X) \Rightarrow (\alpha + \beta) \in RV(X)$
- $\alpha, \beta \in RV(X) \Rightarrow (\alpha \cdot \beta) \in RV(X)$
- $\alpha \in RV(X) \Rightarrow \alpha^* \in RV(X)$

Příklad: $((a+(b \cdot c+d)^*)+e)$

Konvence:

- vnější závorky lze vynechat $(a+(b \cdot c+d)^*)+e$
- závorky lze vynechat u \cdot a díky asociativitě $a+((b \cdot c)+d)^*+e$
- tečku lze vynechat $a+((bc)+d)^*+e$
- priorita operací (nejvyšší) * , \cdot , $+$ (nejnižší) $a+(bc+d)^*+e$

Automaty a gramatiky, Roman Bariák

Hodnota regulárního výrazu

Hodnotou regulárního výrazu $\alpha \in RV(X)$ je množina slov $[\alpha]$ (jazyk) definovaná následovně:

- $[\emptyset] = \emptyset, [\lambda] = \{\lambda\}, [x] = \{x\}$
- $[(\alpha + \beta)] = [\alpha] \cup [\beta]$
- $[(\alpha \cdot \beta)] = [\alpha] \cdot [\beta]$
- $[\alpha^*] = [\alpha]^*$

Regulární výrazy odpovídají regulárním jazykům

- hodnotou regulárního výrazu je regulární jazyk
- každý regulární jazyk lze reprezentovat pomocí regulárního výrazu (jazyk je hodnotou tohoto výrazu)

Příklady:

$$\begin{aligned} & [baba(a+b)^* + (a+b)^*abb(a+b)^* + (a+b)^*baa] = \\ & = \{ w \mid w = babau \vee w = uabbb \vee w = ubaa, u, v \in \{a, b\}^* \} \\ & [(0^*10^*10^*1)0^*] = \\ & = \{ w \mid w \in \{0, 1\}^*, |w|_1 = 3k \} \end{aligned}$$

Automaty a gramatiky, Roman Bariák

Použití regulárních výrazů

Praktický

přehledný zápis jazyka

Teoretický

zjednodušení některých důkazů

Věta: $L \in \mathcal{F}, \forall x \in X \sigma(x) \in \mathcal{F} \Rightarrow \sigma(L) \in \mathcal{F}$

L a $\sigma(x)$ jsou regulární jazyky, lze je tedy reprezentovat regulárními výrazy

každý výskyt x ve výrazu pro L stačí nahradit výrazem pro $\sigma(x)$

Rozšířené regulární výrazy

máme i další „regulární“ operace, např. průnik $(\alpha \& \beta)$

Ekvivalence regulárních výrazů

$\alpha \equiv \beta$ jestliže $[\alpha] = [\beta]$ (tj. výrazy reprezentují stejné jazyky)

Příklad: $(0^*1)^* \equiv \lambda + (0+1)^*1$

Jak to zjistíme?

Automaty a gramatiky, Roman Bariák

Převod regulárního výrazu na konečný automat


Metoda 1 (inkrementální):

- převed' elementární jazyky (prázdný, jednopísmenné)
- spoj použitím regulárních operací podle výrazu

Metoda 2 (přímá)

- očíslov symboly ve výrazu (zleva do doprava)
- zjistí všechny možné páry symbolů, které se mohou vyskytovat za sebou
- zjistí symboly, které mohou být první ve slově
- zjistí symboly, které mohou být poslední ve slově
- zjistí, zda jazyk obsahuje prázdné slovo
- vytvoř nedeterministický automat

stav: s + očíslované symboly
počátek = s
konec = poslední symbol (+ s pro λ)
přechody: $s \rightarrow$ první symbol
 $x_i \rightarrow x_j$, pokud je pár $x_i x_j$




Automaty a gramatiky, Roman Bariák

Můžeme konečné automaty ještě zobecnit?


Konečný automat provádí následující činnosti:

- přečte písmeno
- posune čtecí hlavu doprava
- změní stav vnitřní jednotky



Čtecí hlava se nesmí vracet!

Co když automatu povolíme ovládání hlavy?



Pozor! Automat na pásku nic nepíše!

Automaty a gramatiky, Roman Bariák

Dvousměrné (dvoucestné) konečné automaty

Dvousměrným (dvoucestným) konečným automatem nazýváme pětici $A = (Q, X, \delta, q_0, F)$, kde:

Q - konečná neprázdná množina stavů (stavový prostor)

X - konečná neprázdná množina symbolů (vstupní abeceda)

δ - zobrazení $Q \times X \rightarrow Q \times \{-1, 0, +1\}$ (přechodová funkce) přechodová funkce určuje i pohyb čtecí hlavy

$q_0 \in Q$ (počáteční stav)

$F \subseteq Q$ (množina koncových stavů)

Reprezentace:

stavový diagram, tabulka, stavový strom


Automaty a gramatiky, Roman Bariák

Počítání s dvousměrnými automaty

Kdy dvousměrný automat přijímá slovo?
Co se děje, je-li hlava mimo čtené slovo?

Slovo w je přijato dvousměrným konečným automatem, pokud:

- výpočet začal na prvním písmenu slova w vlevo v počátečním stavu
- čtecí hlava poprvé opustila slovo w vpravo v některém koncovém stavu
- mimo čtené slovo není výpočet definován (výpočet zde končí a slovo není přijato)



Automaty a gramatiky, Roman Barták

Příklad dvousměrného automatu


Nejprve poznámka:

ke slovům si můžeme přidat speciální koncové znaky $\# \notin X$
je-li $L(A) = \{w\# \mid w \in L \subseteq X^*\}$ regulární, potom i L je regulární
 $L = \partial_x \partial^R_x (L(A) \cap \#X^*\#)$

Příklad:

$L(B) = \{\#u\# \mid uu \in L(A)\}$ Pozor! Toto není levý ani pravý kvocient!
Nechť $A = (Q, X, \delta, q_0, F)$, definujme dvousměrný konečný automat
 $B = (Q \cup Q', \# \cup X, \delta', q_0, \{q_f, q'_f\})$, $X, \delta', q_0, \{q_f\}$ takto:

| δ' | X | $\#$ | poznámka |
|-----------|------------|-----------|--------------------------------|
| q_0 | $q_0, -1$ | $q_0, +1$ | |
| q | $p, +1$ | $q', -1$ | $p = \delta(q, x)$ |
| q' | $q', -1$ | $q', +1$ | |
| q'' | $p'', +1$ | $q_f, +1$ | $q \in F, p = \delta(q, x)$ |
| q''' | $p''', +1$ | $q_m, +1$ | $q \notin F, p = \delta(q, x)$ |
| q_n | $q_n, +1$ | $q_n, +1$ | |
| q_f | $q_n, +1$ | $q_n, +1$ | |



Automaty a gramatiky, Roman Barták

Věta o dvousměrných automatech

Jazyky přijímané dvousměrnými konečnými automaty jsou právě jazyky přijímané konečnými automaty.

Možnost pohybovat čtecí hlavou po pásce nezvětšila sílu konečného automatu!

Pozor, na pásku nic nepíšeme!

Pokud můžeme na pásku psát, dostaneme Turingův stroj.

Zřejmé: konečný automat \rightarrow dvousměrný konečný automat
dvousměrný automat vždy posouvá hlavu doprava

$$KA A = (Q, X, \delta, q_0, F) \rightarrow 2KA B = (Q, X, \delta', q_0, F), \delta'(q, x) = (\delta(q, x), +1)$$


Zbývá: dvousměrný konečný automat \rightarrow konečný automat

Automaty a gramatiky, Roman Barták


Důkaz věty o dvousměrných automatech (1)

1) Formální popis vlivu slova u na výpočet nad slovem v

- (i) kdy poprvé opustíme slovo u vpravo
(v jakém stavu poprvé vstoupíme nad v)
 $f(q_0) = q$ poprvé přejdeme na v ve stavu q
 $f(q'_0) = 0$ nikdy neopustíme u vpravo



- (ii) pokud opustíme slovo v vlevo, kdy se nad v opět vrátíme
 $f(p) = q$ vrátíme se nad v ve stavu q
 $f(p) = 0$ nikdy už se nevrátíme



2) Výpočet nad u máme popsány funkcí f_u

$$f_u: Q \cup \{q'_0\} \rightarrow Q \cup \{0\}$$

$f_u(q'_0)$ popisuje situaci (i), když začneme výpočet vlevo v počátečním stavu q_0 , v jakém stavu poprvé odejdeme vpravo
 $f_u(p)$ ($p \in Q$) popisuje situaci (ii), když začneme výpočet vpravo v p , v jakém stavu opět odejdeme vpravo
symbol 0 značí, že daná situace nenastane (odejdeme vlevo nebo cyklus)

Automaty a gramatiky, Roman Barták

Důkaz věty o dvousměrných automatech (2)

Pro každé slovo u máme funkci f_u popisující výpočet dvousměrného automatu A nad u

Definujme ekvivalenci slov takto: $u \sim w \Leftrightarrow_{\text{def}} f_u = f_w$
tj. slova jsou ekvivalentní, pokud mají stejné „výpočtové“ funkce

Vlastnosti \sim :

- je to ekvivalence (zřejmé, definováno pomocí $=$)
- má konečný index (maximální počet různých funkcí je $(n+1)^{n+1}$ pro n -stavový dvousměrný automat)
- je to pravá kongruence (zřejmé $u \sim w \Rightarrow uv \sim wv$, protože rozhraní $u|v$ a $w|v$ je stejné a nad v se automat chová stejně)
- $L(A)$ je sjednocením jistých tříd rozkladu X^+ / \sim
stačí si uvědomit, že $w \in L(A) \Leftrightarrow f_w(q'_0) \in F$
 $u \sim w \Rightarrow f_u(q'_0) = f_w(q'_0) \Rightarrow (u \in L(A) \Leftrightarrow w \in L(A))$

Podle Nerodovy věty je $L(A)$ regulární jazyk.


Automaty a gramatiky, Roman Barták

Převod 2KA na KA

Konstruktivní důkaz věty u dvousměrných automatech.

Jak výpočet s návraty převést na lineární výpočet?


- zajímají nás jen přijímací výpočty
- díváme se na přechody mezi symboly (v jakém stavu se přechází na další políčko)



Pozorování:

- stavy se v přechodu (řezu) střídají (doprava/doleva)
- první stav jde doprava, poslední také doprava
- v deterministických přijímacích výpočtech nejsou cykly
- první a poslední řez obsahují je diný stav

- Najdeme všechny možné řezy - posloupnosti stavů (je jich konečně mnoho).
- Mezi řezy definujeme (nedeterministické) přechody podle čteného symbolu.
- Rekonstruujeme výpočet skládáním řezů (jako puzzle).



Automaty a gramatiky, Roman Barták

Formální převod 2KA na KA

Nechť $A=(Q,X,\delta,q_0,F)$ je dvousměrný konečný automat.

Definujme ekvivalentní nedeterministický konečný automat $B=(Q',X,\delta',(q_0),F')$, kde:


Q' = všechny korektní přechodové posloupnosti

posloupnosti stavů (q^1, \dots, q^k) z Q takové, že

- délka posloupnosti je lichá ($k=2m+1$)
- žádný stav se neopakuje na liché ani na sudé pozici ($\forall i \neq j \ q^{2i} \neq q^{2j}$) & ($\forall i \neq j \ q^{2i+1} \neq q^{2j+1}$)

$F' = \{(q) \mid q \in F\}$ přechodové posloupnosti délky 1 obsahující koncový stav

$\delta'(c,x) = \{ d \mid d \in Q' \ \& \ c \rightarrow d \text{ je lokálně konzistentní přechod pro } x \}$



$L(A)=L(B)?$

„trajektorie 2KA A odpovídá řezům KA B“


Automaty a gramatiky, Roman Bařák

Příklad převodu 2KA na KA

Mějme následující dvousměrný konečný automat:

| | a | b |
|-----------------|---------------|---|
| $\rightarrow p$ | $p,+1 \ q,+1$ | |
| $\leftarrow q$ | $q,+1 \ r,-1$ | |
| r | $p,+1 \ r,-1$ | |


Možné řezy a jejich konzistentní přechody:



Ukázka výpočtu:

aabaabaabb
ppppqqq
r
pqqp
r
pq
rr
rpq
rr
..

Výsledný nedeterministický KA:



Automaty a gramatiky, Roman Bařák