

Automaty a gramatiky


Roman Barták, KTIML

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

Co bylo minule

Regulární jazyk jako sloučenina

- elementární jazyky (prázdný, jednopísmenný) + operace sjednocení, zřetězení, iterace
- Kleeneova věta
- popis jazyků pomocí regulárních výrazů
- převod regulárního výrazu na automat



Dvousměrné (dvoucestné) automaty

- automatem řízený pohyb hlavy
- na pásku nic nepíšeme!
- dva způsoby převodu na konečný automat



Automaty a gramatiky, Roman Barták

Automaty s výstupem (motivace)

... aneb jak zaznamenat výpočet automatu?

Dosud jediná zpráva z automatu - jsme v přijímajícím stavu.

Můžeme z konečného automatu získat více informací?

Můžeme zaznamenat trasu výpočtu?

1) indikace stavů (všech, nejen koncových)
v každé chvíli víme, kde se automat nachází
Příklad: různé (regulární) čítače

2) indikace přechodů
po přečtení každého symbolu víme, co automat udělal
Příklad: (regulární) překlad slov

Automat až není tak docela černá skříňka.

Automaty a gramatiky, Roman Barták

Mooreův stroj

Mooreovým (sekvenčním) strojem nazýváme šestici

$A = (Q, X, Y, \delta, \mu, q_0)$ resp. pěticí $A = (Q, X, Y, \delta, \mu)$, kde:

- Q - konečná neprázdná množina stavů (stavový prostor)
- X - konečná neprázdná množina symbolů (vstupní abeceda)
- Y - konečná neprázdná množina symbolů (výstupní abeceda)
- δ - zobrazení $Q \times X \rightarrow Q$ (přechodová funkce)
- μ - zobrazení $Q \rightarrow Y$ (značkovací funkce)
- $q_0 \in Q$ (počáteční stav)

Poznámky:

- někdy nás nezajímá počáteční stav, ale jen práce automatu
 - značkovací funkce umožňuje suplovat roli koncových stavů
- $F \subseteq Q$ nahradíme značkovací funkci $\mu: Q \rightarrow \{0,1\}$ takto:
- $\mu(q) = 0$, pokud $q \notin F$
 $= 1$, pokud $q \in F$

Automaty a gramatiky, Roman Barták

Příklad Mooreova stroje

Navrhněte automat počítající tenisové skóre.


Vstupní abeceda: ID hráče, který uhrál bod

Výstupní abeceda/stavy: skóre (tj. $Q=Y$ a $\mu(q)=q$)



Stav/výstup	A	B
00:00	15:00	00:15
15:00	30:00	15:15
15:15	30:15	15:30
00:15	15:15	00:30
30:00	40:00	30:15
30:15	40:15	30:30
30:30	40:30	30:40
15:30	30:30	15:40
00:30	15:30	00:40
40:00	A	40:15
40:15	A	40:30
40:30	A	shoda
30:40	shoda	B
15:40	30:40	B
00:40	15:30	B

Stav/výstup	A	B
shoda	A:40	40:A
A:40	A	shoda
40:A	shoda	B
A	15:00	00:15
B	15:00	00:15



Automaty a gramatiky, Roman Barták

Mealyho stroj

Mealyho (sekvenčním) strojem nazýváme šestici

$A = (Q, X, Y, \delta, \lambda, q_0)$ resp. pěticí $A = (Q, X, Y, \delta, \lambda)$, kde:

- Q - konečná neprázdná množina stavů (stavový prostor)
- X - konečná neprázdná množina symbolů (vstupní abeceda)
- Y - konečná neprázdná množina symbolů (výstupní abeceda)
- δ - zobrazení $Q \times X \rightarrow Q$ (přechodová funkce)
- λ - zobrazení $Q \times X \rightarrow Y$ (výstupní funkce)
- $q_0 \in Q$ (počáteční stav)

Poznámka:

výstup je určen stavem a vstupním symbolem

tj. Mealyho stroj je obecnějším prostředkem než stroj Mooreův

značkovací funkci $\mu: Q \rightarrow Y$ lze nahradit výstupní funkcí $\lambda: Q \times X \rightarrow Y$

například takto:

$$\forall x \in X \quad \lambda(q, x) = \mu(q)$$

Automaty a gramatiky, Roman Barták

Příklad Mealyho stroje

Navrhněte automat, který dělí vstupní slovo v binárním tvaru číslem 8 (celočíslně).

Realizace:

- posun o tři bity doprava (1101010 → 0001101)
- potřebujeme si pamatovat poslední trojici bitů (vlastně dynamická tříbitová paměť-buffer)

Stavsymbol	0	1
000	000/0	001/0
001	010/0	011/0
010	100/0	101/0
011	110/0	111/0
100	000/1	001/1
101	010/1	011/1
110	100/1	101/1
111	110/1	111/1

Vadí nám, když nevíme, kde automat startuje?
NE - po třech symbolech začne počítat správně

Automaty a gramatiky, Roman Barták

Výstup sekvenčních strojů

slovo ve vstupní abecedě → slovo ve výstupní abecedě

Mooreův stroj

značkovací funkce $\mu: Q \rightarrow Y$
 $\mu^*: Q \times X^* \rightarrow Y^*$
 $\mu^*(q, \lambda) = \lambda$ (někdy $\mu^*(q, \lambda) = \mu(q)$)
 $\mu^*(q, wx) = \mu^*(q, w) \cdot \mu(\delta^*(q, wx))$
 Příklad: $\mu^*(00:00, AABA) = (00:00 \cdot) 15:00 \cdot 30:00 \cdot 30:15 \cdot 40:15$

Mealyho stroj

výstupní funkce $\lambda: Q \times X \rightarrow Y$
 $\lambda^*: Q \times X^* \rightarrow Y^*$
 $\lambda^*(q, \lambda) = \lambda$
 $\lambda^*(q, wx) = \lambda^*(q, w) \cdot \lambda(\delta^*(q, w), x)$
 Příklad: $\mu^*(, 000^0, 1101010) = 0001101$

Automaty a gramatiky, Roman Barták

Převod Mooreova stroje na Mealyho

Nechť $A = (Q, X, Y, \delta, \mu, q_0)$ je Mooreův stroj.
Umíme najít Mealyho stroj B tak, že $\forall q, w \mu^*(q, w) = \lambda^*(q, w)$?

ANO!
 položíme $B = (Q, X, Y, \delta, \lambda, q_0)$, kde $\lambda(q, x) = \mu(\delta(q, x))$
 tj. λ vrací značku stavu, do kterého přejdeme

Příklad:

stav	0	1	výstup
a	a	b	0
b	b	c	1
c	c	a	2

stav	0	1
a	a/0	b/1
b	b/1	c/2
c	c/2	a/0

Automaty a gramatiky, Roman Barták

Převod Mealyho stroje na Mooreův

Nechť $A = (Q, X, Y, \delta, \lambda, q_0)$ je Mealyho stroj.
Sestrojíme Mooreův stroj B tak, že $\forall q, w \lambda^*(q, w) = \mu^*(q, w)$.

Problém: do jednoho stavu mohou vést přechody s různými výstupy!
Řešení: stav rozdělíme na více stavů (podle počtu výstupních symbolů).

Teď už je to jednoduché! $B = (Q \times Y, X, Y, \delta', \mu, (q_0, _))$, kde
 $\delta'((q, y), x) = (\delta(q, x), \lambda(q, x))$ a $\mu((q, y)) = y$

Příklad:

stav	0	1	výstup
(a,0)	(a,0)	(b,0)	0
(a,1)	(a,0)	(b,0)	1
(b,0)	(a,1)	(b,1)	0
(b,1)	(a,1)	(b,1)	1

Automaty a gramatiky, Roman Barták

„Pravidelnost“ regulárních jazyků

Konečný automat kóduje pouze konečnou informaci.
Přesto můžeme rozpoznávat nekonečné jazyky!
Můžeme přijímat libovolně (ale konečně) dlouhá slova!

Pozorování:
 $L = \{w \mid w \in \{0,1\}^* \ \& \ |w|_1 = 3k+1\}$
 $010011010 \in L$ potom také:
 $01001101011010 \in L$ řetězec 01101 jsme zdvojnili
 $0100110101101011010 \in L$ řetězec 01101 jsme ztrojnili
 $0100 \in L$ řetězec 01101 jsme vypustili

Lze takovou operaci provést s každým slovem libovolného regulárního jazyka?
ANO (pokud je slovo dostatečně dlouhé)

Automaty a gramatiky, Roman Barták

Iterační (pumping) lemma

Nechť L je regulární jazyk. Potom existuje přirozené číslo n takové, že libovolné slovo $z \in L$, $|z| \geq n$ lze psát ve tvaru uvw , kde:
 $|uv| \leq n$, $1 \leq |v|$ a pro všechna $i \geq 0$ $uv^i w \in L$.

Důkaz:
 za n vezmeme počet stavů příslušného automatu
 při zpracování slova délky $\geq n$ se automat nutně musí dostat do jednoho stavu dvakrát (krabičkový princip)
 vezmeme takový stav p , který se opakuje jako první
 potom $\delta(q_0, u) = p$ poprvé jsme se dostali do p
 $\delta(q_0, uv) = p$ podruhé jsme se dostali do p
 zřejmě $|uv| \leq n$ (pouze p se opakuje tj. maximálně $n+1$ stavů)
 $|v| \geq 1$ (smýčka obsahuje alespoň jedno písmeno)
 smýčku mezi prvním a druhým průchodem p (odpovídá jí slovo v) nyní můžeme vypustit nebo projít vícekrát
 tj. $\forall i \geq 0 \ uv^i w \in L$

Automaty a gramatiky, Roman Barták

Iterační lemma a nekonečnost jazyků

Umíme algoritmicky rozhodnout, zda je regulární jazyk L nekonečný?

ANO!

jazyk L je nekonečný $\Leftrightarrow \exists u \in L$ tž. $n \leq |u| < 2n$
 n je číslo z iteračního lemmatu

stačí prozkoumat všechna slova u taková, že
 $n \leq |u| < 2n$ (to je konečně mnoho slov)

PROČ?

- Pokud $\exists u \in L$ tž. $n \leq |u| < 2n$, potom lze slovo u pumpovat, čímž dostaneme nekonečně mnoho slov z jazyka L .
 - Je-li jazyk L nekonečný, obsahuje slovo z takové, že $n \leq |z|$.
 - Pokud $|z| < 2n$ máme hledané slovo.
 - Jinak, podle iteračního lemmatu $z = uvw$ a $uw \in L$, tj. zkrácení
 - Platí-li stále $2n \leq |uw|$, opakuj zkracování se slovem uw .
- Poznámka: zkracujeme maximálně o n písmen, tedy interval $[n, 2n)$ nelze přeskočit!

Automaty a gramatiky, Roman Barták

Použití iteračního lemmatu

1) Důkaz neregulárnosti jazyka

$L = \{0^i 1^i \mid i \geq 0\}$ není regulární jazyk

sporem:

nechť L je regulární, potom lze pumpovat ($\exists n$ tž. ...)

vezmeme slovo $0^n 1^n$ (to je určitě delší než n)

pumpovat můžeme pouze v části 0^n

potom, ale $0^{n+1} 1^n \notin L$ ($i > 0$ je délka pumpované části), což je spor

2) POZOR! Iterační lemma představuje nutnou podmínku regulárnosti jazyka, nedává podmínku postačující.

Existuje jazyk, který není regulární a lze pumpovat.

$L = \{u \mid u = a^i b^i c^i \vee u = b^i c^i\}$

L není regulární (Nerodova věta)

vždy lze pumpovat první písmeno

Automaty a gramatiky, Roman Barták

Konečné automaty - shrnutí

Konečný automat

- jednoznačný redukovaný automat
- nedeterminismus (2^n), dvousměrný KA (n^n)
- Mealyho a Mooreův stroj

Automaty a jazyky

- regulární jazyky
- uzavřenost na množinové operace
- uzavřenost na řetězcové operace
- uzavřenost substituce

Charakteristika regulárních jazyků

- Nerodova věta (kongruence)
- Kleeneova věta (elementární jazyky a operace)
- Iterační lemma (iterace podslov, jen nutná podmínka)

Automaty a gramatiky, Roman Barták



Uvod do formálních gramatik

Gramatiky, všichni je známe, ale co to je?

Popis jazyka pomocí pravidel, podle kterých se vytvářejí všechny řetězce daného jazyka.

Původně pro popis přirozených jazyků

<věta> → <podmětná část> <přísudková část>

Zadání syntaxe vyšších programovacích jazyků od dob Algolu 60

Backus-Naurova normální forma (BNF)

<číslo> ::= <číslo bez zn.> | +<číslo bez zn.> | -<číslo bez zn.>

<číslo bez zn.> ::= <číslice> | <číslice><číslo bez zn.>

<číslice> ::= 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9

Automaty a gramatiky, Roman Barták

Příklady gramatik

1) Gramatika s právných uzávorkování

$V \rightarrow VV \mid (V) \mid ()$

Výraz $((()))()$ je generován posloupností přepisů:

$V \rightarrow VV \rightarrow (V)V \rightarrow ((V)V \rightarrow ((())V \rightarrow ((())()V \rightarrow ((())()())$

2) Gramatika generující všechny výrazy s operacemi $+$ a $*$, závorkami a jedinou konstantou c .

$V \rightarrow T+V \mid T$

$T \rightarrow F*T \mid F$

$F \rightarrow (V) \mid c$

Výraz $c+c*c+c$ je generován posloupností přepisů:

$V \rightarrow T+V \rightarrow F+V \rightarrow c+V \rightarrow c+T+V \rightarrow c+F*T+V \rightarrow c+c*T+V \rightarrow c+c*F+V \rightarrow c+c*c+V \rightarrow c+c*c+T \rightarrow c+c*c+F \rightarrow c+c*c+c$

Automaty a gramatiky, Roman Barták

Přepisovací systémy - základní pojmy

Přepisovacím (produkčním) systémem nazýváme dvojici $R=(V,P)$,

kde

V - konečná abeceda

P - konečná množina přepisovacích pravidel

přepisovací pravidlo (produkce) je uspořádaná dvojice (u,v) , kde $u,v \in V^*$ (z pravidla píšeme $u \rightarrow v$)

Říkáme, že w se přímo přepíše na z (píšeme $w \Rightarrow z$), jestliže:

$\exists u,v,x,y \in V^*$ tž. $w = xuy, z = xvy$ a $(u \rightarrow v) \in P$.

Říkáme, že w se přepíše na z (píšeme $w \Rightarrow^* z$), jestliže:

$\exists u_1, \dots, u_n \in V^*$ $w = u_1 \Rightarrow u_2 \Rightarrow \dots \Rightarrow u_n = z$.

Posloupnost u_1, \dots, u_n nazýváme odvozením (derivací).

Pokud $\forall i \neq j, u_i \neq u_j$, potom hovoříme o minimálním odvození.

Automaty a gramatiky, Roman Barták

Přepisovací systémy

Příklad:

$$V = \{0,1\}$$

$$P = \{01 \rightarrow 10, 10 \rightarrow 01\}$$

$$00110 \Rightarrow^* 00011 \text{ dostaneme z } 001\mathbf{1}0 \Rightarrow 00\mathbf{1}01 \Rightarrow 00011$$

$$00110 \Rightarrow^* 01100 \text{ dostaneme z } 00\mathbf{1}10 \Rightarrow 01\mathbf{0}10 \Rightarrow 01100$$

libovolné slovo přepíše na libovolné jiné slovo
(se stejným počtem výskytů 0 a 1)

Produkční systémy slouží jako programovací nástroj v UI
program = systém produkcí

data = slova v abecedě

- OPS5, TOPS
- Constraint Handling Rules (CHR)
- Definite Clause Grammars (DCG)



Automaty a gramatiky, Roman Barták

Formální (generativní) gramatiky

Generativní gramatikou nazýváme čtveřici $G=(V_N, V_T, S, P)$:

V_N - konečná množina neterminálních symbolů

V_T - konečná množina terminálních symbolů

obě abecedy jsou neprázdné a disjunktní!

$S \in V_N$ - počáteční neterminální symbol

P - systém produkcí $u \rightarrow v$, kde $u, v \in (V_N \cup V_T)^*$

a u obsahuje alespoň jeden neterminální symbol.

Jazyk $L(G)$ generovaný gramatikou G definujeme takto:

$$L(G) = \{w \mid w \in V_T^* \text{ \& } S \Rightarrow^* w\}.$$

Gramatiky G_1 a G_2 jsou ekvivalentní, jestliže $L(G_1) = L(G_2)$.

Příklad:

$$G = (\{S\}, \{0,1\}, S, \{S \rightarrow 0S1, S \rightarrow 01\}), \quad L(G) = \{0^i 1^i \mid i \geq 1\}$$

Automaty a gramatiky, Roman Barták

Chomského hierarchie

Klasifikace gramatik podle tvaru přepisovacích pravidel.

gramatiky typu 0 (rekurzivně spočetné jazyky)

gramatiky v obecné formě (žádná omezení pravidel)

gramatiky typu 1 (kontextové jazyky)

pouze pravidla ve tvaru $\alpha X \beta \rightarrow \alpha \gamma \beta$,

$$X \in V_N, \alpha, \beta \in (V_N \cup V_T)^*, \gamma \in (V_N \cup V_T)^+$$

jedinou výjimkou je pravidlo $S \rightarrow \lambda$, potom se ale S
nevyskytuje na pravé straně žádného pravidla

gramatiky typu 2 (bezkontextové jazyky)

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

gramatiky typu 3 (regulární/pravé lineární jazyky)

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

Automaty a gramatiky, Roman Barták