


Věta 2.60



Kleeneho věta 2.63. Libovolný jazyk je popsatelný regulárním výrazem právě když je rozpoznatelný konečným automatem.

Převod DFA na regulární přechodový graf

Motivace


Věta 2.66. Pro každý regulární přechodový graf $\mathcal{M} = (Q, \Sigma, \delta, I, F)$ existuje ekvivalentní regulární přechodový graf $\mathcal{M}' = (\{x, y\}, \Sigma, \delta', \{x\}, \{y\})$, kde δ' může být definováno pouze pro dvojici (x, y) .


Důkaz. Algoritmus transformace

Krok 1 Ke grafu \mathcal{M} přidáme nový počáteční stav x a nový koncový stav y . Přidáme také hrany $x \xrightarrow{\varepsilon} q$ pro každé $q \in I$ a $r \xrightarrow{\varepsilon} y$ pro každé $r \in F$.

Krok 2 Každý stav p různý od x, y nyní odstraníme spolu s hranami, které do p vcházejí nebo z p vycházejí. Pokud do p nevede hrana z jiného uzlu, je nedosažitelný z počátečního stavu. Pokud z p nevede hrana do jiného uzlu, nelze z p dosáhnout koncový stav. V obou případech p odstraníme bez náhrady.

Pro každou dvojici vstupní hrany vedoucí do p z jiného uzlu a výstupní hrany vedoucí z p do jiného uzlu přidáme přímý přechod. Pak p odstraníme.





Po odstranění všech stavů různých od x a y zůstanou tyto dva stavы spolu s (žádnou nebo jednou) hranou z x do y .

Konečnost algoritmu Každým krokem 2 snížíme počet stavů.

Korektnost algoritmu Z definice regulárního přechodového grafu přímo ověříme, že kroky 1 i 2 zachovávají ekvivalenci. \square

Ekvivalence konečných automatů a regulárních gramatik

Pojem regulárního jazyka byl definován dvakrát – nejprve pomocí regulární gramatiky a pak ještě jednou pomocí konečného automatu.

Převod regulární gramatiky na konečný automat

Lemma 2.69. Ke každé regulární gramatice $\mathcal{G} = (N, \Sigma, P, S)$ existuje nedeterministický konečný automat $\mathcal{M} = (Q, \Sigma, \delta, q_0, F)$ takový, že $L(\mathcal{G}) = L(\mathcal{M})$.

Důkaz.

Konstrukce konečného automatu

- $Q = \{\overline{A} \mid A \in N\} \cup \{q_f\}$, kde $q_f \notin N$.
- $q_0 = \overline{S}$.
- δ je nejmenší funkce $Q \times \Sigma \rightarrow 2^Q$ splňující:
 - Pokud $A \rightarrow aB$ je pravidlo v P , pak $\overline{B} \in \delta(\overline{A}, a)$.
 - Pokud $A \rightarrow a$ je pravidlo v P , kde $a \neq \varepsilon$, pak $q_f \in \delta(\overline{A}, a)$
- $F = \begin{cases} \{\overline{S}, q_f\} & \text{pokud } S \rightarrow \varepsilon \text{ je pravidlo v } P, \\ \{q_f\} & \text{jinak.} \end{cases}$

Korektnost Nejprve indukcí vzhledem ke k dokážeme, že pro každé $a_1, \dots, a_k \in \Sigma$ a $B \in N$ platí

$$S \Rightarrow^* a_1 \dots a_k B \iff \overline{B} \in \hat{\delta}(\overline{S}, a_1 \dots a_k).$$

- **Základní krok** $k = 0$: Z definice $\hat{\delta}$ plyne $\hat{\delta}(\overline{S}, \varepsilon) = \{\overline{S}\}$. Proto

$$S \Rightarrow^* B \iff B = S \iff \overline{B} = \overline{S} \iff \overline{B} \in \hat{\delta}(\overline{S}, \varepsilon)$$

- **Indukční krok:**

$$\begin{aligned} S \Rightarrow^* a_1 \dots a_{k+1} B \\ \iff \exists C \in N \text{ takové, že } S \Rightarrow^* a_1 \dots a_k C \Rightarrow a_1 \dots a_{k+1} B \\ \iff \exists C \in N \text{ takové, že } \overline{C} \in \hat{\delta}(\overline{S}, a_1 \dots a_k) \wedge C \rightarrow a_{k+1} B \\ \iff \exists C \in N \text{ takové, že } \overline{C} \in \hat{\delta}(\overline{S}, a_1 \dots a_k) \wedge \overline{B} \in \delta(\overline{C}, a_{k+1}) \\ \iff \overline{B} \in \hat{\delta}(\overline{S}, a_1 \dots a_{k+1}). \end{aligned}$$

Dokázali jsme: $S \Rightarrow^* a_1 \dots a_k B \iff \overline{B} \in \hat{\delta}(\overline{S}, a_1 \dots a_k)$

Ukážeme, že $w \in L(\mathcal{G}) \iff w \in L(\mathcal{M})$:

- $w = \varepsilon$:

$$\varepsilon \in L(\mathcal{G}) \iff S \rightarrow \varepsilon \in P \iff \overline{S} \in F \iff \varepsilon \in L(\mathcal{M})$$

- $w = va$, kde $v \in \Sigma^*$, $a \in \Sigma$:

$$\begin{aligned} va \in L(\mathcal{G}) &\iff S \Rightarrow^* vB \Rightarrow va \\ &\iff S \Rightarrow^* vB \wedge B \rightarrow a \in P \\ &\iff \overline{B} \in \hat{\delta}(\overline{S}, v) \wedge q_f \in \delta(\overline{B}, a) \\ &\iff q_f \in \hat{\delta}(\overline{S}, va) \iff va \in L(\mathcal{M}) \end{aligned}$$

□

Převod konečného automatu na regulární gramatiku

Lemma 2.71 Pro každý konečný automat $\mathcal{M} = (Q, \Sigma, \delta, q_0, F)$ existuje regulární gramatika $\mathcal{G} = (N, \Sigma, P, S)$ taková, že $L(\mathcal{M}) = L(\mathcal{G})$.

Důkaz.

Bez újmy na obecnosti předpokládejme, že \mathcal{M} je nedeterministický.

- $N = \{\bar{q} \mid q \in Q\} \cup \{S\}$, kde $S \notin Q$.
- P je nejmenší množina pravidel splňující:
 - Pokud $p \in \delta(q, a)$, je $\bar{q} \rightarrow a\bar{p}$ pravidlo v P .
 - Pokud $p \in \delta(q, a)$ a $p \in F$, je $\bar{q} \rightarrow a$ pravidlo v P .
 - Pokud $p \in \delta(q_0, a)$, je $S \rightarrow a\bar{p}$ pravidlo v P .
 - Pokud $p \in \delta(q_0, a)$ a $p \in F$, je $S \rightarrow a$ pravidlo v P .
 - Pokud $q_0 \in F$, je $S \rightarrow \varepsilon$ pravidlo v P .

Gramatika $\mathcal{G} = (N, \Sigma, P, S)$ je zřejmě regulární.

Platí: $\hat{\delta}(q_0, a_1 \dots a_k) \cap F \neq \emptyset$, kde $k \geq 0, a_1, \dots, a_k \in \Sigma$
 $\iff S \Rightarrow^* a_1 \dots a_k$

□

Rozhodnutelné problémy pro třídu reg. jazyků

Regulární jazyk – popsaný některým z uvažovaných formalismů.

Otzky: Máme-li dány konečné automaty \mathcal{M} a \mathcal{M}' nad Σ

ekvivalence: jsou \mathcal{M} a \mathcal{M}' ekvivalentní? (platí $L(\mathcal{M})=L(\mathcal{M}')$?)

inkluze (jazyků): platí $L(\mathcal{M}) \subseteq L(\mathcal{M}')$?

příslušnost (slova k jazyku): je-li dáno $w \in \Sigma^*$, platí $w \in L(\mathcal{M})$?

prázdnost (jazyka): je $L(\mathcal{M}) = \emptyset$?

univerzalita (jazyka): je $L(\mathcal{M}) = \Sigma^*$?

konečnost (jazyka): je $L(\mathcal{G})$ konečný jazyk?

Věta 2.74 Problém **prázdnosti** ($L(\mathcal{M}) \stackrel{?}{=} \emptyset$) a problém **univerzality** ($L(\mathcal{M}) \stackrel{?}{=} \Sigma^*$) jsou rozhodnutelné pro regulární jazyky.

Důkaz. $L(\mathcal{M})$ je prázdný, právě když mezi dosažitelnými stavami automatu \mathcal{M} není žádný koncový stav.

Univerzalita: $L(\mathcal{M}) = \Sigma^* \iff \text{co-}L(\mathcal{M}) = \emptyset$. □

Věta 2.77 Problém **ekvivalence** je rozhodnutelný pro regulární jazyky.

Důkaz. Pro libovolné L_1, L_2 platí:

$$(L_1 = L_2) \iff (L_1 \cap \text{co-}L_2) \cup (\text{co-}L_1 \cap L_2) = \emptyset.$$

Pro L_1, L_2 zadané automaty lze uvedené operace algoritmicky realizovat.

Alternativně: minimalizace a kanonizace. □

Věta 2.76 Problém, zda jazyk L zadaný automatem \mathcal{M} je **konečný**, resp. **nekonečný**, je rozhodnutelný.

Důkaz. Nechť \mathcal{M} je DFA. L je nekonečný právě když \mathcal{M} akceptuje alespoň jedno slovo $w \in \Sigma^*$ s vlastností $n \leq |w| < 2n$, kde $n = \text{card}(Q)$.

(\Rightarrow) L nekonečný, pak existuje $u \in L$ takové, že $|u| \geq n$.

Je-li $|u| < 2n$, jsme hotovi.

Nechť $|u| \geq 2n$. Z lemma o vkládání plyne, že $u = xyz$, kde $1 \leq |y| \leq n$ a $xz \in L$. Platí $|xz| \geq n$. Pokud $|xz| \geq 2n$, celý postup opakujeme.

(\Leftarrow) $|w| \geq n$, pak \mathcal{M} na w musí projít dvakrát stejným stavem.

Proto $w = xyz$ tak, že $|y| \geq 1$ a platí $xy^i z \in L$ pro každé $i \in \mathbb{N}_0$ (viz důkaz lemmatu o vkládání), tedy L je nekonečný.

Existenci $w \in L$ takového, že $n \leq |w| < 2n$, lze algoritmicky ověřit (slov je konečně mnoho, “vyzkoušíme” každé z nich). \square

Aplikace reg. jazyků a konečných automatů

vyhledávání vzorů (pattern matching) v textu (editory, textové systémy),
DNA sekvencích, . . .

Například v Unixu:

grep - vyhledávání podle zadaného regulárního výrazu

egrep - vyhledávání podle zadaného rozšířeného regulárního výrazu

fgrep - vyhledávání podle zadaného řetězce

Zpracování lexikálních jednotek například při automatizované konstrukci
překladačů (lex, flex)

Zpracování obrazů (image processing)

Konečné automaty nad nekonečnými slovy

Specifikace a verifikace konečně stavových systémů

Konečné automaty s výstupem

Bezkontextové jazyky

Bezkontextová gramatika (context-free grammar, CFG) \mathcal{G} je čtveřice (N, Σ, P, S) , kde

- N je neprázdná konečná množina **neterminálních symbolů**,
- Σ je konečná množina **terminálních symbolů** taková, že $N \cap \Sigma = \emptyset$ (značení: $V = N \cup \Sigma$),
- $S \in N$ je **počáteční neterminál**,
- $P \subseteq N \times V^*$ je konečná množina **pravidel**.

Jazyk je **bezkontextový**, pokud je generovaný nějakou bezkontextovou gramatikou.

Příklad

$\mathcal{G} = (\{E, T, F\}, \{+, *, (,), i\}, P, E)$, kde P obsahuje pravidla

$$E \rightarrow E + T \mid T$$

$$T \rightarrow T * F \mid F$$

$$F \rightarrow (E) \mid i$$

Derivační stromy pro bezkontextové gramatiky

Definice 3.1. Nechť $\mathcal{G} = (N, \Sigma, P, S)$ je CFG.

Strom T nazveme **derivačním stromem** v \mathcal{G} právě když

1. kořen má návěští S , vnitřní uzly mají návěští z N , listy mají návěští z $N \cup \Sigma \cup \{\varepsilon\}$,
2. má-li vnitřní uzel návěští A a jeho všichni synové n_1, \dots, n_k mají v uspořádání zleva doprava návěští $X_1, \dots, X_k \in V$, pak $A \rightarrow X_1 \dots X_k \in P$,
3. každý list s návěštím ε je jediným synem svého otce.

Výsledkem derivačního stromu T nazveme slovo vzniklé zřetězením návěští listů v uspořádání zleva doprava.

Vztah mezi derivačními stromy a relací \Rightarrow^*

Věta 3.3. Nechť $\mathcal{G} = (N, \Sigma, P, S)$ je CFG. Pak pro libovolné $\alpha \in (N \cup \Sigma)^*$ platí $S \Rightarrow^* \alpha$ právě když v \mathcal{G} existuje derivační strom s výsledkem α .

Důkaz. Označme $\mathcal{G}_A \stackrel{\text{def}}{=} (N, \Sigma, P, A)$, kde $A \in N$. Dokážeme, že pro každé $A \in N$ platí

$$A \Rightarrow^* \alpha \iff \exists \mathcal{G}_A \text{ existuje derivační strom s výsledkem } \alpha$$

(\Leftarrow) Nechť α je výsledkem derivačního stromu, který má k vnitřích uzlů. Indukcí vzhledem ke k ukážeme, že pak $A \Rightarrow^* \alpha$.

Základní krok $k = 1$:

Indukční krok $k > 1$:

(IP) Tvrzení platí pro stromy s nejvýše $k - 1$ vnitřními uzly.

Strom T s k uzly:

- je-li X_i list, označme $\alpha_i = X_i$
- není-li X_i list, pak α_i je výsledkem podstromu T_i s kořenem X_i
- Výsledek T je $\alpha_1 \dots \alpha_n$.

Platí: $X_i \Rightarrow^* \alpha_i$ (pro X_i , které není listem, podle (IP))
 $A \rightarrow X_1 \dots X_n \in P$ (z definice deriv. stromu)

Dostáváme $A \Rightarrow X_1 \dots X_n \Rightarrow^* \alpha_1 \dots \alpha_n$.

(\Rightarrow) Nechť $A \Rightarrow^* \alpha$. Ukážeme, že v \mathcal{G}_A existuje derivační strom s výsledkem α . Použijeme indukci k délce odvození $A \Rightarrow^* \alpha$.

Základní krok $A \stackrel{0}{\Rightarrow} \alpha$: Pak $\alpha = A$ a odpovídající derivační strom má jen jeden uzel (kořen je list) s označením A .

Indukční krok $A \stackrel{k+1}{\Rightarrow} \alpha$, $k \geq 0$:

(IP) Pro každé $B \in N$ platí: pokud $B \Rightarrow^* \beta$ v nejvýše k krocích, pak v \mathcal{G}_B existuje derivační strom s výsledkem β .

$$A \stackrel{k+1}{\Rightarrow} \alpha \quad \Rightarrow \quad A \Rightarrow X_1 \dots X_n \stackrel{k}{\Rightarrow} \alpha_1 \dots \alpha_n, \text{ kde } X_i \stackrel{\leq k}{\Rightarrow} \alpha_i$$

Konstrukce stromu s výsledkem α :

□

Jednoznačnost derivačních stromů

Derivace je sekvence $S \Rightarrow \alpha_1 \Rightarrow \alpha_2 \Rightarrow \dots \Rightarrow \alpha_n$.

Levá (resp. **pravá**) **derivace** je taková derivace, kde každé α_{i+1} vznikne z α_i přepsáním nejlevějšího (resp. nejpravějšího) neterminálu.

Každému derivačnímu stromu odpovídá jediná levá derivace.

Každé levé derivaci odpovídá jediný derivační strom.

Analogicky pro pravou derivaci.

Existuje pro každé $w \in L(\mathcal{G})$ právě jeden derivační strom?

Definice 3.7. CFG \mathcal{G} se nazývá **víceznačná (nejednoznačná)** právě když existuje $w \in L(\mathcal{G})$ mající alespoň dva různé derivační stromy.

V opačném případě říkáme, že \mathcal{G} je **jednoznačná**.

Bezkontextový jazyk L se nazývá **vnitřně (inherentně) víceznačný**, právě když každá bezkontextová gramatika, která jej generuje, je víceznačná.