

关于一个串为正则语言中 某串的子串的判定算法

庄雷

(郑州大学计算机系, 郑州 450052)

ALGORITHM FOR DECIDING WHETHER A STRING IS A SUBSTRING OF THE STRING WHICH BELONGS TO A REGULAR LANGUAGE

Zhuang Lei

(Department of Computer Science, Zhengzhou University, Zhengzhou 450052)

Abstract The algorithm is given for deciding whether a string s is a substring of the string which is in a regular language L . That also means assuming s is a string over Σ , L is a regular language over Σ . s is a substring of the string in L , if and only if s is a substring of the string which belongs to the set $V_n = \{w \in \Sigma^* \mid w \in L, |w| \leq 2n + k - 2\}$ where $k = |s|$, n is a nature number.

摘要 本文给出一个判定 Σ 上的任意串 s 是否为一正则语言 L 中某个串的子串的算法. 即设 s 为 Σ 上的任一串, L 是 Σ 上的任一正则语言, 则 s 为 L 中某个串的子串, 当且仅当 s 为集合 $V_n = \{w \in \Sigma^* \mid w \in L, |w| \leq 2n + k - 2\}$ 中某串的子串, 其中 $k = |s|$, n 是某个自然数.

本文给出一个有穷字母表 Σ 上的任意串是否为 Σ 上的一正则语言中某个串的子串的判定算法. 设 L 是 Σ 上的一个正则语言, s 是 Σ 上长为 k ($k \geq 2$) 的任意一个串, 则存在一个判定 s 是否是 L 中某个串的子串的算法, 即 s 是 L 中某个串的子串, 当且仅当 s 是集合

$$V_n = \{w \in \Sigma^* \mid w \in L, |w| \leq 2n + k - 2\}$$

中某个串的子串, 其中 n 为某个不依赖于 k 的自然数.

这个算法的意义在于, 只需在有穷多个字符串上逐个进行检验, 即可判定 s 是否为 L 中某个串的子串. 这对研究字符串之间的关系, 特别是对研究由子串关系定义的 Σ^* 上的半序关系所引进的几种广义凸语言都是很有意义的.

定理(子串判定算法):

设 L 是有穷字母表 Σ 上的一个正则语言, 则存在一自然数 n , 使对于 Σ 上的长为 k 的任意串 $s, k \geq 2, s$ 为 L 中某个串的子串, 当且仅当 s 为集合

$$V_n = \{w \in \Sigma^* \mid w \in L, |w| \leq 2n + k - 2\}$$

中某个串的子串.

证明: 由于 L 是有穷字母表 Σ 上的正则语言, 则存在一接受 L 的有穷状态自动机

$$M = (K, \Sigma, \delta, q_0, F),$$

令 $|K| = n$, 即自动机的状态个数为 n (若 $|K| = 1$, 则令 $n = 2$). 显然, 只需证明定理的“仅当”部分. 为此, 只需证明, 若 $s = a_1 a_2 \dots a_k$ 是 $w (\in T(M) - V_n)$ 的子串, 则 s 必是 V_n 中某个串的子串.

设 $w = b_1 b_2 \dots b_{n-1} b_n \dots b_{n+k-1} b_{n+k} \dots b_{2n+k-2} \dots b_m, m > 2n+k-2, w$ 是 $T(M) - V_n$ 中的任意字, 而 s 是 w 的子串. 现将 w 分成三部分. 第一部分由前 $n+k-1$ 个符号组成, 记作 $\langle I \rangle$; 第二部分从 b_{n+k} 到 b_{2n+k-2} 由 $n-1$ 个符号组成, 记作 $\langle II \rangle$; 从 b_{2n+k-1} 到串结束为第三部分, 记作 $\langle III \rangle$. 根据 s 在 w 中的位置, 采取相应的步骤证明.

1. 若串 s 完全位于 $\langle I \rangle$ 中, 则在有穷状态自动机 M 输入字 w 的过程中, 在 $\langle I \rangle$ 中已输入 $n-1$ 个字符, 经历了 n 个状态, 当输入完字段 $\langle III \rangle$ 时, M 在 $\langle I \rangle, \langle III \rangle$ 部分所经历的状态中至少有一个要重复出现两次, 设这个状态为 q . 于是可将 w 写成 $w = x_1 x_2 x_3$, 使得 $q(q_0, x_1) = q, \delta(q, x_2) = q, \delta(q, x_3) = p$, 而 $p \in F$. 显然, $x_1 x_3 \in T(M)$, 而 $|x_2| > 0$, 所以 $|x_1 x_3| < |x_1 x_2 x_3| = |w|$. 若 $|x_1 x_3| \leq 2n+k-2$, 则定理得证, 否则重复上述过程, 经过有限次以后, 得到一个字 y , 使得 $y \in V_n$, 且 s 仍为其子串.

2. 若 s 不是完全位于 $\langle I \rangle$ 中, 即有元素 $a_i \in s$ 使其位于 $\langle I \rangle$ 以后的位置, 则在 M 输入字 w 的过程中, 在输入了前 $n-1$ 个字符后, 当输入完第 n 个字符时, M 中至少有一个状态重复出现二次. 同样, 可将 w 分成三段, 即 $w = x_1 x_2 x_3$, 而 $|x_2| > 0$, 使得 $x_1 x_3 \in T(M)$ 且 s 在 $x_1 x_3$ 中. 若 $|x_1 x_3| > 2n+k-2$ 且 s 仍不完全位于 $\langle I \rangle$ 中, 则重复上述过程; 若 $|x_1 x_3| > 2n+k-2$, 但 s 完全位于 $\langle I \rangle$ 中, 则按步骤 1 进行; 若 $|x_1 x_3| \leq 2n+k-2$, 则定理得证.

总之, 经过有限次上述相应的步骤, 即可证明: s 为 V_n 中某串的子串. 于是定理得证.

参考文献

1 J. E. Hopcroft, J. D. Ullman, Introduction to Automata Theory, Languages and Computation, Addison - Vesley Publishing Company, 1979.