数理解析研究所講究録
第461巻 1982年 102-112

文字列の同時置き換えのための パタン・マッチング・マシンについて

九州大学理学部　有川節夫

1. はじめに

筆者等は九州大学大型計算機センターにおいて，文字列を対象とした研究者用の情報システム SIGMA を実現した [1], [2]．このシステムで扱うデータはほとんど文字列データである．そこで Aho-Corasick [3] によるパタン・マッチング・マシンの手法を駆使した一方向逐字処理 [4] を開発し使用している．

SIGMA システム1つのコマンドとして，テキスト・データの編集に有用な複数個の文字列の同時置き換えを行うための REPLACE がある．これは，与えられたキーワードの対の集合

$$K = \{(x_1, y_1), (x_2, y_2), \ldots, (x_k, y_k)\} \quad (i \neq j \text{ ならば } x_i \neq x_j)$$

に対して，テキスト系列を左から右へ一読する間に集合

$$K_X = \{x_i ; (x_i, y_i) \in K\}$$

の中のなるべく長いキーワード x_i を探し出し，それを対応

するキーワード y_i で次々に置き換えてできるテキスト系列を作るものである.

SIGMA システムでは, K_X から Aho-Corasick の方法でパタン・マッチング・マシンを作り, それを走らせるアルゴリズムに工夫をこらして, REPLACE コマンドを実現している. しかし, これでは走査時の負担が大きくなり効率的でないので, 新しく固有のパタン・マッチング・マシンを開発した. 以下にその概要について報告する.

2. 文字列の同時置き換え

上で述べた「なるべく長いキーワード x_i を探し出しそれを y_i で置き換える」ということは, もう少し正確にいうと次のようなことである. 図1において直線は入力テキスト系列を表わすものとし, $x_i \in K_X$ とする.

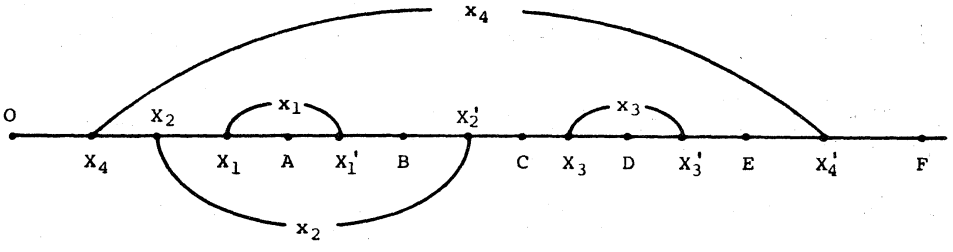

図1. 入力テキストとキーワード x_i

我々が求めるパタン・マッチングマシンは [OA], [OB],... 等

で表わされる入力テキスト系列を次のように変換し出力するものである.

text	replaced text
[OA]	[OA]
[OB]	$[OX_1)y_1(X_1'B]$
[OC]	$[OX_2)y_2(X_2'C]$
[OD]	$[OX_2)y_2(X_2'D]$
[OE]	$[OX_2)y_2(X_2'X_3)y_3(X_3'E]$
[OF]	$[OX_4)y_4(X_4'F]$

さて, こうした文字列の同時置き換えのためのパタン・マッチング・マシン(RPMM と書く)は, Aho-Corasick のマシンと同様に goto 関数 g と, failure 関数 f, 出力関数 output からなる. 与えられたキーワードの対の集合 K から g, f, output を作るわけであるが, そのアルゴリズムは Algorithm 1 と 2 である. g を作る Algorithm 1 は Aho 達のものと output 関数への割当ての所を除いて全く同一である. Algorithm 2 は, failure 関数 f と Algorithm 1 で部分的に求められた output を完成させるためのものである.

Algorithm 1, 2 によって作られる RPMM を, M = (K, g, f, output) で示すことにする.

(例) $K = \{(ABCDF, \alpha), (CDE, \beta), (BC, \gamma)\}$ に対する RPMM

Algorithm 1. (Construction of the goto function)

Input. Set of keyword pairs $K=\{(x_1, y_1),\ldots, (x_k, y_k)\}$.

Output. Goto function g and a partially computed output function output.

Method.

```
begin
    newstate:=0;
    for i:=1 until k do enter(x_i);
    for all a such that g(0, a)=fail do g(0, a):=0
end

procedure enter(a_1a_2...a_m, y):
    begin
        state:=0; j:=1;
        while g(state, a_j) ≠ fail do
            begin
                state:=g(state, a_j);
                j:=j+1
            end
        for p:=j until m do
            begin
                newstate:=newstate + 1;
                g(state, a_p):=newstate;
                state:=newstate
            end
        output(state):=y
    end
```

M=(K, g, f, output)を図2に示す. この図において, 破線を除いた部分がgoto関数gであり, 破線及び破線の出ていない状態から, 状態0への遷移がfailure関数fを表わしている. 出力関数は, 二重丸の印いた状態に対しては, Algorithm 1によって定義され, 0以外の残りの状態に対しては, Algorithm 2によって定義される.

このようにしてAlgorithm 1, 2によって作られたRPMM M=(K, g, f, output)が, 入力テキスト上をAlgorithm 3に従って

Algorithm 2. (Construction of the failure function).

Input. Goto function g and output function output from Algorithm 1.

Output. Failure function f and output function output.

Method.

```
begin
  queue:=empty;
  for each a such that g(0, a)=s ≠ 0 do
    begin
      queue:=queue.s;
      f(s):=0;
      if output(s) is undefined then output(s):=a
    end
  while queue ≠ empty do
    begin
      let queue=r.tail;
      queue:=tail;
      for each a such that g(r, a)=s ≠ fail do
        begin
          queue:=queue.s;
          if output(s) is defined then f(s):=0 else
            begin
              state:=f(r);
              while g(state, a)=fail do
                begin
                  output(s):=if output(s) is defined
                                then output(s).output(state)
                                else output(state);
                  state:=f(state)
                end
              f(s):=g(state, a);
              output(s):=if output(s) is defined
                            then output(r).output(s)
                            else output(r);
              if f(s)=0 then output(s):=output(s).a
            end
        end
    end
end
```

走ることになる. このAlgorithm 3はfによるfailure遷移をするたびにその状態に対する出力を関数outputに従って出す. また入力テキストを読み終った時点では, その時の状態から状態0に至るまでのfailure遷移をくり返し対応する出力を

$K = \{(ABCDEFG, \alpha), (BC, \beta), (EF, \gamma)\}$

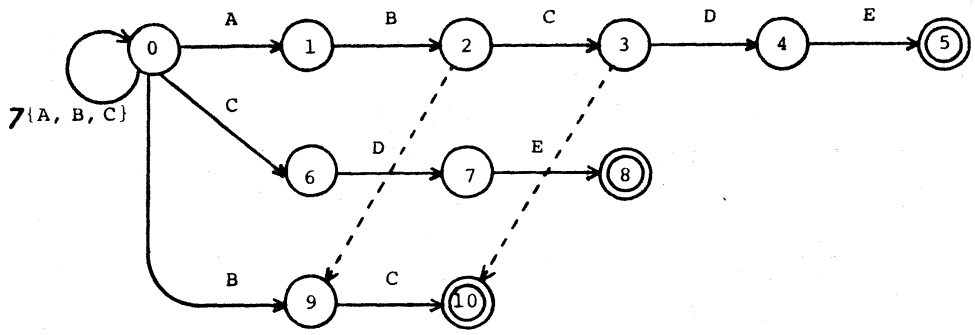

s	output(s)
0	undefined
1	A
2	A (output(1))
3	A
4	AγD (output(3)·output(10)·a)
5	α
6	C
7	CD (output(6)·a)
8	β
9	B
10	γ

図2. R-パタン・マッチング・マシン

出す. なお g(0, a)=0 に対しては a を出力するようになっている点に注意しよう.

(例) 図2のMは入力テキスト DEABCCBCE上で, 図3のように動く. 結局 0→0 遷移の際の入力記号と破線で示した failure 遷移による出力を綴り合せた DEAγCγE が出力系列と

して得られる.

Algorithm 3. (Pattern matching machine for multiple replacement)

Input. A text string $z=a_1a_2...a_n$ and a pattern matching machine with functions g, f and output.

Output. A replaced text string $w=b_1b_2...b_t$.

Method.

```
begin
    state:=0;
    for i:=1 until n do
        begin
            while g(state, a_i)=fail do
                begin
                    print output(state);
                    state:=f(state)
                end
            state:=g(state, a_i);
            if state=0 then print a_i
        end
    while state ≠ 0 do
        begin
            print output(state);
            state:=f(state)
        end
end
```

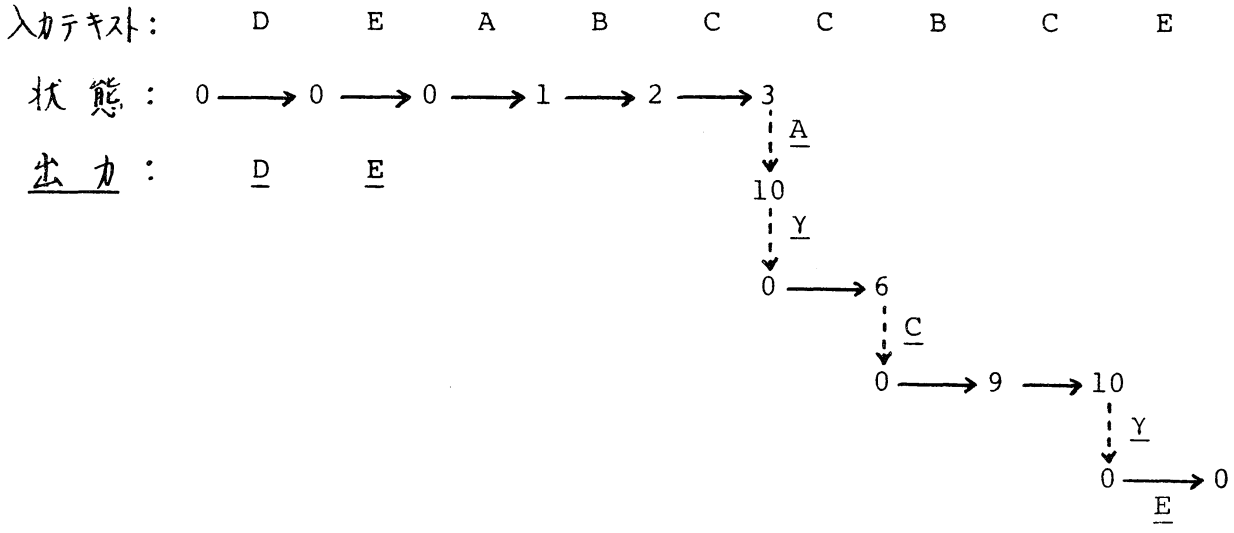

図3. R-パタン・マッチング・マシン M の動き

3. アルゴリズムの妥当性

Algorithm 1, 2 で作られた RPMM $M=(K, g, f, output)$ は Algorithm 3 に従ってテキスト系列上を走るとき，我々の目的にかなった妥当なものであるといえる．

いま，$M=(K, g, f, output)$ を RPMM として，任意のテキスト系列 w に対して，Algorithm 3 を適用して得られる出力系列を $M(w)$ とする．任意の入力テキスト系列 w に対して，u を

(1) $w = uxv, \quad x \in K_{\Sigma}$

となる x が存在するときは，そのような最も短かい文字列とし，x をこの u に対して (1) を満たす最も長い文字列とする．(1) を満たす x が存在しないときは $u=a$ (a は文字)，$x=\varepsilon$ (ε は空列) とする．

$$M(w) = M(uxv) = uK(x)M(v)$$

であれば，RPMM M は<u>妥当 (valid)</u> であるという．ここに，$K(\varepsilon)=\varepsilon$ と仮定する．

<u>定理1.</u> Algorithm 3 に従って走る RPMM $M=(K, g, f, output)$ は妥当である．

証明は Aho-Corasick [3] と同様に関数 g, f, output の性質に関する補題を用意して行う．

4. 時間計算量

Algorithm 1, 2, 3 の時間計算量 (time complexity) に関しては, [3] と全く同様にしていずれも線形時間であることが示される. 即ち,

定理2. Algorithm 3 が長さ n の入力テキストの変換に要する時間を T(n) とすると

$$T(n) < 3n$$

である.

証明. [3] と違って failure 遷移の回数が最悪の場合 2(n-1) 回生じる可能性がある.

定理3. Algorithm 1 が要する時間は, K_X のキーワードの長さの和に関して線形である.

定理4. Algorithm 2 が要する時間は, K に含まれる 2k 個のキーワードの長さの和に関して線形である.

5. 最適化

Algorithm 1, 2 で作られた RPMM には冗長な failure 遷移が含まれている. 例えば, 図2の M において, 状態2及び3からの failure 遷移は, その行き先きである状態 9, 10 で再び 0 への failure 遷移を必要とするので, 冗長である. このような f と output を次の方法で, [3], [4] と同様にして, f', output' へと最適化することができる.

$$f'(1) = 0,$$

$$f'(i) = \begin{cases} f'(f(i)) & (\forall a \text{ に対して } g(f(i),a)=\text{fail または } g(i,a)\neq\text{fail のとき}) \\ f(i) & (\text{そうでないとき}); \end{cases}$$

$$\text{output}'(1) = \text{output}(1)$$

$$\text{output}'(i) = \begin{cases} \text{output}(i) & (f'(i)=f(i) \text{ のとき}) \\ \text{output}(i)\text{output}(f(i)) & (\text{そうでないとき}), \end{cases}$$

ここに，状態1，iは深さ1，iの状態を表わすものである．

この方法を図2のMに適用すると，g，f'としては，破線部をとり除いたクラスで表わされるものをもち，出力関数としては

$$\text{output}'(2) = AB$$

$$\text{output}'(3) = A\gamma$$

$$\text{output}'(i) = \text{output}(i) \qquad (i \neq 2, 3)$$

をもつ RPMM M' へと最適化される．

6. おわりに

文字列の同時置き換えを行うためのパタン・マッチング・マシンを Aho-Corasick とほぼ同様のアルゴリズムで構成し，走らせることができることを示した．ここで示した方法は最長のマッチングをとるための方法としても使えるので，構文解析の道具としても応用できるであろう．

参考文献

1. 有川，篠原，白石，玉越：研究者向き情報システム SIGMA について，九大大型計算機センター広報，Vol. 14, No.4, 1981, 550-573.

2. Arikawa, S. et al.: SIGMA — An Information System for Researchers Use, Bull. Inform. Cybernetics (1982, in press).

3. Aho, A.V. and Corasick, M.T.: Efficient String Matching: An Aid to Bibliographic Search, CACM 18, 1975, 335-340.

4. Arikawa, S.: One-Way Sequential Search Systems and Their Powers, Bull. Math. Stat., Vol. 19, 1981, 69-85.