

逐次検索システムと言語について

九大理 情報研 有川節夫

1. はじめに

逐次サーチに基づく情報検索システムは走査するデータの量に少くとも比例する時間と検索時に必要とする。このためには多数の利用者を対象にする一般的な IR システムとしては不向きである。しかし最近の廉価で高速な外部メモリの開発と普及によって、利用者に新しい問題意識が生れてきた。そして効率的な逐次サーチに関する理論的研究の進展によって、こうした問題の解決が可能になりつつある。

本稿では、数年来筆者等が開発して使用している一方逐次サーチに基づく情報検索システム TEXTIR (Text Information Retrieval System) について、その概要及び能力について考察する。

2. 準備

Σ を字母とする。レコードは Σ^* の要素であり、ファイルは Σ^* の部分集合であるといえる。ファイルはある規則(方針)に従って集められるので、その規則を文法 G と考へると、ファイル

イルは文法 G によって生成される言語 $L(G)$ ということにする。
通常ファイルは $L(G)$ の有限な部分集合である。

逐次検索システムにおいて質問 Q を満たすレコードの集合を検索することは、ファイル $L(G)$ と質問 Q が定義する文法 G' によって定まる言語 $L(G')$ との共通部分 $L(G) \cap L(G')$ を作ることに对应する。質問が $L(G)$ 又は Σ^* の或る明確な部分族を定義できれば、システムの能力を知る上で都合がよい。システムと質問文によって定義される言語族が正規集合族と一致するとき、システムを R -可能ということにする。逐次検索システムとこのように形式言語との対応関係で扱えることによつて、システムの能力の定性的評価が可能になる。

さて、TEXTIR は逐次サーチの部分に Aho-Corasick [1] によるパタン・マッチング・マシンを使用している。パタン・マッチング・マシンは Σ^* の要素としてのテキスト系列を左から右へ一方に向かって一度だけ走査して、与えられたキー (Σ^* の元) の有限集合 K の要素の存在場所をことごとく知らせてくれる一種の有限オートマトンである。従つて、検索システムには、このように出来上がったオートマトンを系列上に走らせる部分と、与えられた K から有限オートマトンを作る部分が必要である。後者は goto 関数構成部と failure 関数構成部から成り立つてゐる。

3. TEXTIR の機能と特徴

TEXTIR はパターン・マッチング・マシンを土台にして、次のこととに留意して構成した。即ち、

- a) パターン・マッチング・マシンを効率良く実現すること。
- b) 機能をできるだけ拡張追加すること。
- c) しかし、そのために速度と効率と犠牲にしないこと。

その結果、結局その Aho-Corasick システムのもつ機能に加えて次の機能と利点をもつものになった。

1) $\Sigma^* x_1 \Sigma^* x_2 \Sigma^* \dots \Sigma^* x_n \Sigma^*$ 形の言語の認識。この機能はキーの出現順序が意味をもつような検索において特に有効である。例えば、 x followed by y の形の検索は、"ゆゆ
トリアル・ドット"を含むキー $A=x\dots y$ と論理式 $Z=A$ を单纯な算術で可能である。

2) 自由なレコード形式。このシステムでは検索の対象となるレコード形式を特定のものに限定していなかつ。ファイル全体を1つの長い文字列として検索を行う。必要なレコードは、出力区切り語を通常のキーと同様に登録して、2つの出力区切り語で囲まれた区间として、検索時に自動的に取出されることができる。

3) 複数質向の同時処理。TEXTIR は一方向の逐次サーキュレーション基づいているため、検索時向は必然的に走査対象のファイル

ルの長さに比例する。そこで、一連の検索における全体の検索時間を短縮するため、最高 15 行までの質問を同時に処理できるようにした。この場合も作成されるパタン・マッチング・マシンは唯一行である。

4) ユニバースの制限。質問は Σ^* のある部分集合を定義するわけであるが、字母 Σ は実際には、計算機で使用できる全ての文字や記号からなる。質問によっては、このユニバース Σ^* を適当な部分集合、例えば、 $\Sigma^* (\Sigma_0 \subset \Sigma)$ に制限したくなる場合もある。これは理論的にはいつでも可能であるが、実際には質問において多数のキーと登録しなければならぬため実用的ではない。そこで TEXTIR では no reset というモードを指定することによって、初期状態への failure transition と、次の出力区切り語と検出するまで禁止することとした。これによつて、キー及び入力・出力区切り語に使用され得る語の集合を X とすると、ユニバースとほぼ X^* に制限することが可能になった。このモードの選択による検索時間への影響はない。

5) メモリの節約。Aho-Corasick の技法を直接的に採用すると、パタン・マッチング・マシンを実現するには、goto 関数を状態図で表わした場合の「ノード数」 + 「終点ノード数」 = n となるとき、サイズ $3n$ の遷移表が必要である。しかし、この表の

goto 関数の行は、任意の状態を π に対して $goto(\pi) = \pi + 1$ となるように出来るので、除去できる。したがって表のサイズを $2n$ に縮めることができる。

6) 検索時間の短縮。遷移表のサイズを固定して、無駄な動作を出来るだけ減少させようとした。(文献[4]参照)

7) R-万能性。式変数と Σ^+ 変数@と論理式に許すとによって R-万能性を得た。したがって、このシステムで少くとも理論的にはすべての正規言語を定義することができる。更に正規文法で書かれたレコードの構文チェックも可能となつた。

4. 質問文と検索

TEXTIRでは、区切り語やキー、論理式の登録に先立つて、トリプル・ドットと表やカ記号、復改用の記号、エラー訂正用の記号、reset/noreset の指定を行うことが出来る。勿論システムには標準的な記号、モードが仮定されているので、これらの指定を省略することもできる。

1) 区切り語。区切り語は Σ^+ の要素であり、出力区切り語と入力区切り語がある。出力区切り語は長いテキスト系列の中に仮想的なレコードを設定して、入力区切り語は論理式と評価すべき区间を指定する。「通常は」出力区切り語は入力区切り語としても働く。システムは入力区切り語を検出するたびに論理式を評価し、出力区切り語と検証した時点での論理

式の値が 1(true) であるような質問に対する検索結果として、最近の 2 つ出力区切り語で囲めた仮想的レコード "と出力する。図 1 の場合には、「通常の」検索においては、出力区切り語 u_3 を検出した時点での論理式乙の論理和が"

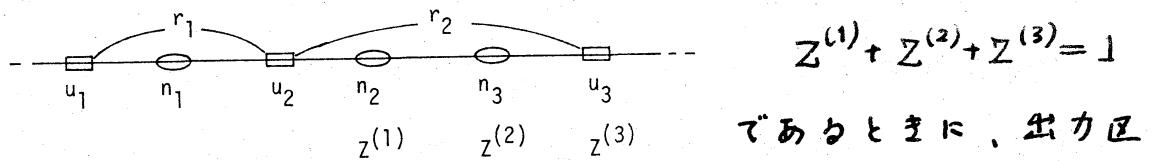


図 1 出力／入力区切り語

□：出力区切り語 (u_1, u_2, u_3)
 ○：入力区切り語 (n_1, n_2, n_3)
 $Z^{(i)}$ ：論理式の値

であるときに、出力区切り語 u_2 と u_3 で囲まれたレコード R_2 となる

論理式に対する検索結果として出力する。

キー、入力区切り語、出力区切り語には、この順序で優先順位がある。したがって、ある記号列がキーでもあり、入力区切り語でもあり更に出力区切り語でもある場合には、システムは、先がキーであることをマークして、論理式と詳述し、仮想的レコードの切り出しを行う。

2) キー。キーには通常のキーとトリプル・ドット (これとで表わす) を含む $x_1 \cdot x_2 \cdot \dots \cdot x_n$ の形のキーがある。キー、区切り語の登録はシステムが発行する変数 A_1, A_2, \dots によって統合して行う。

3) 論理式。「通常の」検索にみける論理式は式変数 Z_1, Z_2, \dots に統合してキー変数 A_1, A_2, \dots と論理和 (+)，論理積 (·)，否定 (-) 及び括弧 [，] を用いて登録する。一般に TEXTIR では論理

式に式変数及み式変数 \oplus を使うこともできる。式変数 \oplus は特別な働きをする。 \oplus の値はシステムが出力区切り語とよぶに離山ようとしているときだけ1で、その後は次の出力区切り語と検出するまで0である。

論理式の評価は Z_1, Z_2, \dots の順序で行われ、出力区切り語と検出して次の仮想レコード上を走査する前に、 $Z_i := ivz(i)$ によって初期化される。ここで $ivz(i)$ は

$$Z_i = f_i(\oplus; A_1, \dots, A_n; Z_1, \dots, Z_m)$$

であるとき、

$$ivz(i) = f_i(1; 0, \dots, 0; ivz(1), \dots, ivz(i-1), 0, \dots, 0)$$

である。

質問リストに \oplus が使用されていないとき、どの論理式 $Z_i = f_i$ にも式変数 Z_j ($j \geq i$) が使用されていないときには、「通常の」方式で検索する。

5. システムの能力

これまでに Aho-Corasick のパターン・マッチング・マシンに論理演算 (+, -, \oplus) だけを使之するシステムと始めとして、「通常の」検索を含む TEXTIR, 一般の TEXTIR の 3 種類の逐次情報検索システムを考えておいたところである。本節ではこれらの能力について考えてみる。

「通常の」TEXTIRにおいては、キー $A=x$ は言語

$$\|A\| = \|x\| = \Sigma^{\#} x \Sigma^{\#}$$

と定義し、キー $A = x_1 \circ x_2 \circ \dots \circ x_n$ は言語

$$\|A\| = \|x_1 \circ x_2 \circ \dots \circ x_n\| = \|x_1\| \cdot \|x_2\| \cdots \|x_n\|$$

と定義すると言えよう。この解釈 $\|\cdot\|$ は一般の論理式にも

$$\|\alpha + \beta\| = \|\alpha\| \cup \|\beta\|$$

$$\|\alpha \cdot \beta\| = \|\alpha\| \cap \|\beta\|$$

$$\|-\alpha\| = \Sigma^{\#} - \|\alpha\|$$

によって拡張できることから、論理式 $Z_i = f(\alpha_1, \dots, \alpha_n)$ は言語

$$\|Z_i\| = \|f(\alpha_1, \dots, \alpha_n)\|$$

と定義することになる。

一般の TEXTIR の質問に対しては多少工夫を要するが、同様に $\|Z_i\|$ をもって、論理式 Z_i が規定する言語を表わすことにある。そして、次のような 3種類のシステムによって定義される Σ 上の言語族を考えてみよう。

$A(\Sigma)$ = Aho-Corasick システムによって定義される言語族,

$R(\Sigma)$ = 「通常の」 TEXTIR による言語族,

$W(\Sigma)$ = 一般の TEXTIR による言語族.

これらに $\text{Reg}(\Sigma)$ を Σ 上の正規言語の族と表わすことにある。

こうすると、族 $A(\Sigma)$ や $R(\Sigma)$, $W(\Sigma)$ の大きさ、或いは $\text{Reg}(\Sigma)$ との関係をもって、システムの検索能力を知ること

ができる。ここでは $\Sigma := \Sigma - \{ \cdot \cdot \cdot \}$ とし、変数の個数、キー や区切り語の長さにに関しては、それが有限であることを除いて特に制限はないものと仮定する。

- (定理1)** (1) $A(\Sigma) = R(\Sigma) \subsetneq W(\Sigma)$ ($\#\Sigma = 1$ のときは),
 (2) $A(\Sigma) \subsetneq R(\Sigma) \subsetneq W(\Sigma)$ ($\#\Sigma \geq 2$ のときは),
 (3) $W(\Sigma) = \text{Reg}(\Sigma)$.

略証. 定義から $A(\Sigma) \subset R(\Sigma) \subset W(\Sigma) \subset \text{Reg}(\Sigma)$ であることは明らかである。また $\#\Sigma = 1$ のときは、

$$\|x_1 \circ x_2 \circ \dots \circ x_n\| = \|x_1 x_2 \dots x_n\|$$

であるから $A(\Sigma) = R(\Sigma)$ である。更に $\Sigma = \{\alpha\}$ とするとき、言語 $L_1 = (\alpha\alpha)^*$ は $R(\Sigma)$ に属しないことが次のようにして示される。 L_1 が $R(\Sigma)$ に属すと仮定して、キーのリスト

$$A_i = \alpha^{r_i} = \alpha\alpha\dots\alpha \quad (r_i \text{ 個}, 1 \leq i \leq n)$$

をもつ質問 $Z = f(A_1, A_2, \dots, A_n)$ が L_1 を定義するとある。

論理式 Z は積和形式

$$Z = f(A_1, A_2, \dots, A_n) = \sum_i A_1^{e_{i1}} \cdot A_2^{e_{i2}} \dots A_n^{e_{in}}$$

で表わされる。ここで $e_{ij} = 0$ 又は 1 であり, $A_j^0 = -A_j$, $A_j^1 = A_j$ である。いま $e_{ij} = 0$ であると、

$$\begin{aligned} \|A_1^{e_{i1}} \dots A_j^{e_{ij}} \dots A_n^{e_{in}}\| &\subset \|A_j^0\| \\ &= \alpha^* - \|A_j\| \end{aligned}$$

$$= \{\varepsilon, a, aa, \dots, a^{r_{\delta}-1}\}$$

となる。 L_1 は無限集合であるから、少くとも 1 つの項

$A_1^{e_{k_1}} \dots A_n^{e_{k_n}}$ に対しては、すべての j に対して $e_{k_j} = 1$ " なければならぬ。そうすると

$$\begin{aligned} \|A_1^{e_{k_1}} \dots A_n^{e_{k_n}}\| &= \|a^{\max(k_1, \dots, k_n)}\| \\ &= a^{\max(k_1, \dots, k_n)} \cdot a^* \end{aligned}$$

となり、 $m > \max(k_1, \dots, k_n)$ に対して、

$$a^m, a^{m+1} \in \|A_1^{e_{k_1}} \dots A_n^{e_{k_n}}\| \subseteq L_1$$

となり、 Σ が L_1 を定義することに反する。したがって L_1 は $R(\Sigma)$ に属さない。 L_1 が $W(\Sigma)$ に属するとは L_1 が正規であることを (3) に依る。これで (1) が証明された。

(2) は $\Sigma = \{a, b\}$ とするとき、 $L_2 = \sum^* a \sum^* a \sum^*$ が $R(\Sigma)$ に属するが、 $A(\Sigma)$ には属さないことに依る。実際 L_2 はキー $A = a \circ a$ と論理式 $\Sigma = A$ によって定義される。 $A(\Sigma)$ に属しないことは上の L_1 に関する議論とほぼ同様にして示される。

(3) は任意の有限オートマトンを $TEXTIR$ の中でシミュレートできることを示せばよい。 $M = (K, \Sigma, \delta, s_1, F)$ を有限オートマトンとする。 $K = \{s_1, s_2, \dots, s_m\}$, $\Sigma = \{a_1, \dots, a_n\}$ として、 a_1, a_2, \dots, a_n を入力区切り語として登録して、各キー変数にキー a_i と $A_i := a_i$ ($1 \leq i \leq n$) と割り当ててお

L. 勿論モードは noreset を選んでおく。そして質向リストを

$$Z_1 = \sum A_j \cdot Z_{n+k} + @,$$

$$(j, k) : \delta(s_k, a_j) = s_i$$

$$Z_i = \sum A_j \cdot Z_{n+k} \quad (1 \leq i \leq m),$$

$$(j, k) : \delta(s_k, a_j) = s_i$$

$$Z_{m+i} = Z_i \quad (1 \leq i \leq m),$$

$$Z_{2m+1} = \sum Z_i, \\ s_i \in F$$

とある。 $\|Z_{2m+1}\| = L(M)$ であることは明らかであろう。

定理1(3) は TEXTIR が "R-不能" であることを示している。したがってこれを正規文法で書かれた L コード の構文チャックにも用いることができる。即ち文法と表現する質向リストを作り、テキスト系列としてその L コード を与え、それが検索結果として出力されるならば、文法に適っていて、そうでなければ文法的誤りがあると判定できる。

実際、例えば図2 で与えられる文法

N に対しては、次のような TEXTIR の

質向が対応する。モードを noreset

に選び、入力区切り語としてはスペ

ース b を登録し、キーと $A_1 = TREAT$, $A_2 = BLEEDING$,

$A_3 = LEFT$, $A_4 = RIGHT$, $A_5 = EXAM$ とする。そして論理式を

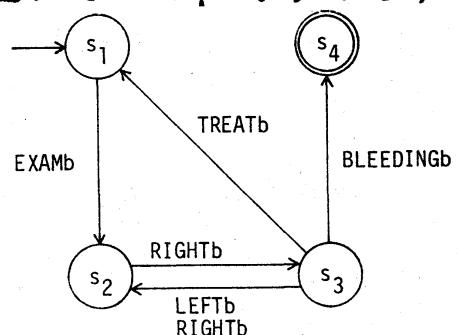


図2 不完全有限オートマトン N
(正規文法)

$$Z_1 = Z_2 \cdot A_2, \quad Z_2 = Z_3 + A_4, \quad Z_3 = Z_4 \cdot A_5 + [A_3 + A_4] \cdot Z_5,$$

$Z_4 = Z_5 \cdot A_1 + @$, $Z_5 = Z_2$ とある。そうすると $\|Z_1\| = L(N)$ となり、 Z_1 でこの文法の構文チェックができる。

さて、この定理からトリポル・ドットの機能は他の論理演算では表せないことも分つた。トリポル・ドットに関するには更に次の定理が成立する。

$R^{(k)}(\Sigma) =$ 「通常の」 TEXTIR における、トリポル・ドットを 1 つのキーの中で高々 n 回しか使用できないと いうような質問によって定義される言語族

である。

$$\text{定理2} \quad A(\Sigma) = R^{(0)}(\Sigma) \subsetneq R^{(1)}(\Sigma) \subsetneq \cdots \subsetneq R(\Sigma).$$

略証。 $L_n = \|a \circ a \circ \cdots \circ a\|$ (n 回) は $R^{(n)}(\Sigma)$ に属すが。

$R^{(n-1)}(\Sigma)$ には属しないことが示される。

E. おわりに

パターン・マッチング・マシンを利用して一方向逐次サーキュレーション情報検索システム TEXTIR について概説し、その能力を述べてみた。システムは「通常」版は FORTRAN で一般の方は Coral 66 で書かれている。今後の方向として、ここで導入した区切り語の概念を一般化して、更にアクションも導入して、検索だけではなく、一般性のあるテキスト編集のためのシステムにある問題がある。

7. 参考文献

- [1] Aho, A.V. and Corasick, M.J. Efficient string matching: An aid to bibliographic search, CACM 18 (1975), 333-340.
- [2] 有川, 武谷, 石橋. パターン・マッチング・マシンと用い方の
文検索システム, 情報処理学会論文集 (1976), 119-120.
- [3] Takeya, S. and Arikawa, S. TEXTIR - A text information retrieval system using pattern matching machines, Res. Rept. Res. Inst. Fund. Inform. Sci., Kyushu Univ. 83 (1978), 1-17.
- [4] Arikawa, S., Hill, A.G. and Townsend, H.R.A. An information retrieval system based on one-way sequential search, Res. Rept. MIRU, Univ. of Edinburgh (to appear).