

手書き片仮名文字認識のための文法推論

上本健治*・甲斐博文**・金岡泰保***・富田真吾***・岡田敏彦***

Grammatical Inference for Recognition of Hand-written Katakana Characters

Kenji UEMOTO, Hirofumi KAI, Taiho KANAOKA, Shingo TOMITA, Toshihiko OKADA

Abstract

In syntactic pattern recognition, the grammatical inference is the process that characterizes a pattern class by a grammar. So establishment of grammatical inference procedure is very important.

In this paper, for the purpose of the recognition of hand-written Katakana characters, we suggest a grammatical inference algorithm for context free grammar. Our inference is developed by selecting sample patterns from original set of sample patterns according to a criterion, and classifying the production rules previously.

1. まえがき

構文的パターン認識は、入力パターンの細線化、ストリング化¹⁾、文法推論^{2), 3)}および誤り訂正ペーパー^{4), 5)}といった一連の過程を経て行われるが、この中で文法推論は、少數のサンプル集合を基にして、あるクラスに属する無限のパターン集合の特徴を文法によって表現しようとする過程である。

本論文は、手書き片仮名文字認識を目的とした文脈自由型文法の一推論法を提案するものである。本方法は、できるだけ簡潔な形で文法を構成するために、用いるサンプル集合をある基準に従って選択すること、および生成規則の型を前もって分類することによって推論が展開される。

2. 文脈自由型文法および生成規則の型分類

本論文で推論の対象とする文脈自由型文法は

$$G = (V_N, V_T, P, S)$$

で与えられる。ここで、 V_N 、 V_T はそれぞれ非終端記号および終端記号の有限集合であり $V_N \cap V_T = \emptyset$ 、また、 V_T^* 上の元をストリングという (U^* は空語 λ を含む U 上の全ての記号系列の集合を表わす)。ストリング $\omega \in V_T^*$ を構成する記号の数をストリングの長さといい $|\omega|$ で示す。但し、 $|\lambda|=0$ 。 P は次のような生

成規則の有限集合である。

$$\alpha \rightarrow \beta, \text{ 但し, } \alpha \in V_N, \beta \in (V_N \cup V_T)^*. \quad (1)$$

S は開始記号を表わし、それから出発してストリングが生成される特殊な非終端記号である。

生成規則の種類が無限に存在することは式(1)からも明らかであるが、本論文では、推論を容易にするために、片仮名文字の特長に注目して、生成規則の型をTable 1に示すように11種類に分類した。Table 中、

Table 1. Classification of production rules.
($A, B, C \in V_N, a, b, c \in V_T$)

class number	①	②	③	④	⑤	⑥
substrings Wi	a b	a b	(a) (a)b	(a) (a)b	(a) b(a)	(a)b
production rule P	A→a A→b	A→a A→a	A→aA A→a	A→aA A→a	A→Aa A→a	A→aA A→b
class number	⑦	⑧	⑨	⑩	⑪	
substrings Wi	b(a)	(a)b (a)b(c)	(a)(b) (a)c(b)	(a)c(b)	(a)(b) (a)c(b)	
production rule P	A→Aa A→b B→a C→bC C→b	A→BC B→aB B→a C→bC C→b	A→BC B→aB B→c C→bC C→b	A→BC B→aB B→a C→bC C→b	A→BC B→aB B→c C→bC C→b	

* 電子工学科（現、シャープ電機）

** 電子工学科（現、TIC）

*** 電子工学科

$A, B, C \in V_N$, $a, b, c \in V_T$ であり, 各 x ($x \in V_T$) に対して, $(x) \in \{x^l | 1 \leq l\}$ である.

3. 文法推論

推論に用いるサンプルストリングは基本要素を表わす記号と基本要素間の連接関係を表わすオペレータで構成されている。すなわち, 基本要素の集合を K , オペレータの集合を R とすると, $V_T = K \cup R$ である。本論文の推論過程はサンプルストリングからさらに有用なストリングを選択することから始まる。

3.1 サンプルストリング S_P^ν の選択

サンプルストリングの集合を

$$S_P = \{\omega_1, \omega_2, \dots, \omega_r\} \quad (1 \leq r)$$

とする。まず, S_P を次のように分割する。

$$S_P = S_P^1 \cup S_P^2 \cup \dots \cup S_P^l \quad (1 \leq l)$$

ここで, 各 S_P^τ ($1 \leq \tau \leq l$) に対して $\omega_i, \omega_j \in S_P^\tau$ ならば $\omega_i = r_1 \Delta_1 r_2 \Delta_2 \dots r_\tau \Delta_\tau$, $\omega_j = r'_1 \Delta'_1 r'_2 \Delta'_2 \dots r'_\tau \Delta'_\tau$ と表わせ, 各 i ($1 \leq i \leq \tau$) に対して $\Delta_i = \Delta'_i$ である。但し, 各 i ($1 \leq i \leq \tau$) に対して $r_i, r'_i \in K^*$ かつ $\Delta_i, \Delta'_i \in R$ 。さらに, $\nu \neq \mu$ なる各 μ ($1 \leq \mu \leq l$, $\mu \neq \nu$) に対して

$$|S_P^\nu| \geq |S_P^\mu|$$

であるような S_P^ν を選択する。

3.2 核生成規則の構成

S_P^ν に属する各ストリングは全て

$$\omega = r_1 \Delta_1 r_2 \Delta_2 \dots r_\nu \Delta_\nu$$

なる形をしていることに着目して, 核生成規則 P_c を

$$P_c : S \rightarrow A_1 \Delta_1 A_2 \Delta_2 \dots A_\nu \Delta_\nu$$

とする。ここで, 各 i ($1 \leq i \leq \nu$) に対して $A_i \in V_N$, $\Delta_i \in V_T$ とする。

3.3 サブストリングの集合 W_i の構成

3.1 で得られた S_P^ν を

$$S_P^\nu = \{\omega_1^\nu, \omega_2^\nu, \dots, \omega_t^\nu\} \quad (1 \leq t)$$

と置き, 各 ω_i^ν ($1 \leq i \leq t$) に対して

$$\omega_i^\nu = r_1^i \Delta_1 r_2^i \Delta_2 \dots r_\nu^i \Delta_\nu$$

とする。このとき, サブストリングの集合 W_i ($1 \leq i \leq \nu$) は

$$W_i = \{r_1^i, r_2^i, \dots, r_\nu^i\}$$

である。従って, W_i ($1 \leq i \leq \nu$) はオペレータを含まない K 上のストリング集合となる。

3.4 文法 G_i の構成

3.3 で得られた各 W_i ($1 \leq i \leq \nu$) に対して, W_i が Table 1 のどの生成規則から導出されるかを調べ, 対

応する生成規則を用いて $G_i = (V_{Ni}, V_{Ti}, P_i, S)$ を構成する。当然のことながら, $V_{Ti} \subseteq K$ である。

3.5 トータル文法 G_T の構成とその簡略化

3.2 および 3.4 で得られた核生成規則 P_c と文法 G_1, G_2, \dots, G_ν より

$$G_T = \bigcup_{i=0}^l G_i$$

であるようなトータル文法 G_T を構成する。但し, $G_0 = (V_N, V_T, P_0, S)$ である。

さらに, $L(G) = L(G_T)$ なる関係を満たすように G_T を簡略化する。すなわち, G_T の生成規則内に同一のストリングを生成するような非終端記号があれば一つに統一し, 不必要な生成規則を削除する。このようにして得られた G を最終的な文法とする。

4. 例 題

いくつかの手書き片仮名 “イ” のサンプル (ストリング化法は文献 (1) の手法による) から

$$S_P^\nu = \{aa + a \times cb, aa + aa \times cbb, aa + a \times bb, a + a \times cb\}$$

が得られたとしよう。ここで, $a, b, c \in K$, $+, \times \in R$ 。すると, 核生成規則は

$$P_c : S \rightarrow E + F \times H$$

となる。又,

$$W_1 = \{aa, aa, aa, a\}$$

$$W_2 = \{a, aa, a, a\}$$

$$W_3 = \{cb, cbb, bb, cb\}$$

であり, W_1, W_2 は Table 1 の③の型, W_3 は⑦の型の生成規則から導出されることがわかる。従って,

$$G_1 = (\{E\}, \{a\}, P_1, E)$$

但し, $P_1 = \{E \rightarrow aE, E \rightarrow a\}$

$$G_2 = (\{F\}, \{a\}, P_2, F)$$

但し, $P_2 = \{F \rightarrow aF, F \rightarrow a\}$

$$G_3 = (\{H\}, \{b, c\}, P_3, H)$$

但し, $P_3 = \{H \rightarrow Hb, Hc\}$

となる。さらに, トータル文法 $G_T = G_1 \cup G_2 \cup G_3 = (V_{NT}, V_{TT}, P_T, S)$ を構成すると

$$V_{NT} = \{S, E, F, H\}$$

$$V_{TT} = \{a, b, c, +, \times\}$$

$$P_T = \{S \rightarrow E + F \times H, E \rightarrow aE, F \rightarrow aF, H \rightarrow Hb, H \rightarrow a, F \rightarrow a, H \rightarrow c\}$$

を得る。 G_T を簡略化することによって $G = (V_N, V_T, P, S)$ を得る。但し,

$$V_N = \{S, E, H\}$$

$$V_T = \{a, b, c, +, \times\}$$

$$P = \{S \rightarrow E + F \times H, E \rightarrow aE, H \rightarrow Hb, E \rightarrow a,$$

Table 2 Some results of the grammatical inference for hand-written Katakana characters.

	sample strings S_P^*	production rules P
イ	aa+a×bbb, aa+aa×bbb aa+a×bb, a×bb	S→E+E×J, E→aE E→a, J→bJ, J→b
イ	ba+a×cb, aa+aa×cbb aa+a×bb, a+a×cb	S→E+G×J, E→Ea, E→a E→b, G→aG, G→a, J→Jb, J→b, J→c
エ	dd+dd×bb+ad×ddd dd+d×bbb+ad×dd dd+dd×bb+ad×dd dd+d×bb+ad×dd	S→E+E×K+L×E, E→dE E→d, K→bK, K→b, L→aL, L→d
エ	ad+d×bb+a×dd a+d×bb+ad×dd aa+d×b+a×cd dd+dd×b+ad×cd	S→E+J×K+L×M, E→aE, E→dE, E→d, E→a, J→dJ, J→d, K→bK, K→b, L→aL, L→a, L→d, M→Md, M→d, M→c
ス	d×a+aa×cc dd×a+a×c dd×ba+aa×c d×a+a×c	S→G×J+K×L, G→dG G→d, J→Ja, J→a, J→b K→aK, K→a, L→cL, L→c
ヒ	b+bbdd×ddd bb+bbdddd×ddd b+bbcddd×ddd b+bbcdd×dd	S→E+G×L, G→KL E→bE, E→b, K→bK K→b, K→c, L→dL L→d
キ	b+(d×c+d×c×d)×d b+(d×c+d×cb×d)×dd b+(d×b+d×c×d)×d b+(d×c+d×cb×dd)×dd	S→E+(N×O+N×Q×T)×T E→b, N→d, O→c O→b, Q→cQ, Q→c Q→b, T→dT, T→d
タ	dda+c+a×aa* da+c+a×ab* dda+c+aa×aab* dda+cc+aa×aa*	S→E+F+J×K*; E→dE E→a, F→cF, F→c J→aJ, J→a, K→aK K→a, K→b
ハ	bbc:bbb, bb:bb bbbb:bb, bc:bb	S→E:F, E→bE, E→b E→c, F→bF, F→b
ル	bbbb:a:bb, bbb:a:bbb bbba:bb, bbbba:bb	S→E:F, E→bE, E→a F→bF, F→b, F→a
ソ	bbaa:c, bbaa:b bbba:c, bbaa:b	S→E:F, E→GJ, G→bG G→b, J→aJ, J→a F→c, F→b
ン	aaad:d, aa:c aaa:c, aa:c	S→E:F, E→aE, E→a E→d, F→d, F→c

$H \rightarrow c\}$.
その他の例を Table 2 に示す.

5. むすび

サンプルストリング集合からさらに S_P^* で示されるようにならざる限られたサンプルを選択し、しかも生成規則の種類を予め規定することで比較的簡潔な文法推論法を確立することができた。本手法を用いて手書き片仮名文字の認識実験を行ったが^{(4), (5)}、ハトルおよびソトン等一部の類似した文字を除くと90%以上の認識率が得られており、このことから本手法は手書き片仮名文字に対して有効であろうと考えられる。

本手法の拡張として、 $S_P^{v1}, S_P^{v2}, \dots, S_P^{vt}$ 対して $G_{v1}, G_{v2}, \dots, G_{vt}$ を構成しそのトータル文法の簡略形として得られる文法を最終的な文法とすることが考えられるが、生成規則の数の増加はパージング過程で要する計算時間の増大を招くことになる。従って、サンプル数、計算時間および認識率相互間の関係についての考察が今後の課題である。

謝辞 ご指導ご助言頂いた本学高浪五男教授、井上克司助教授ならびに御討論頂いた富田研の諸氏に深謝する。

参考文献

- 1) 衣松、浜本、金岡、富田、岡田：“手書き片仮名文字を対象としたストリング化の一手法”，山口大学工学部研究報告，32, 203 (1981).
- 2) G. Thomason: “Syntactic Pattern Recognition, An Introduction,” Addison-Wesley (1978).
- 3) K.S. Fu and T.L. Booth: “Grammatical inference: Introduction and Survey 1”, IEEE Trans. on Syst., Man, Cybern., SMC-5, 95 (1975).
- 4) 森田、金岡、富田、岡田：“文脈自由型誤り訂正文法によるパターン認識について”，山口大学工学部研究報告 32, 195 (1981).
- 5) 岡村、金岡、富田、岡田：“Bottom-up 的構文解析による手書き片仮名文字認識”，山口大学工学部研究報告 32, 319 (1982)

(昭和56年10月15日 受理)