

# 有声破裂音の代表パターンの学習的決定と、 その計算機シミュレーション

鈴木 昇一, 前田 英明

## A Learning Method for the Determination of Prototypical Patterns of Voiced Affricates and its Computer Simulation

Shoichi Suzuki and Hideaki Maeda

あらまし

最小距離分類器、最大相関分類器、最近近傍分類器、不動点探索形構造受精多段階帰納推理の働きでパターン認識を行うシステム RECOGNITRON などでは、典型としての代表パターンを中心とした緩やかなカテゴリを想定している。本研究では、9つの有声破裂音 /ba/, /be/, /bo/, /da/, /de/, /do/, /ga/, /ge/, /go/ を全カテゴリ集合とする場合を想定し、この場合の代表パターンの集合  $\Omega$  が、Kohonenの学習ベクトル量子化法を多少簡単化して得られたアルゴリズムを用いて決定されている。このアルゴリズムで使われる減少関数  $\alpha(t)$  が新しく提案されている。得られた結果は人の耳で聞く限り、大旨良好である。

### キーワード

有声破裂音    学習ベクトル量子化    代表パターン    知覚  
パターンモデル    再帰領域方程式    不動点探索形認識

### Abstract

A minimum-distance classifier, a maximum-correlation classifier, a nearest neighbor classifier and RECOGNITRON (multi-stage inductive-inference recognition-system using structural fertilization transformations of fixed-point searching type) must postulate a gentle definition of each category having a prototypical pattern as a centroid.

We adopt nine voiced affricates (/ba/, /be/, /bo/, /da/, /de/, /do/, /ga/, /ge/, /go/) as a whole set of categories, and prototypical patterns in this case were determined by a simplified algorithm of the learning vector quantization LVQ proposed by Kohonen. A new decreasing function  $\alpha(t)$  needed in this algorithm was used

here. Its simulation result which reproduced the obtained voices by means of a speaker of personal computer Macintosh II<sub>CX</sub> was to some extent satisfactory as long as we listened to them.

**Key words** : voiced affricates learning vector quantization prototypical pattern perception pattern-model reflective domain equation recognition of fixed-point searching type

## 第1章 まえがき

### 1. 1 認識知能情報学の1分野としてのパターン認識

パターン (pattern)  $\phi$  とは、ヒトの顔画像、ヒトの発した音響波形、会話音声、ヒトの描いた文字形、印刷文字形、静止画像、動画像、幾何学的形状などの総称である。ある程度の変形が許されている冗長性のある情報の表現である。

数理科学 (mathematical science) の対象と出来るように、S.Suzukiはこのような類のパターンの**再帰的定義** (recursive definition) が可能なことを認識の働きと関連付けて、初めて明らかにした [3], [7]。

パターン  $\phi$  に対する**認識の働き** (recognition) [1], [12] ~ [14] とは、正規化 (normalization; パターン整形化を目的とした事前処理)、**特徴抽出** (feature-extraction; 識別に役立つ示差的 (distinctive) 量としての特徴量を求めること)、**識別** (classification; パターンの表す類概念を決定すること) なる3つの働きを連動した処理の総称である。

パターン認識技術は当初、人工知能技術の1分野と考えられていたが、その後、記号処理を主目的とする**知能工学** (intelligence engineering) から離反した存在として、扱われた。人工知能分野が人間の苦手な処理を扱うようになっていったからである。ところが、人間の得意な処理を扱おうという気運が漂うになり、当初から**人工頭脳** (artificial brain) として扱われていた digital computer の構成原理に疑問を抱き再登場したニューラルネット理論 [2] は、記号系列による情報処理体系に依存する人工知能理論では容易に扱えない“知識の獲得技術”の存在をその学習法を介し、明らかにし、併せて、認識技術を再構築する役割を積極的に果たした。最近では、パターン認識学は、**知能情報学** (intelligence informatics) の1分野として、扱われている [3], [4]。

認識技術の総称としての“**認識工学** (recognition engineering)”という名称を初めて提唱したのは、量子力学的原理 (principles of quantum mechanics) を多少意味を違えて、

2つのノルム規格化パターン間の内積の絶対値の自乗は、一方のパターンが

部分的に他方のパターンの状態にあることの確率である [15], [16]

という解釈が採用して得られた認識の**量子論** (a quantum theory of recognition) を構築したS.Suzukiである [1]。

### 1. 2 ヒトによるパターン認識方法とは？

表象機能とは、或るもの (指示対象) を或るもの (意味) として表す働きである [33]。

学習・記憶に関する簡単な**認知モデル**とは、刺激となるパターンが学習されると、それらに対応する**記憶表象** (memory-representation) が記憶系に保存されるというものである [32]。この記憶表象は或るカテゴリを代表するパターンであろうか？

ヒトは、パターン  $\phi$  に対する認識の働きを典型的なパターン (第  $j \in J$  番目の類概念としてカテ

ゴリ (category)  $\mathcal{C}_j$  の代表パターン (prototypical pattern)  $\omega_j$  との照合 (matching) を行って実行しているのだろうか?  $\varphi$  から抽出された特徴 (features extracted from pattern  $\varphi$ ) が  $\omega_j$  にあるかどうかを確かめながら、認識しているのだろうか? それとも、 $\omega_j$  の持つ特徴が  $\varphi$  にあるかどうかを確かめながら、認識しているのだろうか? その両方であろうか?  $\varphi$ ,  $\omega_j$  の代りに、各々、その対応するパターンモデル (a corresponding model of a pattern)  $T\varphi$ ,  $T\omega_j$  を使っているのだろうか? 単なるパターン照合ではなくて、 $T\varphi$ ,  $T\omega_j$  双方から抽出された特徴の組で照合することにより認識しているのだろうか?

$T\varphi$  から想起 (recall) されるパターンが  $T\omega_j$  に一致しているどうかで、 $\varphi$  を認識しているのだろうか?

モデル  $T\varphi$  を見たり聞いたりしたならば、原パターン  $\varphi$  と同じに見えたり、同じに聞こえたりすることだと解釈可能なモデル構成作用素  $T$  は少なくとも、axiom 1 [7] を満たすべきであると、S.Suzuki は主張している [2] ~ [4]。このような写像  $T$  の典型的なものは、本研究で学習で決定される各カテゴリ  $\mathcal{C}_j$  の代表パターン  $\omega_j$  の集まり  $\Omega$  を用いて構成される (文献 [4] の定理 A.1. 2, その系 1、定理 7. 3 を参照)。

S.Suzuki の “パターン認識の数学的理論, SS理論 [2], [3], [7]” を基盤として構成された認識システム **RECOGNITRON** では、モデル  $T\varphi$  を多段階的に次々と変形していったパターンモデル列を求めて行き (連想 (association) としての構造受精多段階帰納推理の働き)、 $T\varphi$  から連想されるこのパターン列内の各パターンモデルが  $T\omega_j$  に一致しているどうかで、処理の対象とする問題の原パターン  $\varphi$  が第  $j \in J$  番目のカテゴリ  $\mathcal{C}_j$  に帰属しているという具合に断定し、 $\varphi$  を認識する手法を採用している。。

以下では、 $\Phi$  を処理の対象とする問題のパターン  $\varphi$  の集合とする。 $\Phi$  は、内積、ノルムを各々、 $(\cdot, \cdot)$ ,  $\|\cdot\| \equiv \sqrt{(\cdot, \cdot)}$  とする或る可分な Hilbert 空間 [25]  $\mathfrak{H}$  の、零元 ( $=0$ ) を含む部分集合である。

### 1. 3 ニューラルネットが記憶している不動点は或るカテゴリの代表パターンではないのか?

ニューラルネット (neural network; 神経回路網) の “不動点 (fixed point) への変換” による認識 [2] とは次のように説明される:

各カテゴリ  $\mathcal{C}_j$  の代表パターン  $\omega_j$  のモデル  $T\omega_j$  を不動点 (平衡状態; equilibrium state) に持つニューラルネットを学習の働きで構成しておいて、処理の対象とするパターン  $\varphi \in \Phi$  を偽の吸引点 (spurious attractors) ではない不動点、例えば、 $T\omega_j$  に収束させて、

$$\varphi \text{ belong to the } j\text{-th category } \mathcal{C}_j \quad (1.1)$$

のごとく、認識する。 □

ニューラルネット [2] がその学習過程 (learning process) を介し、計算要素としての神経細胞、ニューロン (neuron) 間のそのシナプス荷重 (synaptic-connection weights) の組に記憶し間接的に獲得する不動点形吸引点 (attractors as fixed-points) は或るカテゴリの代表パターンに相当するだろう。

S.Suzuki は、各層内のニューロン (情報処理細胞) 同士には結合がなくて、前段の層のニューロンからその次の層のニューロンへの結合のみある前進形多層ニューラルネット (multi-layer feedforward network)、或いは、階層形ニューラルネット (hierarchical network) の逐次学習問題を適応誤差の確率分布を想定して、最尤法で一般的に取り扱い、これまでの標準的な “適応誤差の

確率分布を想定しない (distribution-free) 最小自乗学習法に基づく階層形ニューラルネット”の誤差逆伝播学習が、平均値ゼロ・等分散の正規分布を誤差の確率分布とする特別な場合であることを導いた [2]。

以下では、各カテゴリに代表パターンを設けるか、設けないうちに焦点を絞って、パターン認識の各手法を説明してみよう。

#### 1. 4 認識工学では通常、代表パターンの存在を仮定する

入力パターンと各カテゴリの代表パターンとの間の規格化ノルム距離の最小値、規格化内積相関の最大値を計算し、あるいは、入力パターンが与えられたときの各カテゴリの条件付事後生起確率の最大値を計算することによって、入力パターンの帰属するカテゴリを決定する3種類の認識機械 (recognition machine) などの構成技術を論じる認識工学 [1] では、各カテゴリに代表パターンを想定することがある。

パターン  $\varphi \in \Phi$  が与えられたときの、第  $i \in J$  番目のカテゴリ

$$\mathcal{C}_i \in \mathcal{C} \equiv \{\mathcal{C}_j \mid j \in J\} \quad (1.2)$$

の事後生起確率 (a posteriori conditional probability of occurrences of the  $i$ -th category  $\mathcal{C}_i$ , given pattern  $\varphi$ )

$$\text{prob}(\mathcal{C}_i / \varphi) \quad (1.3)$$

の、 $i$  についての最大値を与える最も若いカテゴリ番号  $j \in J$  を発見し、式 (1.1) の如く、パターン  $\varphi$  を識別する機能を持つ認識手法としての

(i) 最大事後確率分類器 (Bayesian classifier) は、各カテゴリ  $\mathcal{C}_i$  の備えている諸性質を典型的に代表する代表パターン

$$\omega_i \in \Omega \equiv \{\mathcal{C}_j \mid j \in J\} \quad (1.4)$$

を直接的には、必要としない。但し、例えば、次の例1. 1の如く、式 (1.3) の事後確率  $\text{prob}(\mathcal{C}_i / \varphi)$  を設定する場合は、代表パターン集合  $\Omega$  を直接的には、必要とする。

[例1. 1] (事後確率  $\text{prob}(\mathcal{C}_i / \varphi)$  の1構成例)

Gibbs distributionに似た形でも、事後確率  $\text{prob}(\mathcal{C}_i / \varphi)$  を構成できる。それを示そう。

次のaxiom 1 [3], [4], [7] を満たす写像

$$T: \Phi \rightarrow \Phi \quad (1.5)$$

を導入する。  $T\varphi \in \Phi$  をパターン  $\varphi \in \Phi$  に対応するモデルという。

**Axiom 1** (パターン集合  $\Phi$  とモデル構成作用素  $T$  との対  $[\Phi, T]$  の満たすべき公理)

(i) (零元の  $T$ -不動点性; fixed-point property of zero element under mapping  $T$ )  $0 \in \Phi \wedge T0 = 0$ .

(ii) (錐性, 正定数倍吸収性; cone property)

$$\forall \varphi \in \Phi, a \cdot \varphi \in \Phi \wedge T(a \cdot \varphi) = T\varphi$$

for any positive real number  $a$ .

(iii) (ベキ等性, 埋込性; idempotency, embeddedness)

$$\forall \varphi \in \Phi, T\varphi \in \Phi \wedge T(T\varphi) = T\varphi.$$

(iv) (写像  $T$  の非零写像性; non-zero mapping property of  $T$ )  $\exists \varphi \in \Phi, T\varphi \neq 0$ . □

上述のaxiom 1を発見し、パターンモデルという概念を初めて明らかにしたのは、S.Suzukiである [3], [6]。

任意の2パターン  $\varphi, \eta \in \Phi$  について、

$$\text{そのパターンモデル [3] } T\varphi, T\eta \text{ の内積 } (T\varphi, T\eta) \text{ が実数値である} \quad (1.5)$$

の場合を考えよう。

非一致条件

$$\forall j \in J, \forall i \in J - \{j\}, \|T\omega_j - T\omega_i\| > 0 \quad (1.6)$$

の下で、

$$\sigma_j(\varphi) \equiv \|T\omega_j\| \cdot \sqrt{1 - |\rho_j(\varphi)|^2} \quad (1.7)$$

$$\rho_j(\varphi) \equiv (T\varphi, T\omega_j) / [\|T\varphi\| \cdot \|T\omega_j\|] \quad (1.8)$$

として、

$$q_j(\varphi) \equiv [2\pi\sigma_j(\varphi)^2]^{-1/2} \cdot \exp[-\|(T\omega_j - \|T\omega_j\|) - \rho_j(\varphi) \cdot \{ \|T\omega_j\| / \|T\varphi\| \} \cdot (T\varphi - \|T\varphi\|) \|^2 / \{ 2\sigma_j(\varphi)^2 \}] \quad (1.9)$$

を導入し、この  $q_j(\varphi)$  を規格化して、Gibbs distribution に似た確率分布  $\text{prob}(\mathcal{C}_j/\varphi)$  を

$$\text{prob}(\mathcal{C}_j/\varphi) \equiv q_j(\varphi) / \sum_{i \in J} q_i(\varphi), \quad j \in J \quad (1.10)$$

と定義できる。

このとき、次の①～④の成立に注意しておく。

$$\textcircled{1} \forall j \in J, \rho_j(\omega_j) = 1 \wedge [\forall i \in J - \{j\}, 0 \leq \rho_j(\omega_i) < 1]$$

$$\textcircled{2} \forall j \in J, \sigma_j(\omega_j) = 0 \wedge [\forall i \in J - \{j\}, 0 < \sigma_j(\omega_i) \leq \|T\omega_j\|]$$

③任意の  $j \in J$  について、 $T\varphi \rightarrow T\omega_j$  のとき、

$$\rho_j(\varphi) \rightarrow 1 \quad \therefore \quad \sigma_j(\varphi) \rightarrow 0 \quad (1.11)$$

であり、よって、

$$q_j(\varphi) \rightarrow +\infty \quad (1.12)$$

④固定した  $j \in J$  に対し、任意の  $i \in J - \{j\}$  について、 $T\varphi \rightarrow T\omega_i$  のとき、

$$\begin{aligned} \exists a_j \in \mathbb{R} \text{ (実数全体の条件)} \quad (0 \leq a_j < 1), \\ \rho_j(\varphi) \rightarrow a_j \end{aligned} \quad (1.13)$$

であり、

$$\exists b_j \in \mathbb{R} (0 < b_j \leq \|T\omega_j\|), \quad \sigma_j(\varphi) \rightarrow b_j \quad (1.14)$$

であり、よって、

$$\exists c_j \in \mathbb{R} (0 < c_j < +\infty), \quad q_j(\varphi) \rightarrow c_j \quad (1.15)$$

が成立している。  $\square$

(ii) 木状類別器 (tree-classifier) を構成したパーセプトロン法 [2] による認識 [5]

実数値の重み  $w_k$  の組  $\{w_k\}_{k \in L}$  を、誤り訂正学習 [2] で決定しておいて、空間パーセプトロンによる類別法、つまり、

$$\sum_{k \in L} w_k \cdot [2 \cdot u(T\varphi, k) - 1] \geq 0 \text{ or } < 0 \quad (1.16)$$

かどうかで、2分割することを、必要な回数だけ繰り返して、パターン  $\varphi \in \Phi$  を認識する手法でも、代表パターン集合  $\Omega$  を直接的には、必要としない。

しかしながら、次の最小距離分類器、最小特徴間距離による認識法、最大相関分類器、最大類似度法、従来の  $n$  次元ユークリッド空間  $\mathbb{R}^n$  での連想形認識、不動点探索形構造受精多段階帰納推理の働きによる多段階パターン認識では、代表パターン集合  $\Omega$  が必ず、必要とされる。

(iii) 1つのカテゴリに複数の代表パターンを設ける最近傍分類器 (nearest neighbor classifier) の特別な場合としての、最小距離分類器 (minimum-distance classifier)

$\varphi$  と  $\omega_i$  との間の相違度 (difference) としての距離 (distance) を  $\text{dis}(\varphi, \omega_i)$  と表すと、

$j = \operatorname{argmin}_{i \in J} \operatorname{dis}(\varphi, \omega_i)$  ( $\operatorname{dis}(\varphi, \omega_i)$  の最小値を与える最も若いカテゴリ番号) (1.17)  
 を求め、式 (1.1) の如く、認識する手法である。

例えば、 $\operatorname{dis}(\varphi, \omega_i)$  を

$$\operatorname{dis}(\varphi, \omega_i) \equiv \|\varphi \cdot \|\varphi\|^{-1} - \omega_i \cdot \|\omega_i\|^{-1}\| \quad (1.18)$$

と設定できる。

(iv) 最小特徴間距離による認識法 (method of minimum feature-distance) [31]

パターン  $\varphi \in \Phi$  から抽出された第  $k \in L$  番目の複素数値特徴量を、

$$u(\varphi, k) \in Z \text{ (複素数の集合)} \quad (1.19)$$

と表す。

正・有限条件

$$[\forall k \in L, 0 < w_k \wedge \sum_{k \in L} w_k < \infty] \quad (1.20)$$

を満たす重み  $w_k$  の組  $\{w_k\}_{k \in L}$  を導入して、2つのパターン  $\varphi, \eta \in \Phi$  間の特徴間距離 (feature distance)

$$\begin{aligned} F\operatorname{dis}(\varphi, \eta) \\ \equiv [\sum_{k \in L} w_k \cdot |u(\varphi, k) - u(\eta, k)|^2]^{1/2} \end{aligned} \quad (1.21)$$

と、各カテゴリ  $\mathcal{C}_i$  の代表パターン  $\omega_i$  のモデル  $T\omega_i$  とを用意して、1つのカテゴリ番号

$$j = \operatorname{argmin}_{i \in J} F\operatorname{dis}(T\varphi, T\omega_i) \in J \quad (1.22)$$

を求め、式 (1.1) の如く、認識する手法である。

(v) 最大相関分類器 (maximum-correlation classifier)

$\varphi$  と  $\omega_i$  との間の類似度としての相関 (correlation) を  $\operatorname{cor}(\varphi, \omega_i)$  と表すと、

$$j = \operatorname{argmax}_{i \in J} \operatorname{cor}(\varphi, \omega_i) \text{ (}\operatorname{cor}(\varphi, \omega_i)\text{ の最大値を与える最も若いカテゴリ番号)} \quad (1.23)$$

を求め、式 (1.1) の如く、認識する手法である。

例えば、内積  $(\cdot, \cdot)$  を用意し、相関  $\operatorname{cor}(\varphi, \omega_i)$  を

$$\operatorname{cor}(\varphi, \omega_i) = (T\varphi \cdot \|T\varphi\|^{-1}, T\omega_i \cdot \|T\omega_i\|^{-1}) \quad (1.24)$$

と、設定できる。

(vi) 最大類似度法 (method of maximum-similarity) [31]

この認識法は最大事後確率分類器、最小距離分類器、最小特徴間距離による認識法、最大相関分類器の一般化である。

次の axiom 2 [3], [4], [7] を満たす類似度関数

$$SM: \Phi \times \Omega \rightarrow \{s \mid 0 \leq s \leq 1\} \quad (1.25)$$

を構成する。SM( $\varphi, \omega_i$ ) は式 (1.24) の相関  $\operatorname{cor}(\varphi, \omega_i)$  の一般化に相当する。

$\varphi$  と  $\omega_i$  との間の類似度 SM( $\varphi, \omega_i$ ) に注目し、

$$j = \operatorname{argmax}_{i \in J} SM(\varphi, \omega_i) \text{ (}\operatorname{SM}(\varphi, \omega_i)\text{ の最大値を与える最も若いカテゴリ番号)} \quad (1.26)$$

を求め、式 (1.1) の如く、認識する手法である。

**Axiom 2 (類似度関数 SM の満たすべき公理)**

(i) (直交性; orthogonality)

$$\forall i, \forall j \in J, SM(\omega_i, \omega_j) =$$

$$\begin{cases} 1 & \text{if } i=j \\ 0 & \text{if } i \neq j. \end{cases}$$

(ii) (規格化条件, 正規性; probability condition, normality)

$$\forall \varphi \in \Phi, \sum_{j \in J} SM(\varphi, \omega_j) = 1.$$

(iii) (写像 T の下での**不変性**; invariance under mapping T)

$$\forall \varphi \in \Phi, \forall j \in J, SM(T\varphi, \omega_j) = SM(\varphi, \omega_j). \quad \square$$

[例1. 2] (最小距離分類器の一般化)

例えば、簡単なものでは、 $\|\cdot\|$  をノルム記号として、

$$SM(\varphi, \omega_j) \equiv \|T\varphi - T\omega_j\|^{-2} / \sum_{i \in J} \|T\varphi - T\omega_i\|^{-2} \quad (1.27)$$

と定義される式 (1.25) の写像 SM は axiom 2 を満たし、この SM には、“類似度はノルム距離である相違性の反映物である” という好ましい性質

$$SM(\varphi, \omega_j) \geq SM(\varphi, \omega_i) \Leftrightarrow \|T\varphi - T\omega_j\| \leq \|T\varphi - T\omega_i\| \quad (1.28)$$

がある。

[例1. 3] (最小特徴間距離による認識法の一般化)

式 (1.21) で定義される特徴間距離  $F_{dis}(\varphi, \eta)$  を用いて、

$$SM(\varphi, \omega_j) \equiv F_{dis}(T\varphi, T\omega_j)^{-1} / \sum_{i \in J} F_{dis}(T\varphi, T\omega_i)^{-1} \quad (1.29)$$

と定義される式 (1.25) の写像 SM は axiom 2 を満たす。

[例1. 4] (最大事後確率分類器の一般化)

Gibbs distribution に似た形でも、類似度関数 SM を構成できる。それを示そう。

式 (1.10) の  $\text{prob}(\mathcal{C}_j/\varphi)$  を採用して、

$$SM(\varphi, \omega_j) \equiv \text{prob}(\mathcal{C}_j/\varphi) \equiv q_j(\varphi) / \sum_{k \in J} q_k(\varphi) \quad (1.30)$$

と定義される写像 SM は axiom 2 を満たすことが例1. 1の①~④よりわかる。

尚、式 (1.25) の類似度関数 SM を用いる最大類似度法は、以下の (イ)、(ロ) で指摘される**不変的認識**(invariant recognition) [6] の働きをもたらししている。

(イ) (モデル構成作用素 T の下での認識不変性)

axiom 2 の (iii) より、表現式 (1.1) が成り立てば、

$$T\varphi \text{ belongs to the } j\text{-th category } \mathcal{C}_j \quad (1.31)_i$$

が成り立つ。逆も成り立つ。また、

(ロ) (正の定数倍に関する認識不変性)

$$\forall \varphi \in \Phi, \forall i \in J, SM(a \cdot \varphi, \omega_i) = SM(\varphi, \omega_i) \text{ for any positive real number } a \quad (1.31)_o$$

$$\because SM(a \cdot \varphi, \omega_i)$$

$$= SM(T(a \cdot \varphi), \omega_i) \quad \because \text{axiom 2 の (iii)}$$

$$= SM(T\varphi, \omega_i) \quad \because \text{axiom 1 の (ii) の後半}$$

$$= SM(\varphi, \omega_i) \quad \because \text{axiom 1 の (iii)}$$

が成り立つことより、表現式 (1.1) が成り立てば、

$$a \cdot \varphi \text{ belongs to the } j\text{-th category } \mathcal{C}_j \quad (1.32)$$

が成り立つ。逆も成り立つ。  $\square$

(vii) 従来の d 次元ユークリッド空間  $R^d$  での連想形認識 (associative recognition) [13]

関連記憶行列 M を用いた記憶想起システムで説明するが、本手法の一般化 [2]~[4], [29] も論じられている。

さて、記憶した実数値パターン

$$\underline{x}_k = \text{col} (x_{1k} \ x_{2k} \ \cdots \ x_{dk}) \text{ (d次元列ベクトル)} \quad (1.33)$$

を N 個、並べて得られる  $d \times N$  形行列

$$M = (\underline{x}_1 \ \underline{x}_2 \ \cdots \ \underline{x}_N) \quad (1.34)$$

を考えよう。記憶したパターン $\underline{x}_k$  ( $k=1\sim N$ ) の内の1つの列ベクトルを一般のユークリッド列ベクトル実数値パターン

$$\underline{x} = \text{col}(x_1 \ x_2 \ \dots \ x_d) \in \mathbb{R}^d \text{ (d次元ユークリッド空間)} \quad (1.35)$$

から想起するように設計された**相関記憶行列** (autocorrelation matrix)  $M$  を用いた想起システムでは、1段階で想起されるパターン $\underline{y} \in \mathbb{R}^d$  は、

$$\underline{y} = M\underline{x} = \sum_{k=1}^N [\underline{x}, \underline{x}_k] \cdot \underline{x}_k \quad (1.36)$$

ここに、

$$[\underline{x}, \underline{x}_k] = \sum_{i=1}^d x_i \cdot x_{ik} \quad (1.37)$$

であるとされる。ここに、登場した  $[\ , \ ]$  はd次元ユークリッド空間  $\mathbb{R}^d$  での内積である。また、 $M$  の第  $i$  行第  $j$  列の要素  $M_{ij}$  は、

$$M_{ij} = \sum_{k=1}^N x_{ik} \cdot x_{jk} \quad (1.38)$$

である。**多段階想起** (multi-stage recall) では、

$$\underline{y}_0 \equiv \underline{x}, \quad \underline{y}_{t+1} = M\underline{y}_t \quad (t=0, 1, 2, \dots) \quad (1.39)$$

を求めて行って、第  $t$  段階で**不動点方程式** (fixed-point equation)

$$\underline{y}_t = M\underline{y}_t \quad (1.40)$$

が満たされるならば、この  $\underline{y}_t$  が最終的に想起される内容であるとする [26]。

その後、式 (1.40) の不動点パターン  $\underline{y}_t$  を何らかの認識手法で、例えば、(i) の最大事後確率分類器で認識して、

$$\underline{y}_t \text{ belong to the } j\text{-th category } \mathcal{C}_j \quad (1.41)$$

が得られたならば、式 (1.35) の入力パターン  $\underline{x}$  を

$$\underline{x} \text{ belong to the } j\text{-th category } \mathcal{C}_j \quad (1.42)$$

と、認識処理する手法である。

記憶系は学習すべき刺激パターンの記憶表象を形成・保存し、必要に応じて、**検索** (retrieval) ・想起するのみではなく、入力刺激パターン、学習された刺激パターン双方の表象同士の照合を行い、未学習の刺激パターンに対しても、学習された刺激パターンの表象との異同の判断を行うとすれば、本連想形認識の働きは正にこの種の記憶系によってなされていると言えよう。

(viii) 可分な一般抽象 Hilbert 空間  $\mathcal{H}$  での不動点探索形構造受精多段階帰納推理の働きによる多段階パターン認識 [3], [4], [7], [22]

任意のパターン認識手法より、認識率が下回らない認識手法が不動点探索形 (構造受精多段階帰納推論) 認識手法として、存在することが、文献 [3] の定理 6. 1 (**万能認識定理**) で証明されている本認識法は、木状分類器 (tree-classifier) を構成したパーセプトロン法 [2] による認識、IV の最大類似度法、従来の  $n$  次元ユークリッド空間  $\mathbb{R}^n$  での連想形認識法などに関する多段階精密化である。

認識システム内の3要素モデル構成作用素  $T$ 、類似度関数  $SM$ 、大分類関数  $BSC$  が十分、問題としている処理対象パターン集合  $\Phi$  に関し適切 [24] に選ばれていなければ、“**入力パターン  $\varphi \in \Phi$  がどの1つのカテゴリに帰属するかについてのカテゴリ帰属知識**” のあいまい性を正しく解消できない。任意の通常の認識法を1段階の認識過程で模擬できるが、このときの通常の認識法での正認識率を高めるには、多段階決定過程を導入することがその1つの解決法であることが、S.Suzuki の得た**万能認識定理**の証明内容などから、容易に理解できる。

各カテゴリ番号  $j \in J$  の集合  $J$  のすべての部分集合のなす集合を  $2^J$  と表そう。  $\mu \in 2^J$  を、パター



ン  $\varphi \in \Phi$  の帰属する可能性のあるカテゴリ番号のリストとして採用しながら、この  $\mu$  (候補カテゴリ番号リスト) を助変数に持つパターン変換作用素 (構造受精作用素)

$$A(\mu): \Phi \rightarrow \Phi \quad (1.43)$$

を用意し、パターンモデル  $T\varphi$  を、

$$TA(\mu) T\varphi = \eta \in \Phi \quad (1.44)$$

というように、パターンモデル  $T\eta$  へと変換することを考えよう。このとき、写像  $T$  のベキ等性を示す axiom 1 の (iii) より、不動点性

$$T\eta = \eta \in \Phi \quad (1.45)$$

が成立しており、この構造受精変換段階で得られた式 (1.45) のパターン  $\eta$  は写像  $T$  の不動点となっている。

認識処理の対象とする問題のパターン  $\varphi \in \Phi$  に対し、初期条件として、

$$\psi_s |_{s=0} = \varphi \quad (1.46)$$

を選び、カテゴリ番号リスト  $\mu_s \in 2^J$  を、多段階認識過程における各  $s$  段階でその都度、適切に選び、式 (1.44) に登場する構造受精変換 (structural-fertilization transformation)

$$TA(\mu_s) T: \Phi \rightarrow \Phi \quad (1.47)$$

を使って、多段階的に

$$\psi_{s+1} = TA(\mu_s) T\psi_s \in \Phi \quad (1.48)$$

と、構造受精多段階帰納推理の働きで何回か繰り返して行き、最終的に第  $t$  段階で不動点方程式

$$TA(\mu_t) T\psi_t = \psi_t \in \Phi \quad (1.49)$$

が成立したとき

$$\mu_t = [j] \in 2^J \quad (1.50)$$

が得られるように、再帰的に定義された連想形認識方程式 (equation of associative recognition) (文献 [3] の式 (G61) (SS方程式) を解き、パターンモデル  $\varphi \in \Phi$  の帰属する可能性のあるカテゴリの番号を唯1つに、例えば、第  $j \in J$  番目のカテゴリ  $\mathcal{C}_j$  に絞ることによって、入力パターン  $\varphi \in \Phi$  を、表現式 (1.1) のごとく、認識する手法が不動点探索形構造受精多段階帰納推理の働きを備えた認識システム RECOGNITRON による多段階パターン認識 (multi-stage inductive-inference recognition using structural-fertilization transformations of fixed-point searching type) である。

式 (1.4) の代表パターン集合  $\Omega$  の表象

$$T \cdot \Omega \equiv \{T\omega_j \mid j \in J\} \quad (1.51)$$

の何れかへと、刺激パターン  $\varphi$  の表象  $T\varphi$  が変換されるということが繰り返されると、このための変換  $TA(\mu_s) T$  の列が記憶系に保存されるであろう。“プロトタイプ+変換列”で指し示されるこの認知モデル (cognitive model) [32] を、不動点探索形構造受精多段階帰納推理の働きによる多段階パターン認識が提供していると言えそうである。変換数が大きくなればなるほど、刺激パターン  $\varphi$  が  $\Omega$  内の或る代表パターンから崩れており、認識しにくいとも主張できよう。また、刺激パターン  $\varphi$  についての変換列を  $\varphi$  と共に記憶していれば、 $\varphi$  と似ている刺激パターン  $\varphi'$  を認識することが  $\varphi$  についての変換列が hint になって  $\varphi'$  についての変換列が容易に得られるようになることが考えられる故に、by-pass 的になされるように事態も予想できよう。

式 (1.4) の代表パターン集合  $\Omega$  を必要とする本認識過程は、式 (1.47) の構造受精変換  $TA(\mu_s) T$  に含まれるモデル構成作用素  $T$ 、類似度関数  $SM$ 、大分類関数  $BSC$  を各段階で使い、入力パターン  $\varphi$  の帰属するカテゴリのリストを仮決定しながら、次の認識段階へと進むとき、このリ

ストを訂正できる機能がある“多段階不動点帰納法 (multistage fixed-point induction)”である。再帰的に定義された連想形認識方程式の最小不動点解 (least fixed-point solution) の分類が、

$$\text{認識処理可能, 認識処理不能, 認識処理不定} \quad (1.52)$$

という具合に、なされる (文献 [3] の定理 G14)。その求解過程を入力パターン  $\varphi$  の帰属するカテゴリ候補の絞り込み過程とみて、その簡単な2つの絞り込み方法 (線形、並びに、修正線形探索法) も論じられている (文献 [3] の G12.1 節)。

### 1.5 各代表パターン $\omega_j$ の、学習ベクトル量子化法による適応的決定

以上の説明からわかるように、最小距離分類器、最大相関分類器、不動点探索形構造受精多段階帰納推理の働きでパターン認識を行うシステム RECOGNITRON などでは、**典型としての代表パターンを中心とした緩やかなカテゴリ**を想定している。

このような緩やかなカテゴリを想定する認識手法では、各カテゴリの代表パターンを予め、決定しておく必要がある (認識工学における必要性)。

本研究では、9つの有声破裂音 /ba/, /be/, /bo/, /da/, /de/, /do/, /ga/, /ge/, /go/ を全カテゴリ集合とする場合を想定し、この場合の代表パターンの集合  $\Omega$  が、Kohonen などにより提唱されている**学習ベクトル量子化LVQ (Learning Vector Quantization)**を多少単純化して得られたアルゴリズムで決定されており (有効性)、このアルゴリズムで使われる減少関数  $\alpha(t)$  が新しく提案されている (新規性)。得られた結果は人の耳で聞く限り、大旨良好である (信頼性)。

## 第2章 第 $j \in J$ 番目のカテゴリ $\mathcal{C}_j$ の代表パターン $\omega_j$ の決定法

本章では、不動点探索形構造受精多段階帰納推理の働きでパターン認識を行うシステム RECOGNITRON [3], [4] で使用される代表パターンの集合  $\Omega$  を学習的に決定する手法が説明される。勿論、このような  $\Omega$  は最小距離分類器、最大相関分類器、最近近傍分類器 [3] などの認識システムにおいても必要とされる。

### 2.1 処理の対象とするパターン $\varphi$ の集合 $\Phi$

処理の対象とするパターン  $\varphi$  は可分な或る一般抽象 Hilbert 空間  $\mathcal{H}$  の元とする。 $\varphi$  の集合  $\Phi$  は  $\mathcal{H}$  の或る部分集合であって、一般に  $\Phi$  は  $\mathcal{H}$  の部分空間ではない。つまり、

一般に、 $\varphi, \eta \in \Phi$  であっても、 $a, b$  を任意の複素定数として、

$$\text{一般に、} a \cdot \varphi + b \cdot \eta \notin \Phi \text{ である} \quad (2.1)$$

とする (パターンの帰納的定義 [3] を参照)。ここに、 $\notin$  は not belong to の意である。

パターンの知覚情報処理は、 $\varphi \in \Phi$  に対応する知覚モデル  $T\varphi \in \Phi$  を形成することから始まる。

モデル形成過程

$$\varphi \in \Phi \rightarrow T\varphi \in \Phi \quad (2.2)$$

は、

①対象  $\varphi$  に存在する諸特徴が抽出され、独立に処理される**初期過程**

$$\varphi \in \Phi \rightarrow \underline{u}(\varphi) \equiv \{u(\ell, \varphi) \in Z \mid \ell \in L\} \in Z^{L+1} \quad (2.3)$$

②抽出されたそれらの諸特徴が統合されて1つの知覚モデル  $T\varphi$  が形成される**結合過程**

$$\underline{u}(\varphi) \in Z^{|L|} \rightarrow T\varphi \in \Phi \quad (2.4)$$

からなる。ここに、 $|L|$  は集合  $L$  に含まれる要素の総数 (cardinality) の意である。また、**特徴抽出写像**

$$u: \Phi \times L \rightarrow Z \text{ (複素数の集合)} \quad (2.5)$$

が導入して、パターン  $\varphi \in \Phi$  から抽出された第  $l \in L$  番目の特徴量を  $u(\varphi, l) \in Z$  と表現している。

**1次独立なパターン形状素の組** (a set of linearly independent primitive shape-components)

$$\psi \equiv \{\psi_l \in \mathfrak{H} \mid l \in Z\} \quad (2.6)$$

を導入して、1.4節の axiom 1 を満たすという意味で**モデル構成作用素** (model-construction operator) と呼ばれる写像  $T$  の構造形式を

$$T\varphi \equiv \sum_{l \in L} u(\varphi, l) \cdot \psi_l \text{ for any } \varphi \in \Phi \quad (2.7)$$

の如く、パターン  $\varphi \in \Phi$  から抽出された各特徴量  $u(\varphi, l) \in Z$  を係数に持つ各  $\psi_l \in \mathfrak{H}$  の1次結合として設定すると [1], [5] ~ [7]、"パターンから抽出された特徴がどのような方法で結合されるのか" という知覚における結合問題 [8] を式 (2.2) のモデル形成過程は、解決していることになる。

尚、意味を担う極小の言語要素を**形態素**と呼ぶが、式 (2.6) の各  $\psi_l$  は意味を担う極小のパターン要素である。

## 2.2 動作領域 $\Phi$ を決定する再帰領域方程式

処理の対象とする問題のパターン  $\varphi$  の集合 (認識システム RECOGNITRON の**動作領域**; operating region)  $\Phi$  について適切なモデル構成作用素 (model-construction operator)

$$T: \Phi \rightarrow \Phi \quad (2.8)$$

を選定する。 $\Phi, T$  からなる対  $[\Phi, T]$  は1.4節の axiom 1 を満たさなければならないこと [3] から、パターンであることが判明しているパターン集合

(**基本領域**; basic domain)  $\Phi_B$  を用意すると、 $\Phi$  は集合論的方程式

(**再帰領域方程式**; reflective domain equation)

$$\Phi = \Phi_B \cup T \cdot \Phi \cup R^{++} \cdot \Phi \quad (2.9)$$

where

$$T \cdot \Phi \equiv \{T\varphi \mid \varphi \in \Phi\} \quad (2.10)$$

$$R^{++} \cdot \Phi \equiv \{a\varphi \mid a \in R^{++} \text{ (正の実数全体の集合)}, \varphi \in \Phi\} \quad (2.11)$$

を満たさなければならない (パターンの帰納的定義)。文献 [3] の定理 2.1 (再帰領域定理) によれば、 $\Phi$  は**誘導領域** (derived domain) として

$$\Phi = R^{++} \cdot (\Phi_B \cup T \cdot \Phi_B) \quad (2.12)$$

と、決定される。式 (2.12) の決定された再帰領域方程式 (2.9) の解  $\Phi$  は、**構成的集合** (constructible set) であることを示しており、 $\Phi$  は原点 ( $= 0 \in \Phi_B$ ) を始点とし、 $\Phi_B \cup T \cdot \Phi_B$  の任意の点を通る任意の半直線を含むような集合 (**錐**; cone) であることを指摘していることに注意しておく。

## 2.3 教師あり学習法による代表パターン集合 $\Omega$ の決定

### 2.3.1 全カテゴリ集合 $\mathcal{C}$ を表現する全代表パターン集合 $\Omega$

正常なパターン  $\varphi$  はある1つのカテゴリ、例えば、第  $j \in J$  番目のカテゴリ  $\mathcal{C}_j$  のみを表現していな

ければならない。このような  $\mathcal{C}_j$  の集まり (全カテゴリ集合)

$$\mathcal{C} \equiv \{\mathcal{C}_j \mid j \in J\} \quad (2.13)$$

を想定し、 $\mathcal{C}_j$  の備えている諸性質を典型的に代表している代表パターン (prototypical pattern)  $\omega_j$  ( $\neq 0$ ) を1つ選定する。このような代表パターン  $\omega_j$  の、1次独立であらねばならない集合全 (全代表パターン集合)

$$\Omega \equiv \{\omega_j \mid j \in J\} \subset \Phi \subset \emptyset \quad (2.14)$$

を、教師あり学習で決定する手法について次項以降で説明しよう。以下の説明は文献 [3] の付録 I にある。

### 2.3.2 学習ベクトル量子化 LVQ と訓練パターン集合の選定

再帰領域方程式 (2.9) の、解表現式 (2.12) の  $\Phi$  内の基本領域  $\Phi_B$  の内から第  $j \in J$  番目のカテゴリ  $\mathcal{C}_j$  に帰属していることが判明している1つのパターン  $\varphi_i$  を選び、天下りの的に、

$$\omega_j = \varphi_i \in \Phi_B \quad (2.15)$$

とすることができる。しかしながら、本節では、通常認識法などが性能の高いものになると期待される適応的決定手法を説明しよう。この手法は、Kohonenにより提唱されている学習ベクトル量子化 LVQ (Learning Vector Quantization) [9] を多少簡単化したものである。

十分長時間では、確率条件

$$[\forall j \in J, 0 < p(\mathcal{C}_j) < 1] \wedge \sum_{j \in J} p(\mathcal{C}_j) = 1 \quad (2.16)$$

での、第  $j \in J$  番目のカテゴリ  $\mathcal{C}_j$  の生起確率  $p(\mathcal{C}_j)$  に比例した出現回数 の形で、各  $\mathcal{C}_j$  に帰属していることが判明しているパターン  $\varphi_i \in \Phi$  が、訓練パターン系列

$$\varphi_0, \varphi_1, \varphi_2, \dots, \varphi_t, \dots \quad (2.17)$$

において表れるものとする。その帰属しているカテゴリが判明してい各時刻  $t$  での訓練パターン  $\varphi_i \in \Phi$  を使っていることが、次項の学習法を教師あり (supervised) にしている。

### 2.3.3 適応アルゴリズム

初期値

$$\omega_{j,t} \mid_{t=0}, j \in J \quad (2.18)$$

を適切に選定し、

$$\omega_{j,t+1} = \omega_{j,t} + \Delta \omega_{j,t} \quad (2.19)$$

という形式で、時刻  $t$  での  $\omega_{j,t}$  を  $\omega_{j,t+1}$  へと更新していくものとする。条件

$$0 \leq \alpha(t) < 1 \quad (2.20)$$

を満たす、 $t$  の非増加関数  $\alpha(t)$  を選定し、

$$\Delta \omega_{j,t} = \alpha(t) \cdot [\varphi_i - \omega_{j,t}] \quad (2.21)$$

とすれば、

$$\varphi_i - \omega_{j,t+1} = [\varphi_i - \omega_{j,t}] \cdot [1 - \alpha(t)] \quad (2.22)$$

であるから、不等式

$$|\varphi_i - \omega_{j,t+1}| \leq |\varphi_i - \omega_{j,t}| \quad (2.23)$$

を得て、

カテゴリ  $\mathcal{C}_j$  に帰属する時刻  $t$  での訓練パターン  $\varphi_i$  に近づく方向に  $\omega_{j,t}$  を  $\omega_{j,t+1}$  へと更新している (訓練パターン系列への適応性) ことがわかる。

### 2.3.4 本計算機シミュレーションで採用した減少関数 $\alpha(t)$

1より小の非負の、式 (2.21) に登場する減少関数  $\alpha(t)$  として、ガウス形関数を選定しても良い

が、訓練期間

$$0, 1, 2, \dots, t_{\max} \quad (2.24)$$

では、次の式 (2.25) のように選ぶと都合が良いことを計算機シミュレーションで発見している：

$$\alpha(t) = \begin{cases} a_1 \cdot [1 - a_2 \cdot t / (t_{\max} + b)] / [c + |J|] & \text{if } t \leq t_{\max} \\ 0 & \text{if } t > t_{\max}. \end{cases} \quad (2.25)$$

□

ここに、4定数  $a_1, a_2, b, c$  は、不等式

$$\begin{aligned} 0 \leq a_2 \cdot t / (t_{\max} + b) \leq 1 & \quad \wedge \\ 0 \leq a_1 / [c + |J|] < 1 & \end{aligned} \quad (2.26)$$

を満たしていれば良い。

### 2.3.5 減少関数 $\alpha(t)$ を変更して行く再帰的学習方式

パターン  $\varphi \in \Phi$  を識別する最小特徴間距離認識法とは、

「パターン  $\varphi$  から抽出される式 (2.3) の第  $k \in L$  番目の特徴量  $u(\varphi, k)$  を導入して、  
 $\varphi$  belongs to the  $j$ -th category  $\mathcal{C}_j$  such that

$$\min_{i \in J} \text{dis}(\varphi, \omega_i) = \text{dis}(\varphi, \omega_j) \quad (2.27)$$

where

$$\text{dis}(\varphi, \omega_i) \equiv \sum_{k \in L} w_k \cdot |u(\varphi, k) - u(\omega_i, k)| \quad (\text{feature-distance between } \varphi \text{ and } \omega_i) \quad (2.28)$$

$$\wedge [\forall k \in L, 0 < w_k < 1] \wedge \sum_{k \in L} w_k = 1 \quad (2.29)$$

と、説明される (1.4節の(iv)を参照)。

式 (2.27) に示される最小特徴間距離認識法によって、式 (2.17) での、時刻  $t$  での訓練パターン  $\varphi_t$  を認識して、時刻  $t$  の関数  $s(t)$  を、

$$s(t) = \begin{cases} +1 & \text{if the classification of } \varphi_t \text{ is correct} \\ -1 & \text{if the classification of } \varphi_t \text{ is incorrect} \end{cases} \quad (2.30)$$

と設定し、

$$\alpha(t) = \alpha(t-1) / [1 + s(t) \cdot \alpha(t-1)] \quad (2.31)$$

という形で、 $\alpha(t)$  を変更して行く再帰的学習方式も提案されている [10]。

## 第3章 計算機シミュレーション

式 (2.13) の全カテゴリ集合  $\mathcal{C}$  として9個の有音破裂音を採用した場合の、2.3.3項で説明された適応アルゴリズムが、personal computer Macintosh IIcx上の言語Cでかかれたプログラムで実施されたが、本章では、その計算機シミュレーション内容が簡単に説明される。

### 3.1 音声データの収集と番号付け

音声波形は、時間の関数であり、音素と共に変化している。調音位置によって日本語子音を分

類すれば、唇音、歯音・歯茎音、口蓋音、声門音ということになる。破裂音、破擦音、摩擦音、弾音、鼻音、半母音という調音様式の差による分類もある。

微視的には、母音や摩擦音は殆ど一定の波形（定常的な波形）の繰り返しである。破裂音は閉鎖、破裂、摩擦の連続した波形である。音声全体は、非定常な信号であり、短時間的には、定常信号である。

無声破裂音には、/p/（唇音）、/t/（歯音・歯茎音）、/k/（口蓋音）があり、有音破裂音には、/b/（唇音）、/d/（歯音・歯茎音）、/g/（口蓋音）がある。

有声音とは発声の時に声帯の振動を伴うものである。

有声破裂音

$$/ba/, /be/, /bo/, /da/, /de/, /do/, /ga/, /ge/, /go/ \quad (3.1)$$

の大学生男5人，大学生女4人の計9人分の，81個の音声波形からなる音声データ

$$\varphi_1, \varphi_2, \dots, \varphi_{81} \quad (3.2)$$

をテープレコーダに採集し、フロッピイディスクに

符号なし8ビットで表現したキャラクタ表示から

$$128を差し引いた値-128\sim+127の振幅 \quad (3.3)$$

を記録した。1番目の学生の音声波形は、

$$\begin{aligned} \varphi_1 [ /ba/ ], \varphi_2 [ /be/ ], \varphi_3 [ /bo/ ], \varphi_4 [ /da/ ], \\ \varphi_5 [ /de/ ], \varphi_6 [ /do/ ], \varphi_7 [ /ga/ ], \varphi_8 [ /ge/ ], \\ \varphi_9 [ /go/ ] \end{aligned} \quad (3.4)$$

である。以下、この順に2, 3, ..., 9人目の音声データが

$$\varphi_{10}, \varphi_{11}, \dots, \varphi_{81} \quad (3.5)$$

の如く番号付けられている。

式 (2.17) の訓練パターン系列内の相異なるパターンの総数 (a number of training patterns) は、81である。

各パターン  $\varphi_n$  ( $n=1\sim 81$ ) を、内積  $(\varphi, \eta)$ 、ノルム  $\|\varphi\|$  を各々、

$$(\varphi, \eta) = \int_{-\infty}^{+\infty} dx \varphi(x) \cdot \overline{\eta}(x) \quad (3.6)$$

$$\|\varphi\| \equiv \sqrt{(\varphi, \varphi)} \quad (3.7)$$

とする可分なHilbert空間  $\Phi = L_2(-\infty, +\infty)$  の元と見做し、2.2項の基本領域  $\Phi_B$  として、

$$\Phi_B \equiv \{ \varphi_1, \varphi_2, \dots, \varphi_{81} \} \quad (3.8)$$

が選ばれた。

### 3.2 カテゴリの番号付けと、訓練パターン系列の設定

式 (3.1) の有声破裂音をこの順に

$$\mathcal{C}_1, \mathcal{C}_2, \mathcal{C}_3, \mathcal{C}_4, \mathcal{C}_5, \mathcal{C}_6, \mathcal{C}_7, \mathcal{C}_8, \mathcal{C}_9 \quad (3.9)$$

と、カテゴリ付けた。

式 (2.13) の全カテゴリ集合  $\mathcal{C}$  での全カテゴリ番号集合  $J$  については

$$J = \{ 1, 2, \dots, 9 \} \quad (3.10)$$

$$J\text{SIZE} = |J| = 9 \text{ (total number of categories)} \quad (3.11)$$

ということになる。第  $j \in J$  番目のカテゴリ  $\mathcal{C}_j$  の、式 (2.16) を満たす生起確率  $p(\mathcal{C}_j)$  は、

$$p(\mathcal{C}_j) = |J|^{-1} \text{ (the probability of occurrence of the } j\text{-th category } \mathcal{C}_j) \quad (3.12)$$

と設定する。

式 (2.17) の訓練パターン系列の  $\varphi_t \in \Phi$  ( $t=1, 2, \dots, 810$ ) を、

$$\varphi_t = \varphi_n \quad (3.13)$$

ここに、

$$t = n + k \cdot 81 \quad (n=1 \sim 81; k=0, 1, 2, \dots, 8) \quad (3.14)$$

と設定した。

### 3.3 計算機シミュレーションの諸条件

標本化周波数 (sampling frequency)  $W_0$  として、

$$W_0 = 5500 [\text{HZ}] \quad (3.15)$$

を採用した。Shannonの標本化定理により、標本化間隔  $\Delta x$  は、

$$\Delta x = (2W_0)^{-1} [\text{sec}] = 0.0909 [\text{msec}] \quad (3.16)$$

ということになる。

式 (2.17) の訓練パターン系列の第  $t$  ( $=1, 2, \dots, 810$ ) 番目の音声波形  $\varphi_t \in \Phi$  は、

$$\varphi_t(x) \equiv \varphi_t[q] \equiv \varphi_t(q \cdot \Delta x) \quad (3.17)$$

$$\text{ここに、 } x = q \cdot \Delta x \quad (3.18)$$

$$q = 0, 1, 2, \dots, \text{TSIZE} - 1 \quad (3.19)$$

$$\text{TSIZE} = 2048 \quad (\text{maximum of quantized times}) \quad (3.20)$$

と表され、

$$\text{TSIZE} \times \Delta x = 186.1818 [\text{msec}] \quad (3.21)$$

がその継続時間である。

式 (3.6) の内積  $(\varphi, \eta)$  の近似式として、

$$(\varphi, \eta) \doteq \sum_{q=0}^{\text{TSIZE}-1} \Delta x \cdot \varphi(q \cdot \Delta x) \cdot \overline{\eta}(q \cdot \Delta x) \quad (3.22)$$

が採用された。

式 (2.18) の初期値として、

$$\omega_{j,t}(x) |_{t=0} = \varphi_0(x) \quad (3.23)$$

ここに、

$$\varphi_0(x) \equiv \sum_{j=1}^9 |J|^{-1} \cdot \varphi_j(x) \cdot \|\varphi_j\|^{-1} \quad (3.24)$$

が採用された。

式 (2.25) 内の助変数  $a_1, a_2, b, t_{\max}, c, |J|$  を

$$\begin{aligned} a_1 = 1.0, a_2 = 1.0, b = 1.0, t_{\max} = 810, c = 0.0, \\ |J| = 9 \end{aligned} \quad (3.25)$$

と選定した。

### 3.4 シミュレーション結果

#### 3.4.1 適応アルゴリズムの収束判定

$$\sum_{j=1}^9 \|\omega_{j,t+1} - \omega_{j,t}\| < 0.015 \quad (3.26)$$

が満足されたとき、2.3.3項の適応アルゴリズムを終了させた。この適応アルゴリズムにおいて、1単位時間進むのに、つまり、 $t \rightarrow t+1$  のとき、約30秒必要とし、

$$810 \times 30 \doteq 24300 \text{秒、つまり、約6.75時間} \quad (3.27)$$

の適応時間を必要とした。

その結果、1次独立であらねばならない式 (2.14) の全代表パターン集合  $\Omega$  が得られたが、このとき、

$$\|\xi\| = 0.953 \quad (3.28)$$

$$\|\omega_j\| = 10.96 \sim 12.4 \quad (j=1 \sim 9) \quad (3.29)$$

ここに、

$$\xi \equiv \sum_{j=1}^9 p(\mathcal{C}_j)^{-1} \cdot \omega_j(x) \cdot \|\omega_j\|^{-1} \quad (3.30)$$

であり、

$t = t_{\max} = 810$  のとき、

$$\sum_{j=1}^9 \|\omega_{j,t+1} - \omega_{j,t}\| = 0.01420838 \quad (3.31)$$

であった。

### 3.4.2 スピーカに入力するための音声波形の変換と、受聴結果

本計算機シミュレーションでは、音声波形  $\varphi = \varphi(x)$  は、

$$\varphi(x) \equiv \varphi(q \cdot \Delta x), q=0 \sim \text{TSIZE} - 1 \quad (3.32)$$

と表され、これを便宜的に、

$$\varphi[q] \equiv \varphi(q \cdot \Delta x), q=0 \sim \text{TSIZE} - 1 \quad (3.33)$$

と表すことにする。

音声波形  $\varphi[q]$  に対し、

① 振幅最大値による規格化

$$\varphi^{\wedge}[q] = \begin{cases} 0 & \cdots \max_q |\varphi[q]| = 0 \text{ のとき} \\ \varphi[q] / \max_q |\varphi[q]| & \cdots \max_q |\varphi[q]| > 0 \text{ のとき} \end{cases} \quad (3.35)$$

② 振幅の1次変換

$$\varphi^{\sim}[q] \equiv a \cdot \varphi^{\wedge}[q] + 128, a = 2^7 - 1 = 127 \quad (3.36)$$

を定義し、

$$\varphi[q] \rightarrow \varphi^{\wedge}[q] \rightarrow \varphi^{\sim}[q] \quad (3.37)$$

と変換し、最終的に得られた音声波形

$$\varphi^{\sim}[q] (= \omega_j^{\sim}[q], j=1 \sim 9) \quad (3.38)$$

を Macintosh II<sub>CX</sub> の SoundEdit™ を使って、スピーカに入力し、再生すると、次の3受聴結果が得られた：

1° /ga/ は /da/ に人の耳では聞こえる。

2° /go/ は /bo/ に人の耳では聞こえる。

その他の

3° /ba/, /be/, /bo/, /da/, /de/, do/, /ge/

は正常にほぼ、聞こえる。 □



## 第4章 むすび

知識や信念は言語表象無しに表すことが難しい [33] ことは容易に理解できるかもしれない。意味は表象で代用できることを考えると、都合がよいからである。パターンは変形に耐え、冗長性ある表現なので、似たパターンの集まりを1つの表象 (代表パターン) で代表すること (認識の働きにおける抽象化 [4]) は素直なことである。

認知科学的には、パターン認識を行うにあたって人は各カテゴリにつき、その代表パターン (標準パターン) をどのように用いているかについては明確な定説がないが [27], [28]、最小距離分類器、最大相関分類器、最近近傍分類器 [3], 不動点探索形構造受精多段階帰納推理の働きでパターン認識を行うシステム RECOGNITRON [3], [4] などのにおいて必要とされる代表パターンの式 (2.14) の集合  $\Omega$  をその所属しているカテゴリ名が判明しているという意味で教師ありと称される学習で決定する手法が、Kohonenの学習ベクトル量子化法を多少単純化して得られることを示し、式 (3.1) の有声破裂音が全カテゴリ集合  $\Omega$  である場合、その実施した計算機シミュレーションの概要が説明された。

式 (2.21) で使用されており、1より小の非負の、式 (2.25) の減少関数  $\alpha(t)$  は計算シミュレーションを反復し、試行錯誤的にS.Suzukiにより発見されたものである。

学習的に教師ありで得られた代表パターンの集合  $\Omega$  を各種認識法に用いることによって各認識性能がどの程度、改良されるかは明らかでない。唯、得られた  $\Omega$  は、式 (2.17) の訓練パターン系列に適應しているので、少なくとも訓練パターン系列内の各パターンに関しては認識の働きが改良されていることは明らかである。

得られた結果は人の耳で聞く限り、大旨良好であるが、この  $\Omega$  を用いて実際に構成された認識システムで式 (2.17) の訓練パターン系列に含まれていないパターンを認識して見て、その学習効果が判明する。しかしながら、この確認は将来の研究として、残されている。

式 (2.30) の再帰式によって  $\Omega$  を決定し、本計算機シミュレーション結果と比較することが残された研究である。

## 文 献

- [1] 鈴木昇一：“認識工学 (上)”，柏書房，Feb.1975
- [2] 鈴木昇一：“(マルチメディア情報処理のための一般化誤差逆伝播学習) ニューラルネットの新数理”，近代文芸社，Sept.1996
- [3] 鈴木昇一：“(知能情報メディア情報処理のためのカテゴリ帰属知識を用いた) パターン認識問題の数理的一般解決”，近代文芸社，June 1997
- [4] 鈴木昇一：“(カテゴリ帰属知識のポテンシャル論を含む) 認識知能情報論の新展開”，近代文芸社，Aug.1998
- [5] 鈴木昇一：“抽出された特徴による手書き漢字構造の再生”，情報処理学会誌，vol.18, no.11, pp.1115-1122, Nov.1977
- [6] 鈴木昇一：“パターンのエントロピーモデル”，電子情報通信学会論文誌 (D-II)，vol.J77-D-II, no.10, pp.2220-2238, Nov.1994

- [7] 鈴木昇一：“パターン認識の数学的理論”，電子情報通信学会技術研究報告 [パターン認識と学習，パターン認識と理解]，PRL84-6 (第1部)，PRL84-30, PRL84-38, PRL85-27, PRU86-8, PRU86-35, PRU86-69, PRU87-1, PRU87-28, PRU88-30, PRU89-1, PRU89-27, PRU89-40, PRU89-66, PRU89-77, PRU89-136, PRU90-5, PRU90-15, PRU90-29, PRU90-125, PRU91-1, PRU91-29, PRU91-42, PRU92-1, PRU92-18, PRU92-25, PRU92-89, PRU92-102 (第28部)，May 1984～Jan.1993
- [8] 下村満子，横沢一彦：“高速提示された刺激の時間的結合錯誤——ターゲットの複雑性操作による効果——”，The Japanese Journal of Psychology, vol.68, no.6, pp.449-456, 1998
- [9] Eric Chen-Juo Tsao, James C.Bezdek and Nikhil R.Pal：“Fuzzy Kohonen clustering networks”，Pattern Recognition, vol.27, no.5, pp.757-764, 1994
- [10] Seong-Whan Lee and Hee-Heon Song：“Optimal design of reference models for large-set handwritten character recognition”，Pattern Recognition, vol.27, no.9, pp.1267-1274, 1994
- [11] 斎藤収三，中田和男：“音声情報処理の基礎”，オーム社，Nov.1981
- [12] Luc Devroye, László Györfi and Gábor Lugosi：“A probabilistic theory of pattern recognition”，Springer-Verlag New York, Inc., 1996
- [13] T.Kohonen：“Content-addressable memories”，Springer-Verlag Berlin Heidelberg New York, 1980
- [14] 長尾真：“パターン情報処理 (電子通信学会大学シリーズ I-4)”，コロナ社，Mar.1983
- [15] 鈴木昇一，奥野治雄：“パターン認識系の特徴抽出構造に関する解析”，電子通信学会インホームーション理論研究会，IT68-9, May 1968
- [16] 鈴木昇一：“測度的不変量検出形認識系の構成理論”，電子通信学会論文誌 (D)，vol.55-D, no.8, pp.513-538, Aug.1972
- [17] 鈴木昇一：“手書き漢字の側抑制効果的分解とその計算機シミュレーション”，情報処理学会誌，vol.15, no.12, pp.927-934, Dec.1974
- [18] 鈴木昇一：“画像情報量とその手書き漢字への応用”，画像電子学会誌，vol.4, no.1, pp.4-12, Apr.1975
- [19] 鈴木昇一，佐久間拓也，前田英明：“数理形態学における諸演算とモデル構成作用素”，情報研究 (文教大学・情報学部)，vol.17, pp.133-170, Dec.1996
- [20] 鈴木昇一：“Radial-basis function networks, wavelet-based networksを用いたモデル構成作用素の構成法”，情報研究 (文教大学・情報学部)，vol.17, pp.71-131, Dec.1996
- [21] 鈴木昇一，佐久間拓也，釈氏孝浩，前田英明，下平丕作士：“不動点探索形構造受精変換多段階認識の、確率過程論的取り扱い”，情報研究 (文教大学・情報学部)，vol.18, pp.53-103, Dec.1997
- [22] 鈴木昇一：“構造受精法と日本語単独母音の認識”，情報研究 (文教大学・情報学部)，vol.18, pp.17-51, Dec.1997
- [23] 鈴木昇一：“高次認知機能における論理表現の要素”，情報研究 (文教大学・情報学部)，vol.1, pp.29-82, Mar.1998
- [24] 鈴木昇一：“類似度関数の選定に関する適切さの検証法”，情報研究 (文教大学・情報学部)，vol.1, pp.83-119, Mar.1998
- [25] 青木利夫，高橋渉：“集合・位相空間要論”，培風館，Sept.1979
- [26] 今田俊明，曾根悟，宇都宮敏男：“収束想起方式の連想記憶について”，信学論 (D)，vol.J60-D, no.3, pp.224-231, Mar.1977

- [27] 古橋啓介：“幾何図形を用いた再認課題における典型の形成”，心理学研究，vol.52, no.6, pp.358-361, Feb.1982
- [28] 石毛明子, 箱田裕司：“カテゴリ群化における典型性効果”，心理学研究，vol.55, no.4, pp.221-227, Apr.1984
- [29] 鈴木昇一：“連想形記憶器 MEMOTRON と日本語母音系列の再生に関する計算機シミュレーション”，情報研究（文教大学情報学部），vol.7, p.p.14-29, Dec.1986
- [30] 鈴木昇一：“多変量解析に基づく大分類関数の決定とその計算機シミュレーション”，情報研究（文教大学・情報学部），vol.10, p.p.35-49, Dec.1989
- [31] 鈴木昇一：“帰属係数法に基づく類似度、帰属関係あいまい度、認識情報量の計算機シミュレーション”，情報研究（文教大学・情報学部），vol.11, p.p.51-68, Dec.1990
- [32] 須藤昇：“学習・再認に関する記憶表象生成モデルの実験的検証”，The Japanese Journal of Psychology, vol.65, no.3, pp.206-214, 1994
- [33] 子安増生, 木下孝司：“〈心の理論〉研究の展望”，The Japanese Journal of Psychology, vol.68, no.1, pp.51-67, 1997

（鈴木昇一・前田英明, 文教大学・情報学部・情報システム学科, “文教大学・情報学部・情報研究 no.20” 投稿論文, 論文題目有声破裂音の代表パターンの学習的決定と、その計算機シミュレーション, 投稿年月日 1998年9月2日（水））