

# 内挿ベクトルを用いる強力なパターン認識法

福島 邦彦<sup>†</sup> 林 勲<sup>†</sup>

<sup>†</sup> 関西大学 総合情報学部

〒 569-1095 大阪府高槻市霊仙寺町 2-1-1

E-mail: [†fukushima@m.ieice.org](mailto:†fukushima@m.ieice.org), [†ihaya@kcn.res.kutc.kansai-u.ac.jp](mailto:†ihaya@kcn.res.kutc.kansai-u.ac.jp)

**あらまし** “内挿ベクトル (interpolating vectors)” を用いる強力なパターン認識アルゴリズムを提唱する。まず、一種の競合学習によって、多次元特徴空間内にラベル付きの参照ベクトルを作成する。次に、同一ラベルを持つ参照ベクトルのあらゆる<sup>ついで</sup>対を考え、それらの対を結ぶ線分上に内挿ベクトルが密に並んでいる状態を想定する。これらの内挿ベクトルの中で、テストベクトルとの類似度が最大のものを選び、そのラベルを認識結果とする。実際にはもっと簡単な操作で、これと等価な結果を得ることが出来る。手書き数字認識を行なうネオコグニトロン<sup>†</sup>の最上位層に本方式を適用した結果、学習に 5000 パターンを用いた場合、未知の 5000 パターンに対する誤認識率が 1.52% から 1.02% に減少した。本方式はネオコグニトロンに限らず、種々のパターン認識システムに使用可能である。

**キーワード** パターン認識, 内挿ベクトル, ラベル付き競合学習, ネオコグニトロン

## Interpolating Vectors for Robust Pattern Recognition

Kunihiko FUKUSHIMA<sup>†</sup> and Isao HAYASHI<sup>†</sup>

<sup>†</sup> Faculty of Informatics, Kansai University

2-1-1 Ryozenji, Takatsuki, Osaka 569-1095

E-mail: [†fukushima@m.ieice.org](mailto:†fukushima@m.ieice.org), [†ihaya@kcn.res.kutc.kansai-u.ac.jp](mailto:†ihaya@kcn.res.kutc.kansai-u.ac.jp)

**Abstract** This paper proposes a powerful algorithm for pattern recognition, which uses *interpolating vectors* for classifying patterns. The basic idea of the algorithm is as follows. Labeled reference vectors in a multi-dimensional feature space are first produced by a kind of competitive learning. We then assume a situation where interpolating vectors are densely placed along line segments connecting all pairs of reference vectors of the same label. From these interpolating vectors, we choose the one that has the largest similarity to the test vector. The label of the chosen vector is taken as the result of pattern recognition. In practice, we can get the same result with a simpler process. We applied this method to the *neocognitron* for handwritten digit recognition and reduced the error rate from 1.52% to 1.02% for a blind test set of 5000 digits. The use of interpolating vectors is not limited to the *neocognitron* but can be applied to various systems for pattern recognition.

**Key words** pattern recognition, interpolating vector, labeled competitive learning, *neocognitron*

### 1. はじめに

“内挿ベクトル (interpolating vectors)” を用いる強力なパターン認識アルゴリズムを提唱する。内挿ベクトルを用いることによって、多次元特徴空間内でのパターン識別能力を大幅に向上させることが出来る。

特徴ベクトルの識別に関してはこれまでに種々の方法が提唱されている [1]~[5]。これらの多くは、まず学習ベクトルからラベル付きの参照ベクトル (コードベクトル) を作成し、テストベクトル (入力パターン) と参照ベクトルとの間のある種の類似度にもとづいて、入力パターンを識別しようとしており、ラ

ベル付きの参照ベクトルの生成法や、最大の類似度を持つ参照ベクトルの探索法などに関して、種々の方法が試みられている。

ここで提唱する方式では、まず、一種の競合学習によってラベル付きの参照ベクトルを生成する。しかし従来の方式とは異なり、テストベクトルとの類似度が最も大きい参照ベクトルを単純に選ぶのではない。同一ラベルを持つ参照ベクトルのあらゆる<sup>ついで</sup>対を考え、それらの対を結ぶ線分上に“内挿ベクトル”と名付けた仮想的なベクトルが密に並んでいる状態を想定する。これらの内挿ベクトルの中で、テストベクトルとの間の類似度が最大のものを選ぶ。選ばれた内挿ベクトルのラベル (クラス名) を認識結果とする。

実際には、無限個の内挿ベクトルを作る必要はない。同一レベルの参照ベクトルを結ぶ線分を、あらゆる対に対して作成する。線分には、その両端の参照ベクトルと同じラベルを付ける。テストベクトルとの間の距離（類似度の基づく距離）を測り、最も近い線分を選び、その線分のラベルを認識結果とする。

多次元特徴空間内で、もしクラス間の境界の一部が凹型であると、線分の中には、凹型の境界を通り越して、別のクラスの領域を侵略するものが出てくる可能性がある。そのような線分を探し出して除去するために、参照ベクトルを作成した後に、調整プロセスを行なう。調整プロセスでは、参照ベクトル形成に用いたと同じ学習ベクトルが、どのように分類されるかを調べる。もし学習ベクトルが誤って認識された場合には、この学習ベクトルに対して誤認識を引き起こす線分をすべて除去する。そのような線分は、クラスの境界を横切っている疑いが濃いからである。

本方式の能力を実証するために、ネオコグニトロンに適用する。ちなみにネオコグニトロンは、変形に強いパターン認識能力を持つ神経回路モデルで、以前筆者が提唱した [6]~[8]。

ネオコグニトロンの場合は、最上位段の S 細胞の入力結合は一種の競合学習によって作られるのであるが、これらの個々の S 細胞の入力結合が参照ベクトルに対応することになる。学習を終わったネオコグニトロンの最上位段の S 細胞の反応は、多次元特徴空間内で、テストベクトル（認識すべき入力パターン）と参照ベクトルとの類似度を表わしていると解釈できる。

通常のコグニトロンでは、最大出力を出した S 細胞のラベル、すなわちテストベクトルとの類似度が最大の参照ベクトルのラベルを、認識結果とする。これに対して本方式では、S 細胞の反応を内挿ベクトルを用いて分析することによって誤認識率を大幅に減少するのである。

以下、2. 節で、まずネオコグニトロンの概要を説明する。3. 節で、内挿ベクトル法の考え方を、パターン認識全般に関して論じる。次に 4. 節で、ネオコグニトロンの最上位段の反応を、内挿ベクトル法をどのように用いて分析するかを論じる。最後に 5. 節で、手書き数字に対するネオコグニトロンの認識率が、内挿ベクトル法によって大幅に向上することを、計算機シミュレーションによって実証する。

## 2. ネオコグニトロン

### 2.1 ネオコグニトロンの概要

内挿ベクトル法を適用するネオコグニトロンの概要について説明する。回路は図 1 に示すように、S 細胞と C 細胞層の組が 4 段重なった構造を持っている： $U_0 \rightarrow U_G \rightarrow U_{S1} \rightarrow U_{C1} \rightarrow U_{S2} \rightarrow U_{C2} \rightarrow U_{S3} \rightarrow U_{C3} \rightarrow U_{S4} \rightarrow U_{C4}$ 。

各層は、個々の細胞が選択的に反応する特徴の違いに応じて、いくつかの“細胞面”に分割されている。各細胞面内で細胞は retinotopy を保って 2 次元的に並んでおり、同一細胞面内の細胞はすべてが同じ入力結合を共有している。その結果、同一細胞面内の細胞はすべてが同一特性の受容野をもつが、その受容野の位置は細胞ごとに異なることになる。学習時にも入力結合は、共有結合の制約のもとに変化していく。




図 1 ネオコグニトロンの回路構造

刺激パターンは視細胞の並んだ入力層  $U_0$  に呈示される。  $U_0$  層の出力は、網膜神経細胞に似たオン中心型あるいはオフ中心型受容野を持つコントラスト抽出細胞の層  $U_G$  に送られる。オン中心型細胞は、入力画像の輝度の正のコントラストを、オフ中心型細胞は負のコントラストを抽出する。

$U_G$  層の出力は、第 1 段目の S 細胞層  $U_{S1}$  に送られる。S 細胞は可変入力結合を持ち、その結合は学習によって形成される。学習終了後は、S 細胞は特徴抽出細胞として働く。

$U_{S1}$  層の S 細胞は、第 1 次視覚野の単純型細胞に似ている。教師あり学習の結果、種々の方位のエッジ成分を抽出するようになっている。中間層 ( $U_{S2}$  と  $U_{S3}$ ) の S 細胞は、教師なし学習によって自己組織的に作られる。

C 細胞は、学習によって変化しない固定入力結合をもつ。受容野の位置が少し異なる複数個の S 細胞の出力を集め、受容野内に呈示された特徴に対して位置不変的な反応を示す。つまり、S 細胞が抽出した特徴の位置ずれを吸収する働きをする。

入力パターンの情報は、階層回路内の各段で、S 細胞による特徴抽出と、C 細胞による特徴の位置ずれの許容化を繰り返しながら上位段に送られる。下位段で抽出された局所的な特徴が階層回路の中で大域的な特徴に組み上げられていく過程で、入力パターンの種々の変形にともなう局所的特徴の相対的な位置ずれの影響が少しずつ吸収されるので、位置ずれだけでなく変形にも強いパターン認識が可能になる。

本提案のコグニトロンは、まず最初に、従来のコグニトロンとまったく同じ方式で学習パターンを学習する [8]。最上位段の S 細胞も、教師あり学習によって、すべての学習パターンを正しく認識するように学習する (2.2.2 節参照)。

従来の学習を完了した後に、未知パターンに対する認識率を向上させるために、内挿ベクトル法 (3. 節参照) を適用する。すなわち、回路の最上位層  $U_{C4}$  が最終認識結果を示す認識細胞層であるが、その反応は、 $U_{S4}$  の反応を内挿ベクトル法を用いて解析して定める (4. 節参照)。

### 2.2 最上位段の S 細胞

#### 2.2.1 $U_{SL}$ の反応

従来のコグニトロン [8] と異なるのは最上位段だけなので、最上位段の S 細胞層  $U_{SL}$  ( $L=4$ ) の性質について論じる。

$U_{SL}$  の  $k$  番目の細胞面の S 細胞の出力を  $u_{SL}(\mathbf{n}, k)$  と表わす。ここに  $\mathbf{n}$  は、その S 細胞の受容野の中心位置を示す。  $U_{SL}$

層には、ほかの層と同様に、S 細胞だけでなく V 細胞も存在する。S 細胞の出力と、その S 細胞に抑制性信号を送っている V 細胞の出力  $v_L(\mathbf{n})$  は、次式で与えられる。

$$u_{SL}(\mathbf{n}, k) = \frac{\sum_{\kappa=1}^{K_{CL-1}} \sum_{|\boldsymbol{\nu}| < A_{SL}} a_{SL}(\boldsymbol{\nu}, \kappa, k) \cdot u_{CL-1}(\mathbf{n} + \boldsymbol{\nu}, \kappa)}{b_{SL}(k) \cdot v_L(\mathbf{n})} \quad (1)$$

$$v_L(\mathbf{n}) = \sqrt{\sum_{\kappa=1}^{K_{CL-1}} \sum_{|\boldsymbol{\nu}| < A_{SL}} c_{SL}(\boldsymbol{\nu}) \cdot \{u_{CL-1}(\mathbf{n} + \boldsymbol{\nu}, \kappa)\}^2} \quad (2)$$

ここに  $a_{SL}(\boldsymbol{\nu}, \kappa, k)$  ( $\geq 0$ ) は、S 細胞が前段の C 細胞  $u_{CL-1}(\mathbf{n} + \boldsymbol{\nu}, \kappa)$  から受け取る入力結合の強度である。一つの細胞面のすべての細胞が同一の入力結合を共有しているため、 $a_{SL}(\boldsymbol{\nu}, \kappa, k)$  は、S 細胞の位置を示す変数  $\mathbf{n}$  を含んでいない。 $A_{SL}$  は  $\boldsymbol{\nu}$  の総和範囲の半径、すなわち 1 個の S 細胞の入力結合の空間的広がり的大小を示す。 $b_{SL}(k)$  ( $\geq 0$ ) は、V 細胞からの抑制性可変結合の強さである。 $c_{SL}(\boldsymbol{\nu})$  は、その V 細胞への興奮性固定結合の強度で、 $|\boldsymbol{\nu}|$  の単調減少関数になっている。

### 2.2.2 最上位段の初期学習

内挿ベクトル法を適用する前に、最上位段の S 細胞を従来のネオコグニトロンと同じ方式で学習させる [8]。

最上位段  $U_{SL}$  の初期学習は、それよりも低次の段 ( $U_{S2}$  と  $U_{S3}$ ) の学習が完了した後に、低次の段の学習に用いたのと同じ学習パターンのセットを用いて始める。

$U_{SL}$  の学習則は、 $U_{S2}$  や  $U_{S3}$  の学習に用いた競合学習に類似しているが、 $U_{SL}$  では学習パターンのラベル (分類すべきクラス名) も学習に用いる。回路は種々の変形パターンも学習するので、 $U_{SL}$  層には通常各クラスに対して、複数の細胞面が形成される。そこで各細胞面が、ある学習パターンを最初に学習したときに、その学習パターンのクラス名を、細胞面のラベルとする。手書き数字認識の場合には、各細胞面は 10 個の数字の一つを表わすラベルを付けられることになる。

学習パターンが呈示されるごとにすべての S 細胞間で競合が起こる。(つまり  $U_{SL}$  層の競合領域は、層中のすべての細胞を覆うほど広い)。もし競合の勝者が学習パターンと同じラベルを持っていれば、勝者が seed cell になって、下位層の seed cell の場合と同様に、その学習パターンを学習する。

もし勝者が、学習パターンと異なるラベルを持っていたり、あるいはすべての S 細胞が無反応であった場合には、新しい細胞面を作成して学習パターンと同じラベルを付ける。新しく作成した細胞面の seed cell を選ぶためには、その細胞面のすべての細胞が、ほとんどゼロに近い非常に弱い拡散した興奮性結合を持っているという仮想的状態を想定する。その仮想的状態のもとで最大出力を出した細胞を seed cell とする。つまりその細胞面の中で、最も多量の情報を受け取ることができる細胞を seed cell に選ぶのである。

ある学習パターンに対して細胞  $u_{SL}(\hat{\mathbf{n}}, \hat{k})$  が seed cell に選ば

れたとしよう。この seed cell の興奮性可変入力結合  $a_L(\boldsymbol{\nu}, \kappa, \hat{k})$  (これは、共有結合の結果、この seed cell の属する細胞面のすべての細胞の入力結合でもある) を、以下の値だけ強める。

$$\Delta a_{SL}(\boldsymbol{\nu}, \kappa, \hat{k}) = c_{SL}(\boldsymbol{\nu}) \cdot u_{CL-1}(\hat{\mathbf{n}} + \boldsymbol{\nu}, \kappa) \quad (3)$$

抑制性可変結合  $b_L(\hat{k})$  の値は、興奮性結合  $a_L(\boldsymbol{\nu}, \kappa, \hat{k})$  の値を用いて、次式によって直接決定する。

$$b_{SL}(\hat{k}) = \sqrt{\sum_{\kappa=1}^{K_{CL-1}} \sum_{|\boldsymbol{\nu}| < A_{SL}} \frac{\{a_{SL}(\boldsymbol{\nu}, \kappa, \hat{k})\}^2}{c_{SL}(\boldsymbol{\nu})}} \quad (4)$$

### 2.3 参照ベクトル

S 細胞の反応をベクトル表記しよう。S 細胞への入力信号をベクトル表記したものを  $\mathbf{x}$  とする。つまり、前層の C 細胞  $u_{CL-1}(\mathbf{n} + \boldsymbol{\nu}, \kappa)$  の反応が、ベクトル  $\mathbf{x}$  の  $\boldsymbol{\nu}$  番目の要素である。

同様に、この S 細胞への  $m$  番目の学習ベクトルを  $\mathbf{x}^{(m)}$  とする。もう少し厳密に述べると  $\mathbf{x}^{(m)}$  は、この S 細胞が属する細胞面に対する  $m$  番目の学習ベクトルである。ここで、この細胞面に対する学習ベクトルの総和を  $\mathbf{X}$  とする。すなわち

$$\mathbf{X} = \sum_m \mathbf{x}^{(m)} \quad (5)$$

この  $\mathbf{X}$  を S 細胞 (あるいはその細胞面) の参照ベクトルとよぶ。

ここで、V 細胞への興奮性固定入力結合  $c_{SL}(\boldsymbol{\nu})$  ( $> 0$ ) の値を重みとして、任意の 2 個のベクトル  $\mathbf{X}$  と  $\mathbf{x}$  の“重み付きの内積を次式で定義する (式 (2) と (3) 参照)。

$$(\mathbf{X}, \mathbf{x}) = \sum_{|\boldsymbol{\nu}| < A_{SL}} c_{SL}(\boldsymbol{\nu}) X(\boldsymbol{\nu}) x(\boldsymbol{\nu}) \quad (6)$$

さらに、ベクトル  $\mathbf{x}$  のノルムを  $\|\mathbf{x}\| = \sqrt{(\mathbf{x}, \mathbf{x})}$  で定義する。

式 (2), (3), (4) を、式 (1) に代入し、ここで定義したベクトル表記を用いると、S 細胞の反応は以下のように表わせる。

$$u_{SL}(\mathbf{n}, k) = s \quad (7)$$

ここに

$$s = \frac{(\mathbf{X}, \mathbf{x})}{\|\mathbf{X}\| \cdot \|\mathbf{x}\|} \quad (8)$$

は、参照ベクトル  $\mathbf{X}$  とテストベクトル  $\mathbf{x}$  との類似度である。これは、多次元ベクトル空間内での、2 個のベクトルのなす角度の cosine になっている。ベクトル  $\mathbf{X}$  と  $\mathbf{x}$  のすべての要素は、非負の値をとるので、 $s$  は  $0 \leq s \leq 1$  の範囲の値をとることになる。S 細胞は、テストベクトルが参照ベクトルと完全に一致したときに最大出力 1 を出す。

ここで、初期学習の操作を、多次元ベクトル空間という立場で眺めてみよう。 $U_{SL}$  の S 細胞の入力結合は、参照ベクトル  $\mathbf{X}$  を表わしていると考えることが出来る。テストベクトルに対する S 細胞の反応は、テストベクトル  $\mathbf{x}$  と参照ベクトル  $\mathbf{X}$  との類似度を示している。

最大出力を出す S 細胞を探す操作は、多次元特徴空間内で最も近距離にあるベクトルを見いだす操作に対応している。各参




図2 多次元特徴空間内での学習ベクトルと参照ベクトルの分布。

照ベクトルは、特徴空間をボロノイ分割することによって定められる自分自身の占有領域を持っている。この意味において、最大出力細胞を探し出す操作は、ベクトル量子化に類似している [2], [3].

初期学習において、ある学習ベクトルが正しく識別された時には、その学習ベクトルは、その時の勝者の参照ベクトルに加え合わせられる。しかし学習ベクトルが誤って識別された場合には、誤った識別を引き起こした勝者の参照ベクトルは、変更せずにそのままにしておく。その代わりに新しい細胞面を生成し、その時の学習ベクトルを、新しい細胞面の参照ベクトルとする。新しい参照ベクトルの生成は、特徴空間内の識別境界を動かすことになる。その結果、ほかのクラスの学習ベクトルの中には、それまでは正しく識別されていたのに、新しい参照ベクトルが形成されたために、誤識別されるようになるものが現われることもある。このような現象が起こったときには、識別境界を再調整するために、新たな参照ベクトルを発生させなければならない。したがって学習が収束するまでには、同一の学習セットを何回も繰り返して呈示する必要がある。このようにして識別境界は次第に移動し、クラス間の真の境界に近づくように調整が進んでいく。

一般に、あるクラスの領域の中心付近に位置する学習ベクトルは正しく識別される可能性が高いので、クラスの境界から離れた位置では、通常1個の参照ベクトルが多数の学習ベクトルを代表することになる。その結果、形成される参照ベクトル(すなわち細胞面)の数は、学習ベクトル(学習パターン)の数よりもはるかに少ない。学習時に誤識別される学習ベクトルの多くは、クラスの境界付近に現われるので、参照ベクトルは図2のように、クラスの境界付近に密集して作られることになる。

学習が収束するまでに学習パターンセットを繰り返し呈示する必要があるが、必要とする繰り返し回数は、通常はそれほど多くはない。後述の5.節の計算機シミュレーションでは、学習ベクトルの認識率が100%になるまでに、6回の繰り返して十分であった。パターンセットの1回の呈示を終るごとに、その1回の呈示期間中に形成された細胞面の数、すなわち誤認識された学習ベクトルの数を数える。この数がゼロになったら、初期学習を終了する。

### 3. 内挿ベクトル

初期学習を終了してすべての参照ベクトルが形成された後

に、パターン認識能力をさらに高めるために内挿ベクトル法を用いる。

内挿ベクトル法の基本的考え方は以下のとおりである。同一ラベルを持つ参照ベクトルのあらゆる対を考え、それらの対を結ぶ線分上に内挿ベクトルと名付けた仮想的なベクトルが密に並んでいる状態を想定する。これらの内挿ベクトルの中で、テストベクトルとの間の類似度が最大のものを選ぶ。選ばれた内挿ベクトルのラベル(クラス名)を認識結果とする。(便宜上、内挿ベクトルという名称を用いているが、後述のように実際には、外挿ベクトルも含めて、ベクトル対を結ぶ線分に並ぶすべてのベクトルを対象にしている)。

実際には、無限個の内挿ベクトルを作る必要はない。同一ラベルの参照ベクトルを結ぶ線分を、あらゆる対に対して作成する。線分には、その両端の参照ベクトルと同じラベルを付ける。テストベクトルとの間の距離(類似度の基づく距離)を測り、最も近い線分を選び、その線分のラベルを認識結果とする。

数式で記述すれば、この操作は以下ようになる。同一ラベルを持つ2個の参照ベクトルを  $\mathbf{X}_i$  と  $\mathbf{X}_j$  とする。この参照ベクトルの対に対する内挿ベクトル  $\boldsymbol{\xi}$  は、その線形結合で与えられる:

$$\boldsymbol{\xi} = p \frac{\mathbf{X}_i}{\|\mathbf{X}_i\|} + q \frac{\mathbf{X}_j}{\|\mathbf{X}_j\|} \quad (p + q = 1) \quad (9)$$

内挿ベクトル  $\boldsymbol{\xi}$  とテストベクトル  $\mathbf{x}$  との間の類似度  $s$  は、

$$s = \frac{(\boldsymbol{\xi}, \mathbf{x})}{\|\boldsymbol{\xi}\| \cdot \|\mathbf{x}\|} = \frac{ps_i + qs_j}{\sqrt{p^2 + 2pqs_{ij} + q^2}} \quad (10)$$

となる。ここに

$$s_i = \frac{(\mathbf{X}_i, \mathbf{x})}{\|\mathbf{X}_i\| \cdot \|\mathbf{x}\|}, \quad s_j = \frac{(\mathbf{X}_j, \mathbf{x})}{\|\mathbf{X}_j\| \cdot \|\mathbf{x}\|}, \quad (11)$$

$$s_{ij} = \frac{(\mathbf{X}_i, \mathbf{X}_j)}{\|\mathbf{X}_i\| \cdot \|\mathbf{X}_j\|}$$

である。

$p$  と  $q$  の種々の組み合わせのもとで、類似度  $s$  の最大値は

$$s_{\max} = \sqrt{\frac{s_i^2 - 2s_i s_j s_{ij} + s_j^2}{1 - s_{ij}^2}} \quad (12)$$

である。ちなみにこの最大値を与える  $p$  と  $q$  の値は、

$$p = \frac{s_i - s_j s_{ij}}{(s_i + s_j)(1 - s_{ij})} \quad q = \frac{s_j - s_i s_{ij}}{(s_i + s_j)(1 - s_{ij})} \quad (13)$$

である。しかし実際には、式(9)で条件  $p + q = 1$  は不要である。類似度  $s$  の計算において  $\boldsymbol{\xi}$  はそのノルムで正規化されるので、(12)の値に影響を与えないからである。重要なのは、 $p$  と  $q$  の比だけである。

$s_{\max}$  は、同一ラベルを持つ1対の参照ベクトル  $\mathbf{X}_i$  と  $\mathbf{X}_j$  を結ぶ線分と、テストベクトルとの類似度を表わしていると解釈することが出来る(図3(a))。同一ラベルの参照ベクトルを結ぶすべての線分の中で、テストベクトルとの類似度が最大のものを選び、その線分のラベル(クラス名)を認識結果とする。

この最大類似度類の探索に際して、 $p$  あるいは  $q$  が負の値をとることも許すことにする。そのほうが、計算機シミュレーショ




図3 同一ラベルを持つ参照ベクトル対を結ぶ線分との最大類似度。




図4 凹型の境界を通り越す線分の除去。図に×で示したクラスBの学習ベクトルは、クラスBの線分よりも、クラスAの線分(破線)に近い。

ンで通常高い認識率が得られるからである。つまり、図3(b)のように、参照ベクトル対を結ぶ線分が、両端の参照ベクトルを越して広がることも許しており、内挿ベクトルだけでなく外挿ベクトルも許していることになる。

多次元特徴空間内で、もしクラス間の境界の一部が凹型であると、線分の中には、凹型の境界を通り越して、別のクラスの領域を侵略するものが出てくる可能性がある。それは例えば図4に破線で示したような線分で、テストベクトルの誤認識を引き起こす可能性が高い。そこで、クラスの境界を通り越して問題を起こす疑いのある線分を探し出して除去するために、参照ベクトルの作成を完了した後に、調整プロセスを行なう。調整プロセスでは、参照ベクトル形成に用いたと同じ学習ベクトルが、どのように分類されるかを調べる。もし、ある学習ベクトルが誤って認識された場合には、この学習ベクトルに最も近い線分がクラスの境界を越境していると見なして、その線分を除去する。場合によっては、1個の学習ベクトルに対して、2本以上の線分が除去されることもある。調整プロセスでは、このようにして、学習ベクトルに対して誤認識を引き起こす線分は、すべて除去してしまう。

#### 4. 内挿ベクトル法のネオコグニトロンへの適用

さて、この内挿ベクトル法を、ネオコグニトロンの  $U_{SL}$  層の反応の分析に用いる。2.3節で述べたように、 $U_{SL}$  層の1個のS細胞の入力結合が参照ベクトルに対応する。すでに初期学習によって、すべての参照ベクトルが形成されており、すべての参照ベクトルにはクラス名のラベルが付いている。

2個のS細胞  $u_{SL}(\mathbf{n}, k_i)$  と  $u_{SL}(\mathbf{n}, k_j)$  が同じラベルを持っているとする。この2個の細胞の出力は、前記の式(11)の  $s_i$  と  $s_j$  に対応する。

$k_i$  番目と  $k_j$  番目の細胞面間、すなわち  $k_i$  番目と  $k_j$  番目の参照ベクトル間の  $s_{ij}$  の値は

$$s_{ij} = \frac{1}{b_{SL}(k_i) \cdot b_{SL}(k_j)} \times \sum_{\kappa=1}^{K_{CL}-1} \sum_{|\nu| < A_{SL}} \frac{a_{SL}(\nu, \kappa, k_i) \cdot a_{SL}(\nu, \kappa, k_j)}{c_{SL}(\nu)} \quad (14)$$

で与えられる。そこで、同一ラベルを持つ細胞面(すなわち参照ベクトル)のあらゆる対に対して、あらかじめ  $s_{ij}$  を計算してその値を記録しておく。さらに調整プロセスでは、その対を結ぶ線分が、いずれかの学習ベクトルに対して誤った識別を引き起こした場合には、クラスの境界を横切っている疑いがあると考えて、そのことを示すマークを付けておく。

このように、同一ラベルの参照ベクトル対に対して  $s_{ij}$  の値をあらかじめ求めてあるので、式(12)を用いて  $s_{max}$  の値を簡単に計算することが出来る。すなわち、同一のラベルを持つS細胞のあらゆる対の中で、 $s_{max}$  の値が最大になるものを探す。この探索は、一つの位置  $\mathbf{n}$  についてだけでなく、受容野位置  $\mathbf{n}$  が異なるすべてのS細胞に対して行なう。このようにして選び出されたS細胞のラベルがパターン認識の最終結果である。しかしこの探索において、クラスの境界を横切っていると疑われてマークを付けられている線分(S細胞の対)は除外する。

#### 5. 計算機シミュレーション

内挿ベクトル法を用いたネオコグニトロンの計算機シミュレーションを行ない、そのパターン認識能力を、旧電総研のETL1データベースからランダムにサンプルした手書き数字を用いて調べた。

回路規模(回路内の細胞数や結合の広がりなど)やパラメータ、初期学習の方法などは、従来のネオコグニトロン[8]とほとんど同じである。すなわち、 $U_{S2}$  層と  $U_{S3}$  層のS細胞に対しては、学習時と認識時とで異なるしきい値を用いた。 $U_{S2}$  層と  $U_{S3}$  層の学習には、それぞれ、学習パターンを1回ずつ呈示するだけで完了した。

最上位段の  $U_{S4}$  層の初期学習には、下位の層の学習に用いたのと同じ学習パターンセットを、新しい細胞面の生成が終わるまで繰り返して呈示した。下記の条件でのシミュレーションの場合には、学習パターンに対して100%の認識率を達成するために、学習パターンセットを6回呈示するだけで十分であった。

ここでは、ランダムにサンプルした5000個のパターン(各数字を各500個)からなる学習セットを用いた場合の実験結果について述べよう。認識率は下位の層のS細胞のしきい値の選び方によって変化するので、最大認識率が得られるしきい値の組合わせを探した。組合わせの数が多数あるので、最適しきい値の探索はまだ完了していないが、ほぼ最適と思われるしきい値を用いた場合の結果を示す。

内挿ベクトル法を用いた場合、学習に用いていない未知の5000個のテストパターンに対して、rejection無しで、誤り率は1.02%(51/5000)、学習パターンに対しては0%(0/5000)であった。なお、 $U_{S4}$  層に形成された細胞面の数、すなわち参照ベクトルの数は160で、学習パターン数に比べてはるかに少ない。その結果、参照ベクトルを結ぶ線分の数も十分少なく、

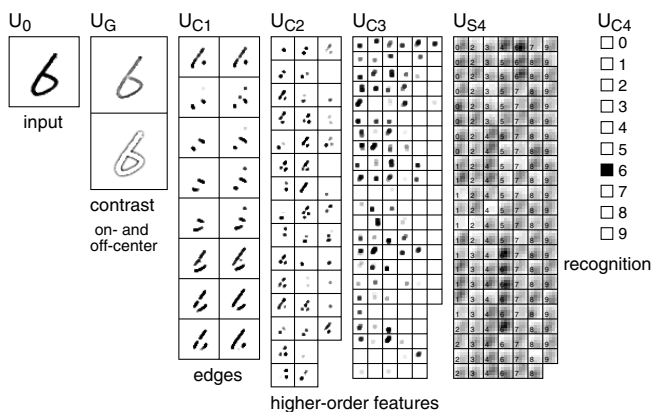


図5 内挿ベクトル法を用いたネオコグニトロンへの入力パターンは正しく‘6’であると認識されている。

4	6	3	2	7	7	2	7	3	3	φ
7	8	8	7	7	2	7	7	7	2	7
6	8	8	8	7	7	7	2	2	7	7
2	3	2	0	5	4	2	2	7	6	8
2	2	7	8	6	7	8				

図6 5000個の未知のテストパターンの中で、誤認識されたパターン。

調整プロセス終了後に1294個であった。また、調整プロセスで除去された線分は16個であった。

図5に、学習を終わった回路内の細胞の反応の一例を示す。図の左端が入力層 $U_0$ 、右端が認識結果を示す認識細胞層 $U_{C4}$ である。層内の各正方形が細胞面を表す。 $U_{S1}$ 、 $U_{S2}$ 、 $U_{S3}$ 層の反応は省略してあるが、対応するC細胞層の反応から容易に推測できる。C細胞層の反応は、その入力結合の抑制性周辺結合成分による影響を多少は受けてはいるが、S細胞層の反応をぼかしたものになっているからである。この図で $U_{S4}$ 層の細胞面は、それが作られた順番ではなく、同一ラベルの細胞面が集まるように並べ替えて表示してある。 $U_{S4}$ 層の各細胞面の中に記入した数字は、そのラベル(クラス名)である。

このとき、未知の5000個のテストパターンの中で誤認識されたパターンを図6に示す。各パターンの左下に記入した数字は、このネオコグニトロンがそのパターンをどのように認識したかを示している。

内挿ベクトル法を用いずに、 $U_{S4}$ の反応を従来のネオコグニトロンで分析した場合には、誤り率は、未知のテストパターンに対して1.52% (76/5000)、学習パターンに対して0.02% (1/5000)であった。内挿ベクトル法を用いることによって、誤認識されるパターンが76個から51個に減少し、認識率が98.48%から98.98%に向上したことを意味している。

ちなみに、疑わしい線分除去を行なう調整プロセスを省いた場合には、誤り率は、テストパターンに対して1.06% (53/5000)、学習パターンに対して0.12% (6/5000)になった。この結果から判断すると、たとえ調整プロセスを省いても、テストパターンに対する誤認識はそれほど増加しないが、学習パターンに対

しては誤りがかなり増加するようである。

学習パターンとテストパターンのサンプリングの仕方によって、認識率の測定値がどの程度変化するかを調べるために、学習パターンとテストパターンとを入れ替えてみた。両者を入れ替えたときの誤認識率は、内挿ベクトル法を用いた場合には、テストパターンに対して1.04% (52/5000)、学習パターンに対して0%で、入れ替えの影響は非常に少なかった。

比較のために、nearest neighbor法による認識も試みてみた。すなわち、 $U_{S4}$ に、各学習パターンごとに細胞面を1個ずつ形成させた。したがって5000個の学習パターンを用いた場合には、5000個の細胞面が形成されることになる。未知のテストパターンに対する誤認識率は1.22% (61/5000)であった。これは、内挿ベクトル法のほうが、はるかに少ない計算量で、高い認識率が得られることを示している。

## 6. むすび

内挿ベクトル法(interpolating vectors)を用いた強力な新しいパターン認識アルゴリズムを提唱した。その有効性を示すために、ネオコグニトロンによる手書き数字認識にこのアルゴリズムを適用した。5000個の数字を学習させた場合、学習に用いなかった別の5000個の未知パターンに対する誤認識率を、内挿ベクトル法を適用することによって、1.52%から1.02%に減少させることが出来た。なお、学習時に作られる参照ベクトル(細胞面)の数は学習ベクトル(学習パターン)の数よりもはるかに少ないので、内挿ベクトル法の適用によって増加する計算量は非常に少ない。

内挿ベクトル法は、ネオコグニトロンに限らず、ほかの種々のパターン認識システムに対しても有効であると考えられる。

謝辞 本研究の一部は文科省の科研費#18500181の助成を受けた。

## 文 献

- [1] T. M. Cover, P. E. Hart: "Nearest neighbor pattern classification", *IEEE Trans. Information Theory*, **IT-4**[5], pp. 515-516 (1968).
- [2] R. M. Gray: "Vector quantization", *IEEE ASSP Magazine*, **1**[2], pp. 4-29 (1984).
- [3] T. Kohonen: *The Self-Organizing Maps*, Berlin-Heidelberg-New York: Springer-Verlag, 1995.
- [4] B. Schölkopf, K. Sung, C. Burges, F. Girosi, P. Niyogi, T. Poggio, V. Vapnik: "Comparing support vector machines with Gaussian kernels to radial basis function classifiers", *IEEE Trans. Signal Processing*, **45**, pp. 2758-2764 (1997).
- [5] C. Burges: "A tutorial on support vector machines for pattern recognition", *Data Mining and Knowledge Discovery*, **2**, pp. 1-47 (1998).
- [6] K. Fukushima: "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position", *Biological Cybernetics*, **36**[4], pp. 193-202 (April 1980).
- [7] K. Fukushima: "Neocognitron: a hierarchical neural network capable of visual pattern recognition", *Neural Networks*, **1**[2], pp. 119-130 (1988).
- [8] K. Fukushima: "Neocognitron for handwritten digit recognition", *Neurocomputing*, **51**, pp. 161-180 (April 2003).  
このネオコグニトロンのC言語の計算機プログラムはVisiome Platform (<http://platform.visiome.org/index.html>)からダウンロード可能