

大脳視覚野における V1 野-IT 野を模した階層型 SOM のパターン分類能力

加藤 聡[†] 下平 博^{††} 堀口 進^{††}

Kohonen の Self-Organizing Maps(SOM) は, 入力信号の集合におけるトポロジカル(位相的)な情報を可能な限り保存しつつ, 多次元の入力信号をより低次元の空間に写像できる教師なしの神経回路網モデルであり, パターン認識や大脳皮質の様々な領野のモデル化等に应用されている. 近年サルを用いた生理学的実験により, 視覚野の IT 野と呼ばれる領野において中程度に複雑な図形に対して選択性を持つ神経細胞が発見されたが, これらの神経細胞がどのようにして図形に対する選択性を獲得するかについて, SOM を用いたモデル化の試みはなされていない.

本論文では, 大脳視覚野における V1 野と IT 野の特徴抽出細胞および V1 野から V2 野, V4 野を経て IT 野に至る階層的な神経投射関係に着目し, SOM を階層的に用いた V1-IT SOM を提案する. 人工的な幾何学図形のパターン分類実験では, 階層化を行わない基本 SOM と比較して, より自然な形態の分類が行なわれることが確認された. また, 手書き数字を用いたパターン認識実験を行なった結果, V1-IT SOM は基本 SOM と比較して高い認識率が得られることが分かった.

Pattern recognition ability of the Hierarchical V1-IT SOM derived from human visual system

SATORU KATO,[†] HIROSHI SHIMODAIRA^{††} and SUSUMU HORIGUCHI^{††}

Kohonen's Self-Organizing Maps(SOM) are well known as unsupervised learning neural network model which can map high dimensional data to a low dimensional space. SOM is applied to clustering, pattern recognition, and modeling of a visual system in a human brain. Recently, a stimulus selective cells which respond only to specific simple geometrical patterns are discovered in the area IT of a monkey's visual cortex by physiological experiments. However there is no model about how the cells acquire selectivity to such geometrical patterns.

This paper suggests a V1-IT SOM derived from the stimulus selective cells in both the area V1 and IT, and the hierarchical neural projection from the area V1 to the area IT via V2 and V4 in a visual cortex. And we discuss about an ability of classification of simple geometrical patterns on the V1-IT SOM, also about an ability of pattern recognition by using the hand-written digits. We found that the V1-IT SOM has high abilities of classification and pattern recognition compared with Kohonen's basic SOM.

1. ま え が き

Kohonen の自己組織化マップ(SOM)¹⁾ は, 入力信号空間における個々の入力信号間の位相構造を反映した特徴マップを, 学習によって形成する事ができ, クラスタリング問題やパターン認識に应用されている. さらに, SOM を大脳視覚野のモデル化に適用する試みも行なわれており, Obermayer らは, 第 1 次視覚野(以下, V1 野)における方位選択性カラム構造が SOM によって再現されることを示した²⁾.

近年, Wang らによる生理学的実験により, サルの大脳の下部側頭葉皮質 IT 野(以下 IT 野)において, 中程度に複雑な幾何学図形に選択的に応答する神経細胞が多数存在することが報告されている³⁾. 加藤らは, これらの細胞に対して, 視覚野における各領野の階層的連絡を考

慮して, 階層型ネットワークに SOM アルゴリズムを段階的に適用した階層型 V1-IT SOM(以下 V1-IT SOM)を構築し, IT 野における特徴抽出細胞と同様に, 特定の幾何学図形に対して選択的に応ずるノードが自己組織的に形成されることを報告している⁴⁾. しかしながら, 大脳視覚野を模した V1-IT SOM のパターン分類能力については未だ十分な考察がなされていない.

大脳視覚野における生理学的知見に基づく階層型の教師なし神経回路網モデルとしては, 福島の新コグニトロン⁵⁾が挙げられる. また, 階層型 SOM については, Lampinen らによるクラスタリング問題への適用⁶⁾や, Suganthan らによる文字認識への応用⁷⁾が報告されている. V1-IT SOM は, ネオコグニトロンと同じく大脳視覚野における生理学的知見に基づいて提案された階層型の神経回路網モデルであるが, ネオコグニトロンとは異なり, V1 野および IT 野における特徴抽出細胞や, V1 野から V2 野および V4 野を経て IT 野に至るまでの階層的な神経投射等の事実に基づいて, より生体に近い構造で形態の知覚を行なう神経回路網を構築することを目

[†] 松江工業高等専門学校

Matsue National College of Technology

^{††} 北陸先端科学技術大学院大学

Japan Advanced Institute of Science and Technology

的としている．本報告では，V1-IT SOM における図形分類の特性およびパターン認識性能について議論する．

2. 基本 SOM と V1-IT SOM

2.1 基本 SOM の構成と SOM 学習アルゴリズム

Kohonen が提案した基本 SOM は 1 つの入力層と 1 つの競合層を持ち，図 1 において Input-layer および Competitive-layer1 のみで構成される．競合層の各ユニットをノードと呼び，入力層の i 番目のユニット i と競合層の j 番目のノード j の結合には，結合加重 w_{ij} が与えられている．競合層のノードは入力層のユニットと完全結合しているため，ノード j は結合加重ベクトル W_j を持つとみなす事が出来る．以下に，SOM 学習アルゴリズムの手順を示す．

STEP1 初期化：学習回数 $t = 0$ において，各ノードが持つ重みベクトルを乱数によって初期化する．

STEP2 入力ベクトル E の呈示

STEP3 勝者ノードの決定：次式に従い， E と最も良く一致する結合重みベクトル W_c を持つ競合層のノード c を決定する．ノード c を勝者ノードと呼ぶ．

$$c = \arg \min_j \{ |E - W_j| \} \quad (1)$$

STEP4 重みベクトルの更新：勝者ノード c およびその近傍 N_d に属するノードの重みベクトル W_j の各要素 w_{ij} を次式に従って修正する．

$$\Delta w_{ij} = \begin{cases} \alpha(e_i - w_{ij}) & \text{if } j \in N_d \\ 0 & \text{otherwise} \end{cases} \quad (2)$$

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij} \quad (3)$$

ここで， α は学習率であり， $0.0 < \alpha \leq 1.0$ の範囲で経験的に決定される量である．

STEP5 学習時刻の更新： $t = t + 1$ とし，学習時刻を更新する．

STEP2 から STEP5 の操作を繰り返すことにより学習が進められる．なお，近傍半径 d と学習率 α は t の増加に対して単調減少させる．

2.2 V1-IT SOM による幾何学図形の学習

V1-IT SOM は基本 SOM に競合層を追加した物であり，図 1 の様に構成される．V1-IT SOM の学習は階層型 SOM と同様，2 段階で行なわれる．まず第 1 段階として，入力層に任意の位置および傾きを持つ線分図形を呈示することにより，中間競合層（以下，V1 層）の学習を行なう．この時，出力競合層（以下，IT 層）への入力信号の伝達は行なわれない．第 1 段階の学習によって，V1 層の各ノードは，特定の位置および傾きに対する選択性を獲得する．V1-IT SOM が一般的な階層型 SOM と異なる所は，第 1 段階の学習時に，第 2 段階の学習に用いる幾何学図形の部分構造を V1 層に対して学習させる事である．

第 2 段階の学習では，入力層には任意の形状の幾何学図形を呈示する．このとき，V1 層の各ノードは第 1 段

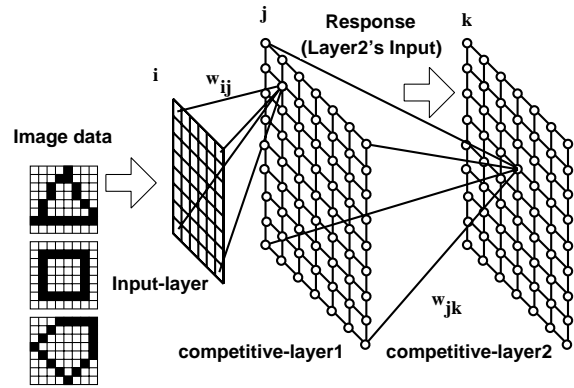


図 1 V1-IT SOM

階で既に方位選択性を獲得しており，入力層に呈示された幾何学図形を構成する複数の線分に対して，V1 層の各ノードが次式に基づいた出力値 v_j を出す．

$$v_j = \cos \theta_{EW} = \frac{E \cdot W_j^{\text{mid}}}{|E| \cdot |W_j^{\text{mid}}|} \quad (4)$$

ここで， E は入力ベクトルであり， W_j^{mid} は V1 層のノード j における重みベクトルである． v_j は V1 層全体で出力ベクトル V を構成し，IT 層は V を入力ベクトルとして学習を行なう．第 2 段階の学習終了後，出力競合層の各ノードは特定の図形に対する選択性を持つようになる．

2.3 対象図形および SOM の構成

分類実験には，入力集合として表 1 に示すような 7 種類の四角形と 2 種類の三角形合わせて 9 種類のサンプル図形を用いた．学習サンプルの合計は 108 個である．

幾何学図形は 30×30 画素のビットマップ画像であるため，基本 SOM，V1-IT SOM 共に入力層の大きさは 30×30 とする．基本 SOM の競合層のノード数はサンプル数と同じ 9 個とし，V1-IT SOM においては V1 層のノード数を 400 個，IT 層のノード数を 9 個とした．また，競合層の各ノードは四角形格子状に結合しているものとする．さらに，V1 層には事前にランダムな中心位置と傾きを持つ直線の画像を学習させた．学習時のパラメータは，学習回数 100000 回，近傍半径 d の初期値 $d_{ini} = 2$ ，学習率 α の初期値 $\alpha_{ini} = 0.2$ とした．

2.4 分類結果の比較

基本 SOM および V1-IT SOM において，競合層の各ノードが受け持つ図形集合を表したものを表 2，表 3 に示す．いずれの場合も表 1 と一致した分類を行なっていないことが分かる．次に，表 1 における図形の分類を考えずに，三角形，四角形の分類がどれだけ良く行なわれているかについて検討する．あるノード j が受け持つ図形集合に含まれる図形の総数を M_j とし，その図形集合に含まれる三角形と四角形のうち，多い方の個数を U_j とし，ノード j における三角形と四角形の分離度 I_j を次のように定義する． I_j が 1 に近いほど分離度は高く， I_j が 0.5 に近いほど分離度が低いと言える．

表 1 クラスタリング実験に用いた幾何学図形

Sample No.	Patterns
1	
2	
3	
4	
5	
6	
7	
8	
9	

表 2 基本 SOM による幾何学図形の分類結果

Node No.	Patterns
1	
2	
3	
4	
5	
6	
7	
8	
9	

$$I_j = \frac{U_j}{M_j} \quad (5)$$

(5) 式によって求めた分離度をまとめたものを表 4 に示す。V1-IT SOM は基本 SOM と比較して、三角形と四角形という大まかな図形特徴に関しては良く分離していると言える。

2.5 V1 層による変換前後の入力集合の性質

基本 SOM と V1-IT SOM の幾何学図形の分離度の違いは、入力層への入力ベクトル \mathbf{E} と、IT 層への入力ベクトルとなる V1 層の出力ベクトル \mathbf{V} の性質の違いによってもたらされていると考えられる。そこで、表 1 で示される 9 種類の幾何学図形のそれぞれをクラスと見なし、入力層への入力ベクトル \mathbf{E} の集合 S と V1 層により変換を受けた IT 層への入力ベクトル \mathbf{V} の集合 S_{IT} の性質を比較する。

いま、 S においてクラス i に属するベクトルを \mathbf{E}_i 、 S_{IT} においてクラス i に属するベクトルを \mathbf{V}_i とし、 S にお

表 3 V1-IT SOM による幾何学図形の分類結果

Node No.	Patterns
1	
2	
3	
4	
5	
6	
7	
8	
9	

表 4 基本 SOM および V1-IT SOM における三角形と四角形の分離度

	Basic SOM	V1-IT SOM
分離度 (平均値)	0.78	0.98

表 5 V1 層の変換前後における $D_{inter}/\bar{D}_{intra}$ の比較

	D_{inter}	\bar{D}_{intra}	$D_{inter}/\bar{D}_{intra}$
S	3.5787	6.2617	0.57152
S_{IT}	2.1463	2.2307	0.96130

るクラス内分散の平均 \bar{D}_{intra} およびクラス間分散 D_{inter} をそれぞれ以下のように定義する。

$$\bar{D}_{intra} = \frac{1}{M} \sum_{i=0}^M \frac{1}{N_i} \sum_{j=0}^{N_i} |\mathbf{E}_{ij} - \bar{\mathbf{E}}_i| \quad (6)$$

$$D_{inter} = \frac{1}{M^2} \sum_{i=0}^M \sum_{k=0}^M |\bar{\mathbf{E}}_i - \bar{\mathbf{E}}_k| \quad (7)$$

ここで、 M は S における総クラス数、 N_i はクラス i に属するベクトルの総数、 $\bar{\mathbf{E}}_i$ および $\bar{\mathbf{E}}_k$ はそれぞれクラス i および k に属するベクトルの平均ベクトルである。 S_{IT} における \bar{D}_{intra} および D_{inter} は、(6) 式、(7) 式において \mathbf{E} を \mathbf{V} に置き換えて、 S の場合と同様に定義するものとする。

表 5 に、 S と S_{IT} における D_{inter} および \bar{D}_{intra} の値を示す。 D_{inter} および \bar{D}_{intra} の値は共に減少しているが、 \bar{D}_{intra} の減少が特に著しく、結果として $D_{inter}/\bar{D}_{intra}$ の値が増加していることが分かる。すなわち、 S と比較して S_{IT} ではクラス内分散がクラス間分散に対して相対的に減少した事を意味しており、V1 層によって元の入力集合が比較的分離しやすい状態に変換されたと考えられる。

さらに、 S における場合と S_{IT} における場合とで入力

図形に対しクラスタ分析を行なった。その結果、 S の場合では四角形同士の局所的な併合がほとんど見られないのに対し、 S_{IT} の場合では三角形および四角形がそれぞれ局所的に併合されていることが分かった。

以上のことから、 S における元の図形集合が V1 層によって S_{IT} に変換されることにより、図形を持つ特徴がより正確に反映され、結果として V1-IT SOM において構造の異なる図形の分類が正しく行なわれていると考えられる。

3. 手書き数字認識による基本 SOM と V1-IT SOM のパターン認識性能の比較

3.1 手書き数字データベースおよび SOM の構成

認識実験には、手書き数字データベースである MNIST handwritten digits database を用いた。60000 字分のデータベースから、3000 字を学習用としてランダムに抽出し、同様に 1000 字をテスト用として抽出した。

基本 SOM、V1-IT SOM 共に入力層には 30×30 のユニットを配置し、V1-IT SOM の V1 層には 20×20 、基本 SOM の競合層および V1-IT SOM の IT 層には 4×4 のノードをそれぞれ四角形格子状に配置した。学習回数はいずれも 500000 回とし、近傍半径 d の初期値 $d_{ini} = 3$ 、学習率 α の初期値 $\alpha_{ini} = 0.2$ とした。また、V1-IT SOM の V1 層には事前にランダムな中心位置と傾きを持つ直線画像に加えて、ランダムな中心位置、直径および始点による中心角 180 度の円弧を学習させた。

3.2 学習終了後の文字認識手法

本稿では以下に示す手順によって認識クラスの決定を行なうものとする。

STEP 1: 学習終了後の SOM に対して学習図形 i を呈示した時の、競合層のノード j の出力 o_j を次のように定義する。

$$o_j = \cos \theta_{E_i, W_j} = \frac{E_i \cdot W_j}{|E_i| \cdot |W_j|} \quad (8)$$

STEP 2: 競合層の出力ベクトル O_i を生成する。

$$O_i \equiv [o_{1i} o_{2i} \cdots o_{ji} \cdots o_{m^2 i}]^T \quad (9)$$

ここで、 m^2 は競合層の総ノード数である。

STEP 3: クラス c に属する図形群に対する出力ベクトルの平均 \bar{O}_c を求める。 \bar{O}_c を以下ではラベルベクトルと呼ぶ。

STEP 4: テスト図形 k の呈示に対して得られる出力ベクトルを O_k とする。

STEP 5: O_k ともっとも近いマハラノビス距離を持つラベルベクトル \bar{O}_c を求め、その時の c を認識クラスとする。

3.3 手書き数字に対する認識実験結果

表 6 に基本 SOM および V1-IT SOM それぞれにおける、テスト用サンプルに対する 1 位から 3 位までの認識率を示す。表 6 より、V1-IT SOM は基本 SOM に比べて高い認識率が得られる事が確認された。このことが

表 6 手書き数字に対する基本 SOM および V1-IT SOM における 1 位から 3 位までの認識率

	Basic SOM	V1-IT SOM
1 位認識率 (%)	78.90	90.34
2 位	91.18	96.34
3 位	94.25	97.94

ら、入力信号の部分的構造を利用した V1-IT SOM において、V1 層による入力信号の変換が、入力信号の分離の容易性を高める作用がある事が認識率の上からも確認された。また、V1-IT SOM は基本 SOM と比較して高いパターン認識性能を持つ事が分かった。

4. む す び

本論文では、大脳視覚野における V1 野及び IT 野の階層性と、それぞれにおける視覚情報処理の性質に着目し、視覚情報の部分的構造をあらかじめ学習させた上で特徴抽出器として用いる V1-IT SOM を提案した。幾何学図形の分類実験では、V1 層は入力信号のクラス内分散をクラス間分散と比較して相対的に低くする働きがある事を示し、V1-IT SOM は基本 SOM と比較してより自然な図形の分類が出来ることを示した。さらに、手書き数字によるパターン認識実験を行ない、V1-IT SOM の基本 SOM に対する有効性を確認した。

今回提案した V1-IT SOM では、予め V1 層に線分あるいは線分と円弧を学習させており、従って V1 SOM の学習結果は、未知の入力集合に対して入力信号の部分構造を必ずしも正確に反映したもとはならない。V1 SOM において入力信号の部分構造を適応的に学習させる手法の提案と実装が今後の課題である。

参 考 文 献

- 1) T. Kohonen, "Self-Organizing Maps" Springer-Verlag Berlin Heidelberg, 1995.
- 2) K. Obermayer, H. Ritter and K. Schulten: "A principle for the formation of the spatial structure of cortical feature maps", Proc. Natl. Acad. Sci. USA, Vol. 87, pp. 8345-8349, 1990.
- 3) Gang Wang, Manabu Tanifuji and Keiji Tanaka "Functional architecture in monkey inferotemporal cortex revealed by in vivo optical imaging" Neuroscience Research, Vol. 32, pp. 33-46, 1998.
- 4) Satoru Kato, Kunihito Yamamori and Susumu Horiguchi, "Three-layered neural model between cortical areas V1 and IT" Proc. ICANN'98, Vol. 1, pp. 1003-1008, 1998.
- 5) 福島邦彦, "神経回路と情報処理" 朝倉書店, 1989.
- 6) Jouko Lampinen and Erkki Oja, "Clustering properties of hierarchical self-organizing maps." Journal of Mathematical Imaging and Vision, Vol. 2, pp. 261-272, 1992.
- 7) P. N. Suganthan, "Hierarchical overlapped SOM's for pattern classification." IEEE Trans. on Neural Networks, Vol. 10, No. 1, pp. 193-196, 1999.