

# 自己組織化マップを用いたパターン認識に関する考察

小森雅和・宮原俊弥<sup>1</sup>

A Consideration of Pattern Recognition using Self-Organizing Map

Masakazu KOMORI and Shunya MIYAHARA<sup>1</sup>

(Accepted October 1, 2013)

**Abstract** A model of self-organizing map called LISSOM(Laterally Interconnected Synergetically Self-Organizing Map) was proposed by Miikkulainen et al. This model is composed of three layers of networks. And it is designed to capture the essential biological processes. Previously, we added a layer which has excitatory afferent connections, excitatory lateral connections and inhibitory lateral connections to this model. Then, we simulated the network for the pattern recognition using supervised learning. In this simulation, new layer's units could began to exhibit selectivity for the pattern to some extent. However, there is a problem that the new layer's units could output from effects of common third layer outputs for different pattern. In this report, we add a new layer which has excitatory afferent connections, inhibitory afferent connections, excitatory lateral connections and inhibitory lateral connections to LISSOM. Then, we simulate the network for the pattern recognition using supervised learning and we consider its simulation results.

**Keywords** [Self-organizing map, LISSOM, Pattern recognition]

## 1 はじめに

人などの脳における視覚情報処理は大変優れないと考えられる。例えば、物を認識する際に大きさが異なったり、変形していたり回転していても対象の特徴を捉え柔軟に認識することが可能である。また、新たな物体であっても学習することにより容易に認識することが可能となる。このような視覚情報処理能力をパターン認識などに工学的に応用することが出来れば大変有用であると考えられる。

ニューラルネットワークによるパターン認識のモデルとしては、パーセプトロン<sup>1)</sup>や、ネオコグニトロン<sup>2)</sup>などが提案されている。単純パーセプトロンは、線形分離不可能な入力パターンに対しては学習ができず、変形や位置ずれにも弱いものとなっている。多層パーセプトロンは、学習したパターンの情

報をネットワーク全体の結合荷重に分散した形で保持しており、新たに学習するパターンを追加する際に最初から学習をやり直す必要があると考えられる。ネオコグニトロンは、ある程度の変形や位置ずれにも対応でき、高い認識率を誇っている。ネオコグニトロンでは、最上位層である認識細胞層のユニット1つが1つのパターンに反応するように学習が行われることから、新しいパターンを追加する際に、認識細胞層のユニットの追加が必要となり、場合によっては細胞面と呼ばれるユニットの集団を追加する必要があり、ネットワークの変更が必要となる。さらに、学習に競合作用を用いることから、最初から学習をやり直す必要があると考えられる。

それに対して、自己組織化マップ(SOM)は、平面上に並べられたユニットが学習により、特定のパターンに選択的に応答するようになり、近くのユニット

もそのパターンに近いものに選択的に応答するようになるという特徴を持っている。通常、SOMの特定のパターンに対する反応は、ユニット1つではなく、複数のユニットによる集団での反応であり、ユニットの結合荷重は特定のパターンに反応するように学習が行われる。この性質を利用すれば新たなパターンを追加的に学習するのも容易になるのではないかと考えられる。

Laterally Interconnected Synergetically Self-Organizing Map(LISSOM)は、Miikkulainenらによって提案されたモデルであり、視覚経路における視覚情報処理の動作の過程を再現した自己組織化機能を持つモデルである<sup>3)</sup>。このモデルは、3層構造をしており、学習の際に入力に楕円型ガウシアン入力画像などを加えることにより、第3層に入力の線分の傾きにそれぞれ選択的に応答するユニットが形成されるようになっている。実際の脳においても一次視覚野に線分の傾きに選択的に応答する細胞が存在しているという知見もある<sup>4)</sup>。

LISSOMで得られた入力の線分の傾きの選択性による特徴抽出結果を用いることにより、学習可能な柔軟なパターン認識モデルを形成できるのではないかと考えられる。しかしながら、LISSOMは教師なし学習であるため、パターンに選択的に応答する出力が出力層のどの部分であるか決まらない。工学的応用を考えるとこれは好ましくないと考えられる。そこで、著者らはまずLISSOMに興奮性の求心性結合のみを持つ第3層と同様な第4層を付け加え、3つの様々な角度の図形を入力として加えて、図形パターンごとに第4層の特定の領域で選択的に応答するように教師あり学習を行うシミュレーションを行い、考察を行った<sup>5)</sup>。結果としては、図形に対する選択性が現れたが、図形間で共通する第3層の出力部分の影響により、その図形の領域外のユニットの一部にも出力が現れてしまった。

そこで、本報告では、著者らが先に行なったシミュレーション<sup>5)</sup>のネットワークモデルの第3層から第4層への求心性結合を興奮性と抑制性の2種類の結合を持つように変更し、シミュレーションを行い、考察を行った結果について報告する。

## 2 LISSOM モデルの概要

本報告で構成したネットワークモデルは、LISSOMがベースとなっている。そこで、ここではLISSOMモデルについて簡単に述べる。Fig. 1にLISSOMモデルのネットワーク図を示す。LISSOMは3層構造をしており、各層はそれぞれ視覚経路における網膜

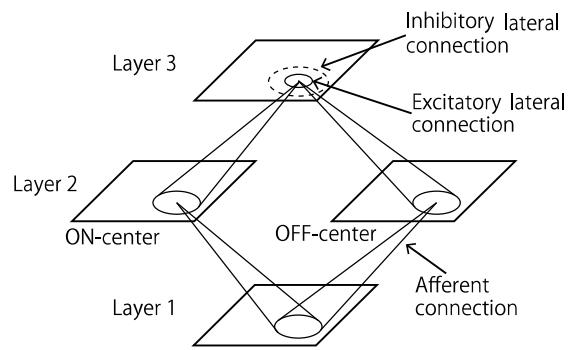


Fig. 1 Architecture of the LISSOM model.

(RTN)、外側膝状体(LGN)、一次視覚野(VI)に対応づけられており、各層には入出力処理を行うユニットがシート状に並べられている。自己組織化における学習は、第2層から第3層への求心性結合と第3層内の側方性結合に対して行われるようになっている。

第1層は、入力層で視覚経路におけるRTNに対応づけられている。出力は、入力そのままを出力するようになっており、通常は0から1までの値を入力するようになっている。方位選択性の自己組織化のシミュレーションの場合には、主に楕円型ガウシアン入力を加えることにより行われる。

第2層は、視覚経路におけるLGNに対応づけられており、Fig. 1に示すように第2層の各ユニットは、第1層の対応する特定の領域である受容野からの入力を受けるようになっている。また、第2層はそれぞれ2つの正規化されたガウシアン関数の差(DoG)によって決定されるON-center、OFF-centerの入力結合荷重を持つ2つの層から構成されている。以下に、第2層の位置(a,b)における第1層の位置(x,y)からの入力の結合荷重 $L_{xy,ab}$ の式を示す。

$$L_{xy,ab} = \frac{\exp\left(-\frac{(x-x_c)^2+(y-y_c)^2}{\sigma_c^2}\right)}{\sum_{uv} \exp\left(-\frac{(u-x_c)^2+(v-y_c)^2}{\sigma_c^2}\right)} - \frac{\exp\left(-\frac{(x-x_c)^2+(y-y_c)^2}{\sigma_s^2}\right)}{\sum_{uv} \exp\left(-\frac{(u-x_c)^2+(v-y_c)^2}{\sigma_s^2}\right)} \quad (1)$$

ここで、 $x_c$ 、 $y_c$ はガウシアン関数の中心位置、 $\sigma_c$ 、 $\sigma_s$ はそれぞれのガウシアン関数の広がりである。 $\sigma_c < \sigma_s$ の時、結合荷重はON-center、 $\sigma_c > \sigma_s$ の時はOFF-centerとなる。第2層の位置(a,b)のユニットの入出力は以下の式によって計算される。

$$\xi_{ab} = \sigma \left( \gamma_L \sum_{xy} L_{xy,ab} \chi_{xy} \right) \quad (2)$$

$$\sigma(s) = \begin{cases} 0 & s \leq \theta_l \\ (s - \theta_l)/(\theta_u - \theta_l) & \theta_l < s < \theta_u \\ 1 & s \geq \theta_u \end{cases} \quad (3)$$

ここで、 $\chi_{xy}$  は第1層の出力、 $\gamma_L$  は入力の強さを調整する係数である。出力関数である式(3)は、シグモイド関数の区分線形近似関数で、 $\theta_u$ 、 $\theta_l$  はそれぞれ、上と下のしきい値となっている。

第3層は視覚経路におけるV1に対応づけられている。各ユニットへの入力は特定の範囲の第2層のユニットおよび第3層のユニットからの入力となっている。学習の進行により、興奮性の側方性結合は結合範囲が徐々に小さくなるように変更が行われる。第3層のユニットは側方性結合を持つことから、出力がある程度安定するまで以下に述べるような方法で複数回入出力の計算を行うようになっている。まず、以下のように求心性の入力による計算を行う。

$$s_{ij} = \gamma_A \left( \sum_{ab \in ON} AON_{ab,ij} \xi_{ab} + \sum_{ab \in OFF} AOFF_{ab,ij} \xi_{ab} \right) \quad (4)$$

$$\eta_{ij}(0) = \sigma(s_{ij}) \quad (5)$$

ここで、 $s_{ij}$  は第3層の位置  $(i, j)$  のユニットの求心性入力の総和、 $\gamma_A$  は入力の強さを調整する係数、 $AON_{ab,ij}$ 、 $AOFF_{ab,ij}$  はそれぞれ第2層のON-center、OFF-centerの位置  $(a, b)$  からの入力に対する結合荷重であり、 $\eta_{ij}(0)$  はユニットの最初の出力を表す。また、式(5)の関数  $\sigma$  は式(3)と同様の式である。次に、側方性結合による入力を考慮した次のような入出力の計算を複数回行う。

$$\eta_{ij}(t) = \sigma \left( s_{ij} + \gamma_E \sum_{kl} E_{kl,ij} \eta_{kl}(t-1) - \gamma_I \sum_{kl} I_{kl,ij} \eta_{kl}(t-1) \right) \quad (6)$$

ここで、 $\eta_{ij}(t)$  は  $t$  回目の入出力の計算によるユニットの出力、 $\eta_{ij}(t-1)$  は  $t-1$  回目の出力であり、 $\gamma_E$ 、 $\gamma_I$  はそれぞれ興奮性、抑制性の側方性結合による入力の強さを調整する係数、 $E_{kl,ij}$ 、 $I_{kl,ij}$  は位置  $(k, l)$  からの入力に対する興奮性、抑制性の側方性結合荷重である。出力安定化のための計算回数は学習の進行に伴い変更されるようになっている。

先に述べたように、LISSOMの学習は、第3層の求心性結合および興奮性、抑制性の側方性結合に対して行われ、すべて同じ学習則が適用されるようになっている。学習は正規化機能を持つヘップの学習則によって行われる。

$$w'_{pq,ij} = \frac{w_{pq,ij} + \alpha X_{pq} \eta_{ij}}{\sum_{uv} (w_{uv,ij} + \alpha X_{uv} \eta_{ij})} \quad (7)$$

ここで、 $w_{pq,ij}$ 、 $w'_{pq,ij}$  はそれぞれ位置  $(p, q)$  から位置  $(i, j)$  への更新前と更新後の結合荷重、 $X_{pq}$  は位置  $(p, q)$

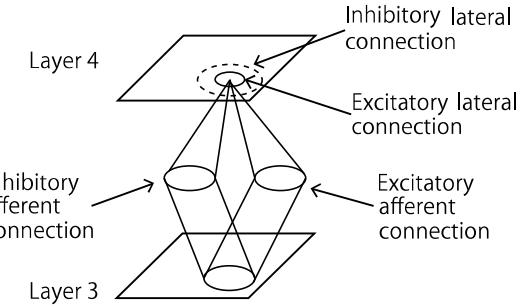


Fig. 2 Architecture of the layer 4.

からの入力、 $\alpha$  は学習係数である。

### 3 LISSOM モデルへの第4層の追加

はじめにでも述べたが、著者らは以前、LISSOMに興奮性の求心性結合のみを持つ第3層と同様な第4層を付け加え、3つの様々な角度の図形を入力として加えて、図形パターンごとに第4層の特定の領域で選択的に応答するように教師あり学習を行うシミュレーションを行った<sup>5)</sup>。しかしながら、図形に対する選択性が現れたが、図形間で共通する第3層の出力部分の影響により、その図形の領域外のユニットの一部にも出力が現れてしまった。これは、第3層から第4層への求心性結合が1つであり興奮性結合であることから、異なる図形入力でも、共通する部分に関する出力が影響してその図形の領域外のユニットにも出力が出てしまったと考えられる。そこで、本報告では、第3層から第4層への求心性結合を興奮性と抑制性の2つとし、抑制性結合により異なる図形間の共通する部分の出力の影響が小さくなるように学習する第4層を付け加えた。Fig. 2に第4層のモデル図を示す。

第4層の各ユニットは、他の層のユニットと同様に第3層の特定の範囲内のユニットからの入力を持つようになっている。また、各ユニットは先ほど述べた通り興奮性と抑制性の求心性結合を持ち、第3層の入力の範囲は同じものとなっている。第4層の側方性結合は、第3層のものと同様なものとなっている。第4層の入出力の計算は、第3層と同様に側方性結合を持っていることから複数回の計算が必要となっている。まず、以下のように求心性の入力による計算を行う。

$$u_{ij} = \gamma_{A2} \left( \sum_{ab \in E} AE_{ab,ij} \eta_{ab} - \sum_{ab \in I} AI_{ab,ij} \eta_{ab} \right) \quad (8)$$

$$\delta_{ij}(0) = \sigma(u_{ij}) \quad (9)$$

ここで、 $u_{ij}$  は第4層の位置  $(i, j)$  のユニットの求心性入力の総和、 $\gamma_{A2}$  は入力の強さを調整する係数、

Table 1 Simulation parameter of the LISSOM simulation.

Layer1	
Number of units	77 × 77
Layer2	
Number of units	60 × 60
Radius of the afferent connections $r_l$	9.0
Radius of DoG center Gaussian $\sigma_c$	0.5
Radius of DoG surround Gaussian $\sigma_s$	2.0
Scaling factor for the afferent weights $\gamma_L$	4.6
Layer3	
Number of units	96 × 96
Radius of the afferent connections $r_a$	7
Radius of the initial lateral excitatory connections $r_e$	5
Radius of the lateral inhibitory connections $r_i$	11
Scaling factor for the afferent weights $\gamma_A$	1.0
Scaling factor for the lateral excitatory weights $\gamma_E$	0.9
Scaling factor for the lateral inhibitory weights $\gamma_I$	0.9
Initial value for the afferent learning rate $\alpha_A$	0.0035
Initial value for the lateral excitatory learning rate $\alpha_E$	0.0330078
Lateral inhibitory learning rate $\alpha_I$	0.00466167
Initial value for the number of settling iterations	9
Other	
Initial value for the lower threshold of the output function $\theta_l$	0.083
Initial value for the upper threshold of the output function $\theta_u$	0.633

$AE_{ab,ij}$ 、 $AI_{ab,ij}$  はそれぞれ第 3 層の位置  $(a, b)$  からの入力に対する興奮性および抑制性結合荷重であり、 $\delta_{ij}(0)$  はユニットの最初の出力を表す。また、式(9)の関数  $\sigma$  は式(3)と同様の式である。次に、側方性結合による入力を考慮した次のような入出力の計算を複数回行う。

$$\delta_{ij}(t) = \sigma \left( u_{ij} + \gamma_{E2} \sum_{kl} E2_{kl,ij} \delta_{kl}(t-1) - \gamma_{I2} \sum_{kl} I2_{kl,ij} \delta_{kl}(t-1) \right) \quad (10)$$

ここで、 $\delta_{ij}(t)$  は  $t$  回目の入出力の計算によるユニットの出力、 $\gamma_{E2}$ 、 $\gamma_{I2}$  はそれぞれ興奮性、抑制性の側方性結合による入力の強さを調整する係数、 $E2_{kl,ij}$ 、 $I2_{kl,ij}$  は位置  $(k, l)$  からの入力に対する興奮性、抑制性の側方性結合荷重である。出力安定化のための計算回数も第 3 層と同様に学習の進行に伴い変更されるようになっている。

第 4 層の学習は、興奮性および抑制性の求心性結合のみ教師あり学習を行うようになっている。興奮性および抑制性の側方結合に関しては、第 3 層の学習則式(7)と同じものが適用される。求心性結合に関しては、学習則は以下に示すような式(7)の正規化機能を持つヘップの学習則に教師信号による学習係数  $\beta_{ij}$  をかけたものとした。

$$w'_{pq,ij} = \frac{w_{pq,ij} + \alpha \beta_{ij} X_{pq} \eta_{ij}}{\sum_{uv} (w_{uv,ij} + \alpha \beta_{ij} X_{uv} \eta_{ij})} \quad (11)$$

$$\beta_{ij} = \begin{cases} \beta_{in} & (i, j) \in D_p \\ \beta_{out} & \text{other} \end{cases} \quad (12)$$

ここで、式(12)の  $(i, j) \in D_p$  は、入力図形が  $p$  の時に、第 4 層の位置  $(i, j)$  のユニットが入力図形  $p$  に対

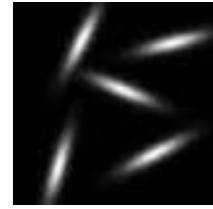


Fig. 3 An input example of the LISSOM simulation.

応する領域  $D_p$  に入っていることを示す。また、 $\beta_{in}$ 、 $\beta_{out}$  は興奮性の結合の場合は、それぞれ  $\beta_{in} = 1.0$ 、 $\beta_{out} = 0.0$ 、抑制性の結合の場合は、 $\beta_{in} = 0.0$ 、 $\beta_{out}$  は 0 から 1 までの間の値としている。

この学習則によって、入力図形と一致する領域のユニットの興奮性の求心性結合は入力に合わせる形で強化され、一致しない入力図形に対して反応してしまった場合には抑制性の求心性結合が入力に合わせる形で強化されることとなる。このことによって、図形間で共通する第 3 層の出力部分の第 4 層のユニットに対する影響が抑えられるのではないかと考えられる。また、抑制性の求心性結合における  $\beta_{out}$  が 1 より小さな値になっているのは、学習の際に抑制性の入力が強く効きすぎてしまうとユニットの出力がなくなってしまい、学習が行われなくなってしまうのを防ぐためである。

#### 4 シュミレーション

本報告で追加した第 4 層は、LISSOM の第 3 層の出力を利用していることから、まず LISSOM のみの学習のシミュレーションを行った。そこで、まず最初に LISSOM のシミュレーション結果について述べる。Table 1 に、Miikkulainen らの文献 3)を参考に決定した LISSOM のパラメータを示す。入力も同様に文献 3)を参考に、以下の式により 5 つの橿円型ガウジアン入力をランダムな角度、位置に加えた。

$$\chi_{xy} = \max_k \exp \left( - \frac{[(x - x_{c,k}) \cos(\phi) - (y - y_{c,k}) \sin(\phi)]^2}{\sigma_a^2} - \frac{[(x - x_{c,k}) \sin(\phi) + (y - y_{c,k}) \cos(\phi)]^2}{\sigma_b^2} \right) \quad (13)$$

ここで、 $k = 5$  であり、 $x_{c,k}$ 、 $y_{c,k}$  は  $k$  番目の橿円型ガウジアンの中心座標である。また、 $\sigma_a = 13.3$ 、 $\sigma_b = 2.85$  とした。Fig. 3 に実際の入力例を示す。以上の設定で、10000 回の学習のシミュレーションを行った。シミュレーションの際には、文献 3)と同様に、学習が進むにつれ、興奮性の側方性結合の範囲  $r_e$  と学習係数  $\alpha_E$ 、出力関数の  $\theta_l$ 、 $\theta_u$ 、求心性結合の学習係数  $\alpha_A$  及び第 3 層の入出力の計算回数が変更されるように

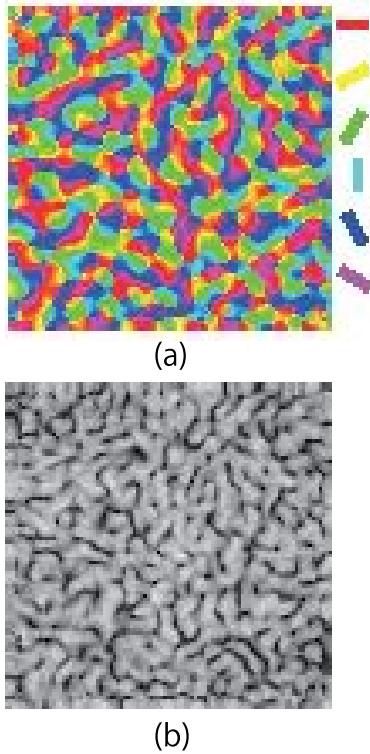


Fig. 4 Orientation map and orientation selectivity.  
(a) Orientation map. (b) Orientation selectivity.

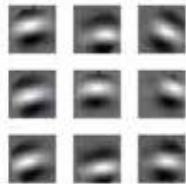


Fig. 5 Examples of the layer 3 afferent weights.

した。

Fig. 4 に文献 3) を参考に作成したシミュレーション後の第3層の方位選択性マップ、Fig. 5 に ON-center、OFF-center からの求心性結合の差分をとった結果の一例を示す。方位選択性マップの作成の際には、幅 2 ドットの線分を利用したことから、ガウシアン入力のようになだらかに輝度値が変化しないので第2層の入力が強くなってしまう。そこで、入力の強さを調整する係数  $\gamma_L$  を 0.92 とした。Fig. 4(a) が方位選択性マップで、色でそのユニットの選択性を示している。Fig. 4(b) はそのユニットの選択性の度合いを示した結果で白色であるほど選択性が高いことを示している。Fig. 4 および Fig. 5 を見てわかるように LISSOM の方位選択性獲得のシミュレーションが再現できていることがわかる。

本報告では、以上の LISSOM のシミュレーション結果を用いて、LISSOM に第4層を追加して、3つの

Table 2 Simulation parameter of the layer 4.

Number of units	$48 \times 48$
Radius of the afferent connections $r_{a2}$	45
Radius of the initial lateral excitatory connections $r_{e2}$	5
Radius of the lateral inhibitory connections $r_{i2}$	11
Scaling factor for the afferent weights $\gamma_{A2}$	8.388
Scaling factor for the lateral excitatory weights $\gamma_{E2}$	0.9
Scaling factor for the lateral inhibitory weights $\gamma_{I2}$	0.9
Initial value for the afferent learning rate $\alpha_{A2}$	0.0035
Initial value for the lateral excitatory learning rate $\alpha_{E2}$	0.0330078
Lateral inhibitory learning rate $\alpha_{I2}$	0.00466167
Initial value for the number of settling iterations	9
Initial value for the lower threshold of the output function $\theta_{l2}$	0.0
Initial value for the upper threshold of the output function $\theta_{u2}$	0.55

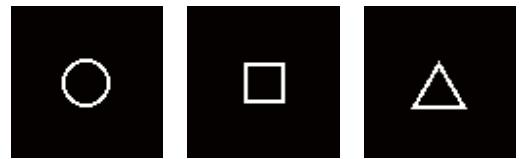


Fig. 6 Input patterns of the layer 4 simulation.

図形を用いてシミュレーションを行った。Table 2 に第4層のパラメータを示す。求心性結合の結合半径は、入力図形に対する第3層の出力が収まるよう広く取ることとした。また、第4層のユニットの入力は抑制性の求心性結合を持つことと、求心性結合の結合半径が広いことから、学習により結合荷重が正規化された際に入力値が非常に小さくなることから、 $\theta_{l2}$ 、 $\theta_{u2}$  の初期値は、それぞれ 0.0、0.55 とし、 $\gamma_{A2} = 8.388$  とした。また、学習のシミュレーションの際には、LISSOM のシミュレーションと同様の変更割合で、学習が進むにつれ、興奮性の側方性結合の範囲  $r_{e2}$  と学習係数  $\alpha_{E2}$ 、出力関数の  $\theta_{l2}$ 、 $\theta_{u2}$ 、求心性結合の学習係数  $\alpha_{A2}$  及び第4層の入出力の計算回数が変更されるようにした。抑制性の求心性結合の学習で使用する  $\beta_{out}$  は 1000 回までは 0.3 として、それ以降は 0.8 とするようにした。これは、学習の初期の段階において、抑制性結合の学習の影響が強いと、入力に対しての第4層のユニットの出力が出ず、学習がなかなか進まないことがあるからである。これを回避するために、学習のシミュレーションではこのような方法を取ることとした。入力は、Fig. 6 に示すような円、四角、三角の図形を入力の中心から  $x$  軸、 $y$  軸にそれぞれ  $\pm 2$  ドットの範囲でランダムにずらしながらランダムに加え、10000 回の学習を行った。また、四角、三角に関してはランダムな角度で加えるようにした。学習の際には、Fig. 7 に示すように、各図形が出力すべき第4層の領域を設定し、式(11) および式(12) にしたがって学習を行った。

Fig. 8 に、学習のシミュレーションが終了した後に、中央に角度 0° で各図形を入力した際のシミュレ

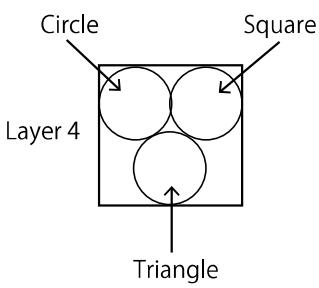
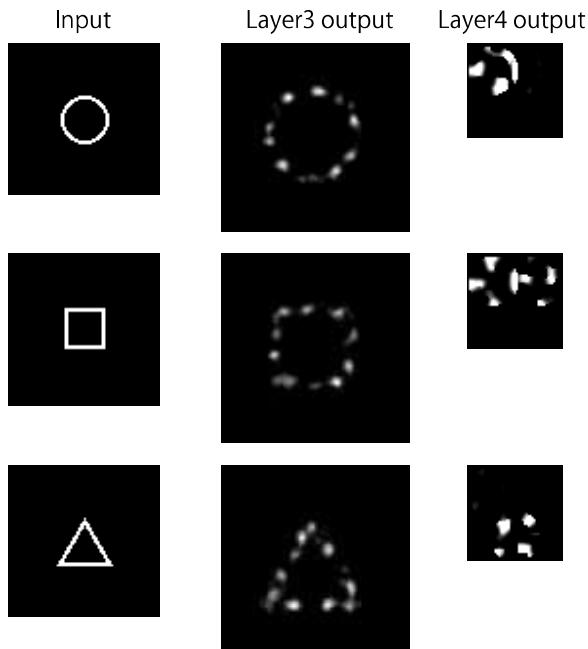


Fig. 7 Target area of the learning.

Fig. 8 Examples of the simulation result ( $0^\circ$ ).

ーション結果を示す。円と三角に関しては、非常に弱い出力が対象領域外で少し出てしまったが、対象領域に強い出力が現れた。しかしながら、四角に関しては、円の対象領域にも強い出力が現れてしまった。学習のシミュレーションでは、円と四角の対象領域には重なりがあるので、第4層の上部中央には双方の図形に対する出力が現れるが、その他の領域に関しては、第3層の出力で多数の共通する出力部分が見られることから、その影響ではないかと考えられる。特に、学習のシミュレーションにおいて図形の種別は等確率で選択しており、円に関しては図形の回転の必要がないため興奮性の求心性結合の学習による強化が他の図形より強くなつたことが影響しているのではないかと考えられる。

Fig. 9に同じ位置に角度を変えて図形を入力した時の一例を示す。Fig. 9(a)は $50^\circ$ の角度で四角を入力した時の結果である。第4層の出力を見てわかるよ

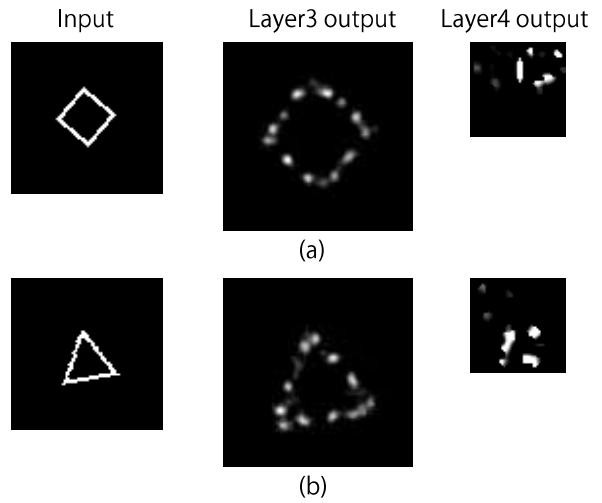


Fig. 9 Examples of the simulation result.  
(a) Square( $50^\circ$ ). (b) Triangle( $10^\circ$ ).

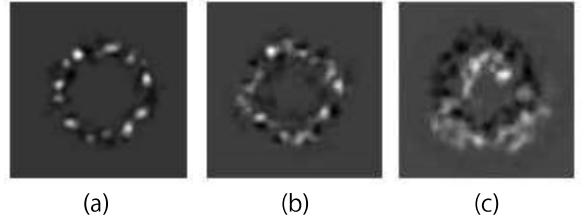


Fig. 10 Examples of the layer 4 afferent weights.  
(a) Circle. (b) Square. (c) Triangle.

うに、円の対象領域の出力が少なくなっているのがわかる。四角の入力に関しては、この角度が円の対象領域での出力が最も少ない結果であった。Fig. 8 の円入力の第3層の出力と見比べてみると、共通する部分がいくつか見られるが、それ以外の部分も多数あり、その部分の抑制性の求心性結合と出力計算の際のしきい値の作用からこのような結果が得られたと考えられる。Fig. 9(b)は、三角を $10^\circ$ の角度で入力した時の結果である。三角の入力に関しては、この角度が最も三角の対象領域外で出力が現れている例である。三角は、Fig. 8 の円や四角の第3層の出力と比較してもわかるように、共通する部分が少なくなつておらず、そのことから比較的良い結果が得られたのではないかと考えられる。

Fig. 10に、学習のシミュレーションで得られた興奮性と抑制性の求心性結合の差をとった結果の一例を示す。Fig. 10で(a)は円の領域のユニットの結果で、(b)、(c)はそれぞれ四角、三角の領域のユニットの結果である。図で、白の部分は興奮性の求心性結合が抑制性のものより強いことを表しており、黒い部分は抑制性の求心性結合が強いことを表している。Fig. 10(a)では、他の結果と比較して円入力に対

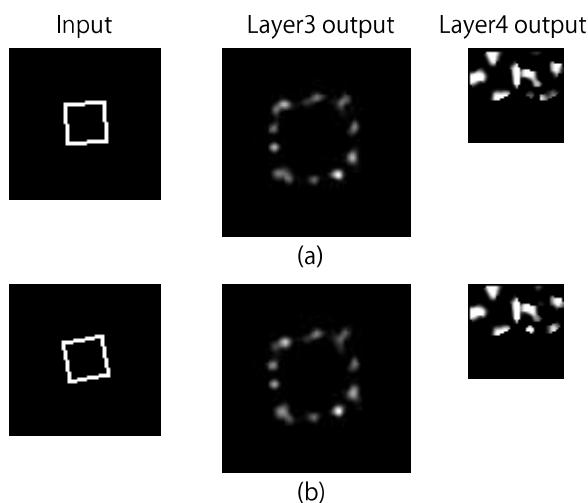


Fig. 11 Example of the simulation result.

(a) Square(5°). (b) Square(10°).

する第3層の出力に一致する部分で興奮性の求心性結合が強くなっていることが見て取れる。これは、先に述べたように、円に関しては回転が必要ないことから、興奮性の求心性結合の学習による強化の影響が強くなったことによるものと考えられる。これに対して、Fig. 10(b)(c) は、それほど興奮性の求心性結合の影響が強くなく、Fig. 10(c) は対応領域が三角であるということから、特に抑制性の求心性結合の影響が強く出ているのが見て取れる。

以上のことから、抑制性の求心性結合を導入したことによる効果がある程度見られたと考えられる。しかしながら、第3層の共通する部分が多く、それ以外の部分が少い場合は、余り効果がないということが言えると考えられる。

次に、入力図形の角度を変えていくと第4層の出力がどのように変化していくかのシミュレーションを行った。Fig. 11 に、四角を中心で  $5^\circ$  と  $10^\circ$  の角度で入力した時の結果を示す。結果を見てわかるように、入力角度の変化にしたがって第4層の出力が徐々に変化していくのがわかる。また、第3層の出力も図形の入力角度に対して徐々に変化していくのがわかる。これは、第3層と第4層が興奮性および抑制性の側方性結合を持っていることから、あるユニットが出力すると興奮性の側方性結合により周辺のユニットも出力しやすくなり、遠くのユニットは抑制性の側方性結合の影響により出力しにくくなる。そのため、各ユニットの周辺にそのユニットが選択性をもつ入力パターンに近い入力パターンに選択性を持つユニットが集まるように学習が行われるからである。この性質と複数のユニットの集団である第4層の領域という形で図形の識別に利用する

ことにより、様々な角度の図形に対応できるのではないかと考えられる。

## 5 おわりに

著者らは、以前、LISSOM に興奮性の求心性結合のみを持つ第3層と同様な第4層を追加し、3つの図形を様々な角度で入力として加えて、図形パターンごとに第4層の特定の領域で選択的に応答するように教師あり学習に基づいたシミュレーションを行ったが、図形間で共通する第3層の出力部分の影響により、その図形の領域外のユニットの一部にも出力が現れてしまった。そこで本報告では、LISSOM に興奮性と抑制性の求心性結合を持つ LISSOM の第3層と同様な第4層を追加し、3つの図形を様々な角度で入力として加えて、図形パターンごとに第4層の特定の領域で選択的に応答するように教師あり学習を用いてシミュレーションし、考察を行った。

抑制性の求心性結合の効果により、ある程度異なる図形に共通する第3層の出力による第4層の図形の対象領域外のユニットの出力が抑えることができたと考えられる。しかし、第3層の共通する部分が多く、それ以外の部分が少ない場合は、余り効果がなかった。

本報告では、LISSOM に第4層を追加することによって、第3層で得られた図形入力に対する線分の傾き情報をそのまま使ってシミュレーションを行ったが、図形の部分的特徴を抽出する自己組織化ネットワークの層を第3層と第4層の間に挿入することによって、更に良い結果が得られるのではないかと思われる。これは、部分的特徴を抽出するために、第3層の出力のより狭い範囲を見ることになることから、学習の際に結合荷重を正規化しても第3層の出力の共通部分以外のわずかに違う部分の影響がより強くなることが考えられるからである。

図形の入力角度を変えた場合のシミュレーションについては、側方性結合による効果により、角度が変化していくとその図形の第4層の対象領域のユニットの出力が徐々に変化していくという結果が得られた。この性質と複数のユニットの集団である第4層の領域という形で図形の識別に利用することにより、パターン認識に応用する際には様々な角度の図形に対応できるのではないかと考えられる。

## 参考文献

- 1) 坂和正敏, 田中雅博: ニューロコンピューティング入門, 森北出版, 1997

- 2) 福島邦彦:神経回路と情報処理, 朝倉書店, 1989
- 3) Risto Miikkulainen, James A. Bednar, Yoonsuck Choe,  
Joseph Sirosh: Computational Maps in the Visual Cortex,  
Springer, 2005
- 4) 内川恵二, 篠森敬三: 視覚 I 視覚系の構造と初期機能, 朝倉書店, 2007
- 5) 宮原俊弥, 小森雅和: LISSOM を用いたパターン認識の学習法に関する考察, 第 18 回高専シンポジウム in 仙台講演要旨集, p.164, 2013.1