

Aperture問題のルール抽出による一解析法

An Analysis Method of Aperture Problems by Acquiring its Rules

林 勲* 前田 利之**
Isao Hayashi* Toshiyuki Maeda**

* 阪南大学 大学院 企業情報研究科
Graduate School of Corporate Information, Hannan University

* 福山平成大学 経営学部
Faculty of Management, Fukuyama Heisei University

Abstract The aperture experiments are significant data for discussing visual models. A circle aperture has been displaying by computer and a linear line inside there is moving. When the other line-moving of circles at the both sides of the center circle is recognized, the perceptual grouping for changing orientation of the line-moving at the center circle might be constructed. On the other hand, a lot of visual neural networks have been proposed. Prof. S. Grossberg mentioned two kinds of significant mechanism are needed for the visual models in his paper, which are the folded feedback mechanism, and the horizontal connections with excitatory and inhibitory signals. In this paper, the TAM Network (Topographic Attentive Mapping Network) based on a biologically-motivated neural network model is applied to the aperture problems. We discuss the necessity of feedback mechanism of the TAM network and show its usefulness through the fuzzy rules since the fuzzy rules are acquired from the TAM Network.

キーワード： 視覚, Aperture 問題, 知覚的グルーピング, ニューラルネットワーク, ファジィルール
Keywords: Vision, Aperture Problems, Perceptual Grouping, Neural Networks, Fuzzy Rules

1 はじめに

1980年代半ばからのニューラルネットワーク研究にコネクショニズムのアプローチがある[1]。ニューラルネットワークが適用される分野での有効性や有用性を議論するのではなく、人間の生理学的、認知心理学的な機能の解析を主眼とする。したがって、データ解析の精度よりも構築モデルの正当性が議論の対象となる。

特に、視覚系モデルとして多くの有用なニューラルネットワークが提案されている。人間の視覚系では、網膜からの光情報は桿体細胞や錐体細胞の光受容細胞からガングリオン細胞に入り、外側膝状体を介して第1視覚野(V1)に入力され、コラム構造で方位や方向、色などが識別処理された後、第2視覚野(V2)以降では、対象の形状は側頭連合野で認識され、対象との奥行きや距離感は頭頂連合野で認識される[2]。有用な視覚系ニューラルネットワークとして、BCS[3]、ネオコグニトロン[4]、ARTMAP[5]、fuzzy ARTMAP[6]、TAM[7]、Visual Cortex Model[8]などがある。特に、GrossbergのVisual Cortex Modelは、外側膝状体からV2までを詳細に概念化しており、視覚系モデルを構築する際の指針となっている。Grossbergはその論文の中で、知覚的グルーピング[2]を認識するための視覚系モデルの必要機能として、次の2つの挙げている。

1. 折り返しフィードバック機能

2. 水平細胞間の興奮性・抑制性信号

知覚的グルーピングとは、視覚対象が共通的法則や運動同時性を有する際に、個別の対象が組織化され視覚される現象を言う。例えば、図1にその一例を示す。左図では知覚的グルーピングは認識されないが、右図では、横方向の3本の直線がそれぞれ知覚的グルーピングとして認識されている。知覚的グルーピングは、錯視やAperture問題において視覚系モデルを解析する際の重要な対象となる。

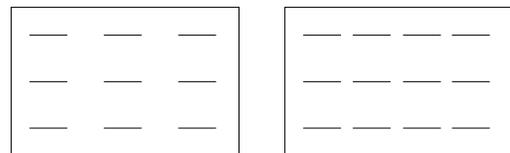


Figure 1: Perceptual Grouping

本研究では、Aperture問題として、コンピュータディスプレイ上で円内を移動する線分の運動知覚の心理実験[9],[10]をとりあげ、TAMネットワークによりその実験データを解析して、視覚モデルとしての有用性を議論する。TAMネットワーク(Topographic Attentive Mapping Networks)は、網膜の機能を模擬した入力層、外側膝状体の学習を行うカテゴリー層、第1視覚野(V1)

のコラム構造である出力層からなる。出力値と教師値に差がある場合、V1 から外側膝状体への選択的フィードバック信号により、共振学習とノードの増加、ピジランス・パラメータによる抑制性学習を行う。また、過剰学習となる場合の抑制機能として結合とノードのブルーニング機能が付加された [11],[12]。このブルーニング機能により TAM ネットワークの構造からファジィルールを抽出できる。

本研究では、まず、コンピュータディスプレイに円形の小窓を表示し、円内の線分の移動に伴う運動方向を知覚する実験を行う。岡田ら [9],[13] は、この実験において運動方向の知覚と線分の呈示時間との関連を解析し、運動方向検出の局所性と情報の拡散に基づくモデルを提案して、繰り返しフィードバック機能の必要性を議論している。ここでは、同じ実験を行った結果、岡田らの報告の一部を支持する結果が得られたことを報告する。次に、TAM ネットワークにより運動知覚の正解率と抽出されたファジィルールを用いて、TAM ネットワークの視覚モデルとしての有用性を議論する。最後に、フィードバック機能の必要性を議論する。

本研究を通して、線分の運動方向の知覚は、円の半径や円間距離の規則性に依存しており、TAM ネットワークから抽出されたファジィルールはその規則性をよく表現していると言えた。

2 Aperture 問題

Aperture 実験の構成を図 2 に示す。実験では、コンピュータのディスプレイの中央に 1 個の円形の小窓が表示されており、円内を線分が右下から左上方向に移動する。移動途中でその小窓の両側に 45° の傾きを持った別の 2 つの円形の小窓が表示され、その両小窓内でも線分が移動する。ただし、これらの両端の線分は垂直上方方向に移動する。これらの 3 つの線分が連続していると知覚された場合には、中央の小窓内の線分の運動方向は、垂直上方方向に方位を変更したように知覚される。この運動方向の変更は知覚的グルーピングと言える。岡田ら [9],[13] は、この知覚的グルーピングに対して、線分の呈示時間が長いほど知覚されやすいことを示し、運動方向検出の局所性と情報の拡散に基づくモデルを提案して、繰り返しフィードバック機能の必要性を議論している。

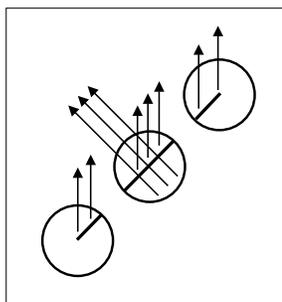


Figure 2: Aperture Experiment

本研究では、同様な実験を行った。ただし、線分の

運動方向の知覚は、被験者とディスプレイ画面との距離、円の半径、円間の距離に依存していると考えられる。この規則性を確認するため、被験者とディスプレイ画面との距離を 50cm 程度に一定に保ち、円の半径と円の中心間距離との比率を一定とした場合と一定としない場合との 2 種類の実験を行い、それらの知覚の認識率を得た。

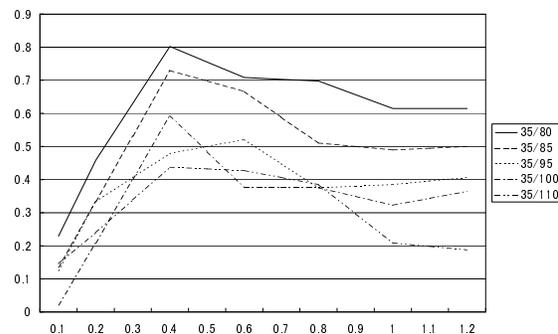


Figure 3: Reaction of Subjects (1)

まず、比率が一定でない実験を行った。3 つの小窓の条件を (円の半径 (mm), 中心間距離 (mm)) = (35,80), (35,85), (35,95), (35,100), (35,110) とし、20 代前半の 4 名を被験者として、呈示時間を 0.1s, 0.2s, 0.4s, 0.6s, 0.8s, 1.0s, 1.2s と変化させた場合の線分の運動方向の知覚の認識率を調べた。各被験者には、小窓の各条件と呈示時間の組み合わせで 12 回の運動方向の知覚の有無を確認して回答を得た。被験者ごとに合計 420 回の回答を 1 試行の実験とし、1 週間後に再度同じ実験を行い、被験者 4 名に対する 2 回の試行の全回答数 3,360 回の認識率を計算した。結果を図 3 に示す。結果では、岡田らが指摘した線分の運動方向の呈示時間の依存性の一部を支持し、各実験条件ごとに単峰的に認識率が最大となる呈示時間が存在することが確認された。結果では、各被験者にとって、それぞれの実験条件で知覚が認識されやすい呈示時間が存在した。また、この実験では円の半径は一定としているので、半径と中心間距離との依存性から、円の中心間距離が大きくなる場合、知覚の認識度は低下することがわかる。さらに、他の実験から得た知見で、認識されやすい呈示時間は加齢とともに遅くなる傾向があることが確認できた。

2 番目の実験として、円の半径と中心間距離との比率を一定とした実験を行った。実験条件を円の半径 (mm)/中心間距離 (mm)=0.38 として、(円の半径, 中心間距離) = (23,60), (31,80), (35,90), (39,100), (47,120) とした。実験では、20 代前半の 4 名の被験者に対して、呈示時間を 0.1s, 0.2s, 0.4s, 0.6s, 0.8s, 1.0s, 1.2s と変化させた場合の呈示時間に対する線分の運動方向の知覚の認識率を調べた。最初の実験と同様に、各被験者に小窓の各条件と呈示時間の組み合わせで 12 回の運動方向の知覚の有無を確認して回答を得て、被験者 4 名に対する 1 回の試行の全回答数 1,680 回の認識率を計算した。結果を図 4 に示す。(円の半径, 中心間距離) = (23,60) の場合を除き、認識率がほぼ同じ挙動を示していることがわかる。これにより、半径と中心間距離とが一定

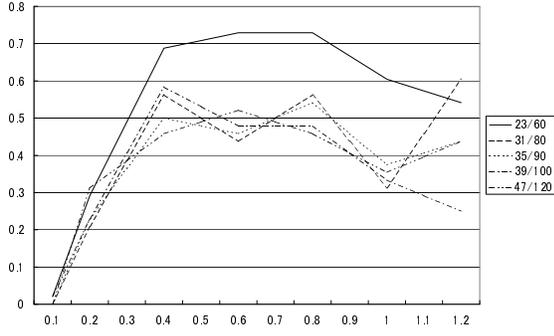


Figure 4: Reaction of Subjects (2)

の場合には、同じ知覚が認識できると仮定できる [14] .

3 TAM ネットワーク

TAM ネットワークの構造を図 5 に示す . カテゴリー層では、属性ノード f_i への分布データ f_{ih} と学習パラメータ w_{jih} との活性値 x_{ji} を計算し、出力層への出力 y_j を得る .

$$x_{ji} = \frac{\sum_{h=1}^L f_{ih} w_{jih}}{1 + \rho^2 b_{ji}} \quad (1)$$

$$y_j = \prod_{i=1}^M x_{ji} \quad (2)$$

ただし、 ρ はビジランス・パラメータ、 b_{ji} は抑制パラメータである .

TAM ネットワークの出力値 K は次式より得られる .

$$K = \{k | \max_k z_k\} \quad (3)$$

$$z_k = \sum_{j=1}^N y_j p_{jk} \quad (4)$$

ただし、 p_{jk} は出力ノードでのカテゴリーに対する学習パラメータである .

いま、 K^* を正しい教師値としよう . K が K^* と一致しない場合には、“選択的注意” を発動し、ビジランス・パラメータ ρ は初期値 $\rho = 0$ から上昇し、 b_{ji} とともにカテゴリーの各ノードの活性値を抑制する . ρ は $z_{K^*}/z_K \geq OC$ の条件が満足されるか最大値になるまで上昇し、最大値になった場合には、カテゴリー層のノードを 1 個分増加させる . ここで、 OC は評価のためのしきい値である .

$$\begin{aligned} &\text{If } z_{K^*}/z_K < OC \text{ then repeat} \\ &\quad (a) \ \rho = \rho + \rho^{(step)} \\ &\quad (b) \ \text{equation (1) - (4)} \\ &\text{until either } z_{K^*}/z_K \geq OC \text{ or } \rho \geq \rho^{(max)} \end{aligned} \quad (5)$$

一方、 $z_{K^*}/z_K \geq OC$ を満足する場合には、学習モードに入る .

$$y_j^* = \frac{\prod_{i=1}^M x_{ji} \times \sum_{k=1}^U z_k^* p_{jk}}{\sum_{j'=1}^N \prod_{i=1}^M x_{j'i} \times \sum_{k=1}^U z_k^* p_{j'k}} \quad (6)$$

$$z_k^* = 1 \text{ if } k = K^*; \ z_k^* = 0 \text{ otherwise} \quad (7)$$

各学習パラメータ w_{jih} 、 p_{jk} 、 b_{ji} を次のように更新する .

$$\Delta w_{jih} = \frac{\alpha y_j^* (f_{ih} - w_{jih})}{\alpha \beta(M) + n_j} \quad (8)$$

$$\Delta p_{jk} = \frac{\alpha y_j^* (z_k^* - p_{jk})}{\alpha + n_j} \quad (9)$$

$$\Delta b_{ji} = b_j^{(rate)} y_j^* (x_{ji} - b_{ji}) \quad (10)$$

$$\Delta n_j = \alpha y_j^* (1 - n_j) \quad (11)$$

$$\beta(M) = \frac{\lambda^{1/M}}{1 - \lambda^{1/M}}, \quad \lambda \in (0, 1) \quad (12)$$

パラメータの調整はネットワークヘデータが逐次的に投入されるごとに行い、全学習データを 1 エポックとして数エポック回数分の学習を行う .

学習後、プルーニングモードに入る . プルーニングモードでは、属性データ f_{si} 、 $s = 1, 2, \dots, R$ と教師値のクラス k からなる R 個の全データ D を学習用データと評価用データに分割する . まず、学習データを用いて入力層の各属性の重要度を次式の情報量 $H(i)$ により計算し、値の大きい属性から順に選択する .

$$H(i) = - \sum_{j=1}^N g_j \sum_{k=1}^U G_{jk} \log_2 G_{jk} \quad (13)$$

$$g_j = \frac{\sum_{s=1}^R x_{jis}}{\sum_{j=1}^N \sum_{s=1}^R x_{jis}} \quad (14)$$

$$G_{jk} = \frac{\sum_{s \in \psi_k} \gamma_{js} \times p_{jk}}{\sum_{s=1}^R \gamma_{js} \times p_{jk}} \quad (15)$$

$$\gamma_{js} = \prod_{i \in I^*} x_{jis} \times x_{jis} \quad (16)$$

ここで、 ψ_k は D でのクラス k をもつデータの集合である .

選択する属性 i^* は次式より求める .

$$i^* = \{i | \max_i H(i)\} \quad (17)$$

プルーニングモードでは、次の 3 つのルールに基づきノード間の結合を削除する .

【プルーニング・ルール 1】

第 j 番目のカテゴリーにおいて、第 k 番目のクラスとの間で次の条件を満足した場合、第 j 番目のカテゴリーと第 k' 、 $k' = 1, 2, \dots, U$ 、 $k' \neq k$ 番目のクラスとの結合を削除する . 同時に、第 j 番目のカテゴリーと第 $i' \notin I^*$ 番目の属性との結合を削除する . ただし、 η はしきい値である .

$$G_{jk} \geq \eta \quad (18)$$

【プルーニング・ルール 2】

第 j 番目のカテゴリーにおいて、次の条件を満足した場合、第 j 番目のカテゴリーと i 及び $i' \notin I^*$ 番目

の属性との結合を削除する．ただし， θ はしきい値である．

$$\frac{1}{R} \sum_{s=1}^R \gamma_{js} < \theta \quad (19)$$

【ブルーニング・ルール 3】

クラス K において，次の条件を満足した場合，第 K 番目のクラスと第 $j' \neq j$ 番目のカテゴリーとの結合を削除する．ただし， $\Gamma_K = \{s \mid K = K^*, K = \max_k \sum_{j=1}^N y_j p_{jk}\}$ であり， ξ はしきい値である．

$$\varphi_{jK} = \frac{\sum_{s \in \Gamma_K} \gamma_{js} \times p_{jK}}{\sum_{j=1}^N \sum_{s \in \Gamma_K} \gamma_{js} \times p_{jK}} \geq \xi \quad (20)$$

TAM ネットワークのアルゴリズムを次に示す．

- [Step 1] TAM ネットワークの出力値 K を得る．
- [Step 2] K が K^* と一致しない場合， $\rho = \rho + \rho^{(step)}$ とする． ρ が最大値になった場合に，カテゴリー層のノードを 1 個分増加させる．
- [Step 3] $z_{K^*}/z_K \geq OC$ を満足する場合，学習モードに入る．
- [Step 4] ステップ 1 からステップ 3 までを繰り返し，学習データを用いて学習する．
- [Step 5] 学習後，ブルーニングモードに入る．学習データに対して，第 i 番目の属性の情報量 $H(i)$ を計算する．
- [Step 6] 次式の i^* を選択し， $I^* = \{i^*\}$ とする．

$$i^* = \{i \mid \max_i H(i)\} \quad (21)$$

- [Step 7] 評価データに対して次の条件を満足した場合に，第 j 番目のカテゴリーと第 $k' \neq k$ 番目のクラスとの結合，第 $i' \notin I^*$ 番目の属性との結合を削除する．

$$G_{jk} \geq \eta \quad (22)$$

- [Step 8] 評価データに対して次の条件を満足した場合に，第 j 番目のカテゴリーと i 及び $i' \notin I^*$ 番目の属性との結合を削除する．

$$\frac{1}{R} \sum_{s=1}^R \gamma_{js} < \theta \quad (23)$$

- [Step 9] 評価データに対して次の条件を満足した場合に，第 K 番目のクラスと第 $j' \neq j$ 番目のカテゴリーとの結合を削除する．

$$\varphi_{jK} \geq \xi \quad (24)$$

- [Step 10] 全結合が削除されたノードを削除する．
- [Step 11] ステップ 6 において，全ての属性が選択されるまで，ステップ 5 からステップ 10 までを繰り返す．

アルゴリズム終了後， I^* により各属性の重要度が表現され， φ_{jk} により各カテゴリーの重要度が表現され，不要な結合やノードが削除されたネットワークが得られる．また，TAM ネットワークの処理過程はファジィ推論と同じであるので，このアルゴリズムにより，属性数，クラス数およびルール数が調整されたファジィルールが獲得できる．

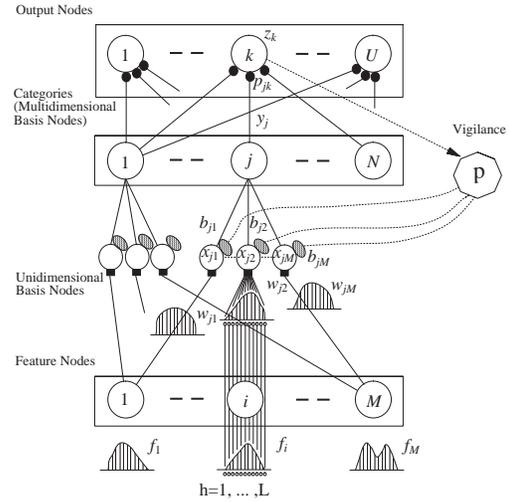


Figure 5: TAM Network

4 TAM ネットワークによる Aperture 問題の解析

ここでは，TAM ネットワークを用いて Aperture 実験によるデータを解析し，TAM ネットワークの有用性を検討した．

まず，図 3 と図 4 の全回答を学習・評価データとして，TAM ネットワークを用いて学習した．学習のためのパラメータ値を次に示す．

$epoch$	$= 1$	$category\ init$	$= 0$
L	$= 5$	$rho\ init$	$= 0.0$
OC	$= 0.8$	$rho\ step$	$= 0.1$
α	$= 0.0000001$	$rho\ max$	$= 100.0$
λ	$= 0.33$	b_j^{rate}	$= 0.01$
η	$= 0.8$	θ	$= 0.03$
ξ	$= 0.5$		

Table 1: Results by TAM Network (1)

		TAM	Pruning TAM
Figure 3	Correctness (%)	62.4	58.8
	Number of Nodes	6	6
Figure 4	Correctness (%)	63.7	60.7
	Number of Nodes	6	1

結果を表 1 に示す．ブルーニング前後の TAM ネットワークの正解率とカテゴリー層のノード数を示した．結果では，正解率は 60% 前後を示した．この精度が良くない理由として，学習データに知覚が認識されるデータと認識されないデータの矛盾するデータが多く含まれているため，TAM ネットワークの学習機能ではそれらに対応できなかった点が挙げられる．また，TAM ネットワークは水平細胞間の興奮性・抑制性学習機能

を持たないので、カテゴリー層でのノード間の競合作用が起こらず、より精度の高い結果が得られなかったことが考えられる。これらは今後の課題としたい。一方、図4の結果に対するブルーニング後のTAMネットワークのカテゴリー層のノード数は、6個から1個に減少した。TAMネットワークのカテゴリー層はファジィルールを表しているので、これは図4を表現するファジィルールの個数がブルーニング機能により減少したことを示している。

ブルーニングによって得られた図3の結果に対するファジィルールを図6に示し、図4のファジィルールを図7に示す。ここで、左下から左奥に向う軸はファジィルール番号を示し、横軸は前件部と後件部を表す。ただし、ファジィルールの前件部の第1属性は円の半径、第2属性は円の中心間距離、第3属性は呈示時間であり、後件部は認識率を表す。なお、前件部のメンバーシップ関数は正規化を施していない。また、後件部が非認識の程度を表すファジィルールも存在するが、ここでは省略し、認識される場合のファジィルールだけを示した。

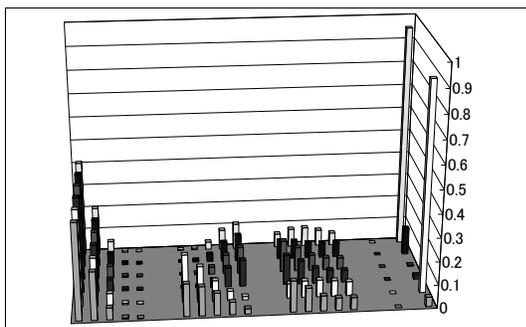


Figure 6: Fuzzy Rules of Figure 3

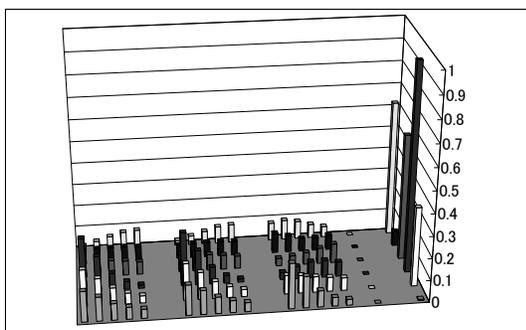


Figure 7: Fuzzy Rules of Figure 4

図3の結果では、呈示時間は0.4sと0.6~0.8s付近で認識率が高くなっている。図6のファジィルールでは、これに対応して、呈示時間を表す第3属性が中程度を表すファジィ集合の第2ルールと第6ルールにおいて後件部の認識率が高くなっており、得られたファジィルールが妥当であることがわかる。一方、図7で

は、後件部の認識率が最も高い第3ルールの第3属性は中程度を表すファジィ集合であり、これは図4での呈示時間が0.6s付近で認識率が高いことを表していると考えられる。

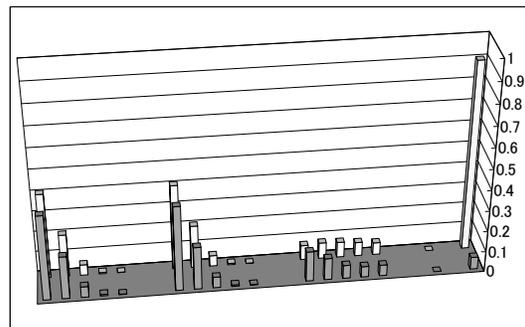


Figure 8: Fuzzy Rules of (35,80)

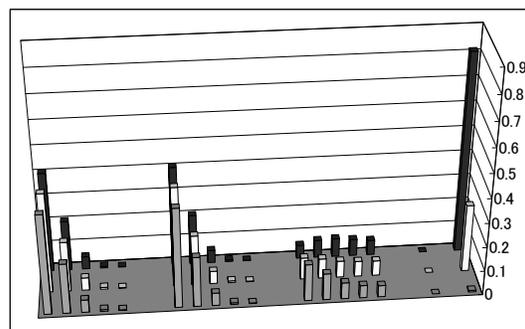


Figure 9: Fuzzy Rules of (35,95)

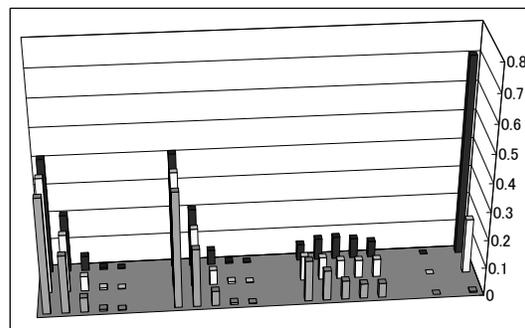


Figure 10: Fuzzy Rules of (35,110)

次に、図3での(円の半径, 中心間距離) = (35,80), (35,95), (35,110)を学習・評価データとして、別々にTAMネットワークにより学習し、ファジィルールを得た。得られたファジィルールを図8~図10に示す。また、図6~図10のそれぞれのカテゴリー層のノード数、得られたファジィルールの数、正解率を表2に示す。

図3の結果では、(円の半径, 中心間距離) = (35,80),

(35,95), (35,110) の認識率はほぼ同じ形状を示している。図 8~図 10 では、これらに対応して、ファジィルールの前件部のファジィ集合はほぼ同じ形状を示している。また、後件部の認識率は、図 8 のファジィルールの場合が最も高く、図 10 のファジィルールが最も低い。図 3 では、中心間距離 = 80 の場合が最も認識率が高く、中心間距離=110 の場合が最も低い。これらの結果から、得られたファジィルールが図 3 の結果を正しく表現していることがわかる。

Table 2: Results by TAM Network (2)

(radius, center distance)	Number of Nodes	Number of Fuzzy Rules	Correctness (%)
Inconstant Case	6	12	62.4
Constant Case	6	12	63.7
(35,80)	2	4	53.3
(35,95)	3	6	62.5
(35,110)	3	6	71.0

最後に、TAM ネットワークのフィードバック機能の必要性を検討するため、ビジランス・パラメータの学習を停止して、正解率 (%) を比較した。図 4 において、評価データを (円の半径, 中心間距離) = (39,100) とし、残りの全てを学習データとした。結果を表 3 に示す。フィードバック機能を持たない TAM ネットワークでは、学習においてノード数が限りなく増大し、学習データに対する正解率を得ることができなかった。したがって、評価データの結果も得ることができなかった。一方、フィードバック機能を持つ TAM ネットワークでは、プルーニング後の評価データに対する正解率が向上し、ノード数も減少した。

Table 3: Results by TAM Network (3)

		TAM	Pruning TAM
with Feedback	Learning Data (%)	62.9	62.9
	Number of Nodes	6	6
	Checking Data (%)	55.4	66.1
	Number of Nodes	6	1
without Feedback	Learning Data (%)	—	—
	Number of Nodes	over 1000	over 1000
	Checking Data (%)	—	—
	Number of Nodes	—	—

5 おわりに

TAM ネットワークを用いて、Aperture 実験における知覚的グルーピングのデータ解析を行った。今後、より精度の高いモデルを得るため、水平細胞間の興奮性・抑制性の機能を TAM ネットワークに付加する必要がある。

なお、本研究を遂行するに際し、Aperture 実験で協力頂いた阪南大学経営情報学部の月田君、橋渡君、槇島君、吉澤君、親泊君に感謝申し上げます。

参考文献

- [1] 川人 光男：“脳の計算理論”，産業図書 (1996)
- [2] 三上 章允：“視覚の進化と脳”，朝倉書店 (1993)
- [3] S.Grossberg and E.Mingolla: “Neural Dyanamics of Form Perception: Boundary Completion, Illusion Figures, and Neon Color Spreading,” *Psychological Review*, Vol.92, No.2, pp.173-211 (1985)
- [4] K.Fukushima: “Neocognitron: A Self-Organizing Neural Network Model for a Mechanism of Pattern Recognition Unaffected by Shift in Position,” *Biological Cybernetics*, Vol.36, pp.193-202 (1980)
- [5] G.A.Carpenter, S.Grossberg and J.Reynolds: “ARTMAP: Supervised Real-time Learning and Classification of Nonstationary Data by a Self-organizing Neural Network,” *Neural Networks*, Vol.4, pp.565-588 (1991)
- [6] G.A.Carpenter, S.Grossberg, N.Markuzon, J.Reynolds and D.B.Rosen: “Fuzzy ARTMAP: A Neural Network Architecture for Incremental Learning of Analog Multidimensional Maps,” *IEEE Transactions on Neural Networks*, Vol.3, pp.698-713 (1992)
- [7] J.R.Williamson: “Self-organization of Topographic Mixture Networks Using Attentional Feedback,” *Technical Report CAS/CNS TR-99-027* (1999)
- [8] S.Grossberg: “How Does the Cerebral Cortex Work? Learning, Attention, and Grouping by the Laminar Circuits of Visual Cortex,” *Spatial Vision*, Vol.12, No.2, pp.163-185 (1999)
- [9] 岡田 真人：“運動知覚のダイナミクスとその脳内表現”，日本視覚学会 2000 年夏期大会 (2000)
- [10] 林 勲：“TAM Network による Aperture 問題の一考察”，第 17 回ファジィシステムシンポジウム (2001)
- [11] 林 勲，前田 利之：“TAM Network のプルーニング手法の一提案”，第 16 回ファジィシステムシンポジウム，pp.127-130 (2000)
- [12] I.Hayashi, J.R.Williamson: “Acquisition of Fuzzy Knowledge from Topographic Mixture Networks with Attentional Feedback,” *the International Joint Conference on Neural Networks (IJCNN' 01)*, pp.1386-1391 (2001)
- [13] K.Fukushima, Y.Yamaguchi and M.Okada, “Neural Network Model of the Spatial Memory: Associative Recall Maps,” *Neural Networks*, Vol.10, pp.971-979 (1997)
- [14] 松田 隆夫：“知覚心理学の基礎”，培風館 (2000)