

脳内初期視覚モデルによる方位選択性と知識再構築 Orientation Selectivity and Knowledge Restructuring by Computational Model in Early Vision of Brain

林 勲

Isao Hayashi

関西大学 総合情報学部

Faculty of Informatics, Kansai University

Abstract TAM (Topographic Attentive Mapping) network is a biologically-motivated model with Gabor function type receptive fields. In this paper, we discuss a new TAM network structure with extensive receptive fields and a restructuring method of fuzzy knowledge acquired from the network structure. We also show the usefulness of TAM network using some examples.

1. はじめに

網膜での視細胞の視覚情報は受容野に対応した神経節細胞で処理され、外側膝状体を介して、第一視覚野で対象画像の方位選択性が検知される。対象の知覚はより上位の視覚前野以降で認識される [1]。この初期視覚の処理過程は、Hubel-Wiesel の階層仮説に代表され、多くの有用な視覚系モデルが提案されている [2-4]。特に、Williamson が提案した TAM (Topographic Attentive Mapping) ネットワーク [4, 5] は有用である。TAM ネットワークの構造は入力層、基盤層、カテゴリー層、出力層の 4 層からなり、第一次視覚野から視覚前野以降までを模擬している。入力層では、受容野を想定し方位選択成分が入力され、基盤層のシナプス荷重は受容野からの方位選択成分を分布型で学習する。カテゴリー層では抑制性ノードを構成しており、学習された受容野の方位選択成分を全結合している。クラス層では、教師信号を与える。

一方、人間の視細胞には、単純型細胞、複雑型細胞、超複雑型細胞が存在する。この受容野の視覚構造を表現するモデルに、空間分布型の関数モデルであるガボール関数 [6-9] がある。ガボール関数はガウス関数と正弦・余弦関数から構成され、任意の周波数成分を抽出するフィルタリング機能をもつ。著者らは、ガボール関数の受容野構造を導入した視覚系モデル [5] として、改良型 TAM ネットワーク [4, 10] を提案している。このモデルは学習後のブルーニング機能を有し、ネットワーク構造を表現したファジィ知識を抽出することができる。

本論文では、改良型 TAM ネットワークの受容野入力層をさらに改良し、対象画像全体の全方位を検出する広範囲の受容野構造を新たに設け、画像全般の全体の方位選択性を検出する新たなモデルを提案する。また、Carpenter ら [11] の知見から、ネットワークを学習部とオブジェクトクラスの知識記憶部とに分離し、基盤層からクラス層の多層構造からの獲得知識を再構築するアルゴリズムを定式化する。具体的には、ガボール関数によって受容野の輝度情報から対象画像の 16 方位選択成分を抽出し、そのエッジ特徴画像に対してより広範囲の

方位選択性を抽出して、既存画像との比較で回転特性を推定する。第一視覚野以降では、この回転特性に対応した特徴マップを構成して、TAM ネットワークの学習機能により対象画像を認識する。また、ファジィ情報量を用いたブルーニング手法によって、TAM ネットワークの構造からファジィルールを獲得し、ファジィ知識を蓄積、再構築する [12]。ここでは、文字認識と画像判別の数値例を用いて、受容野入力構造と知識の再構築機能をもつ TAM ネットワークの認識率と頑健性について議論する。

2. Simple TAM ネットワーク

Williamson によって提案された TAM ネットワーク [4, 5] の構成を図 1 に示す。ガボール関数を導入した改良型 TAM ネットワークと区別するため、ここでは、このモデルを Simple TAM ネットワークと呼ぶ。カテゴリー層では、特徴マップ f_{ih} と学習荷重 w_{jih} との活性化値 x_{ji} を計算して、クラス層への出力 y_j を得る。

$$y_j = \prod_{i=1}^M x_{ji} = \prod_{i=1}^M \frac{\sum_{h=1}^L f_{ih} w_{jih}}{1 + \rho^2 b_{ji}}$$

ただし、 ρ はビジランスパラメータであり、 b_{ji} は抑制荷重である。

出力値 K は次式より計算される。

$$K = \{k | \max_k z_k\} = \{k | \max_k \sum_{j=1}^N y_j p_{jk}\}$$

ただし、 p_{jk} は学習荷重である。

Simple TAM ネットワークはカテゴリー層のノード増幅機能をもつ。いま、 K^* をクラス層での正しい教師値とする。 $K \neq K^*$ の場合には、ビジランスパラメータ ρ は初期値から $z_{K^*}/z_K \geq OC$ の条件が満足されるか最大値になるまで上昇する。最大値になった場合には、カテゴリー層のノードが 1 個分増加する。

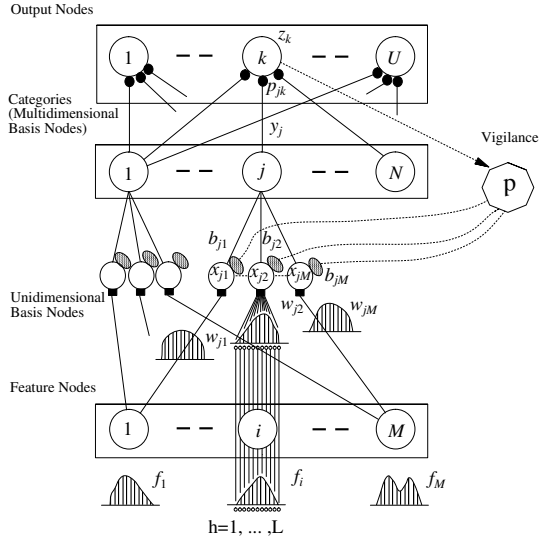


Fig. 1: TAM Network

一方, $z_{K^*}/z_K \geq OC$ を満足する場合には, 学習モードに入り, 学習荷重 w_{jih} , p_{jk} , b_{ji} を次式で更新する.

$$\Delta w_{jih} = \frac{\alpha y_j^* (1 - \lambda^{1/M}) (f_{ih} - w_{jih})}{(\alpha - 1) \lambda^{1/M} + n_j}, \lambda \in (0, 1)$$

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

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

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

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

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

ただし, $b_j^{(rate)}$ は学習定数であり, α と λ は係数, y_j^* はカテゴリー層へのフィードバック信号である.

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, 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.

2. 受容野構造をもつ TAM ネットワーク

受容野構造をもつ改良型 TAM ネットワークの構成を図 2 に示す. 第一視覚野からクラス層までを構成する Simple TAM ネットワークに対して, 網膜層から LGN 層までの新たな構造を付加している. 網膜層や LGN 層では, 対象画像をガボール関数型受容野で処理し, 16 方位の方位選択成分を抽出する. 得られたエッジ特徴画像に対し, 広範囲受容野構造を適用して, より広範囲な方位選択成分を抽出する. この広範囲な方位選択成分から, 第一視覚野での 16 方位の輝度分布の特徴マップを得る. ここで, 対象画像の回転特性は広範囲方位選択成分から得られ, 第一視覚野での 16 方位の特徴マップを変更する. 得られた特徴マップから, 基盤層, カテゴリー層, クラス層での学習機能により視界画像を認識する (図 1 を参照).

2 次元正弦関数型ガボール関数 $G(x, y)$ は次のように定義される.

$$G(x, y) = K e^{-\frac{1}{2} \left(\frac{(x-\mu_x)^2}{\sigma_x^2} + \frac{(y-\mu_y)^2}{\sigma_y^2} \right)} \times \sin(2\pi f_x x \cos \theta + 2\pi f_y y \sin \theta + \phi)$$

ただし, K は振幅, (μ_x, μ_y) はガボール関数の中心, σ_x と σ_y は標準偏差, f_x と f_y は周波数を表す. 図 3 にガボール関数の例を示す.




Fig. 2: TAM Network with Extensive Receptive Field




Fig. 3: Gabor Function

次に, 方位選択成分の検出過程を図 4 に示す. いま, 視界の原画像の横幅と縦幅をそれぞれ, $R_H \text{ pixels}$ と $R_V \text{ pixels}$ とする. 原画像 $O(p, q)$, $0 \leq p \leq R_H$, $0 \leq q \leq R_V$ における受容野の i 番目の方位選択成分 $C_i^1(x, y)$, $i = 1, 2, \dots, 16$ は, 次の畳み込み計算により計算される.

$$C_i^1(x, y) = \sum_{q=1}^{R_V} \sum_{p=1}^{R_H} G_i(x-p, y-q) \times O(p, q)$$

いま, 第 I 番目の方位選択成分が得られたとする. この第 I 番目の方位選択成分に対して, より広範囲な受容

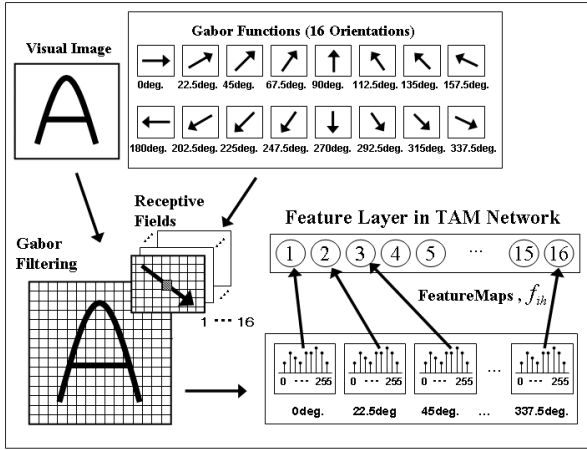


Fig. 4: Gabor Filtering Process

野を用いて、第2段目の畳み込み計算を行い、第 I 番目のみの方位選択成分 $C_I^2(x, y)$ を計算する。

$$C_I^2(x, y) = \sum_{q=1}^{R_V} \sum_{p=1}^{R_H} G_I(x-p, y-q) \times C_I(p, q)$$

TAM ネットワークの特徴マップ層での i 番目の特徴マップは、この方位選択成分の輝度を各方位ごとに正規化して構成される。

$$f_{ih} = \frac{\sum_{\{x,y|O_i(x,y)=h\}} C_i^2(x, y)}{\sum_{y=1}^{R_V} \sum_{x=1}^{R_H} C_i^2(x, y)}, \quad h = 1, 2, \dots, 256$$

ただし、TAM ネットワークの学習後に、評価用の方位選択成分画像として、 $C_{i,new}^2(x, y)$ が得られた場合、その $C_{i,new}^2(x, y)$ の特徴マップ f_{ih} は次式の角度 r により入れ替える。

$$r = \min_i \left(\frac{\sum_x \sum_y C_{i,new}^2(x, y)}{R_H \times R_V} - \frac{\sum_x \sum_y C_I^2(x, y)^2}{R_H \times R_V} \right)$$

3. 文字認識による例題

広範囲受容野をもつ TAM ネットワークの有効性を確認するため、アルファベットの文字認識を行った。入力画像として電子タブレットによって作成された画像データを用いる。画像の大きさを $15 \text{ pixels} \times 15 \text{ pixels}$ とする。ここでは、次の2点から TAM ネットワークの有効性を評価した。

- 回転特性をもたない改良型 TAM ネットワークを用いて、全26文字のアルファベット認識、回転文字認識、斜体文字認識を行う。
- 回転特性をもつ改良型 TAM ネットワークを用いて、回転文字認識を行う。

TAM ネットワークの学習パラメータは次の通りである。

L	$= 255$	ρ^{init}	$= 0.0$
OC	$= 0.8$	ρ^{step}	$= 0.1$
α	$= 0.01$	ρ^{max}	$= 100.0$
λ	$= 0.33$	$b_j^{(rate)}$	$= 0.0000001$
μ_x	$= 0.0$	μ_y	$= 0.0$
σ_x	$= 1.99$	σ_y	$= 1.92$
f_x	$= 0.127$	f_y	$= 0.127$
ϕ	$= 90.0$	K	$= 1.0$

まず、回転特性をもたない TAM ネットワークに対する特性を示す。学習用画像を図5に示し、全26文字のアルファベット認識率の結果を図6に示す。認識率はデータ順序を変えた30回の平均値を表している。学習回数(エポック数)を2回と5回として比較した。どちらのエポック回数においても、ほぼ60%以上の認識率を示し、高い認識率を確保していることがわかる。しかし、回転文字認識と斜体文字認識に対しては、頑健性が高い文字と低い文字が混在し、回転特性に弱いことがわかった。この原因として、受容野構造が単層であり、十分な方位選択性を確保できず、また、回転特性に対する機能も存在していないことが考えられる。

次に、回転特性をもつ TAM ネットワークに体する特性を示す。ここでは、2種類のアルファベット‘A’と‘B’の学習画像に対して、回転角度を与えた評価画像を準備し、方位選択性の回転特性に対する依存性を検分した。学習用画像を図7に示し、評価用画像を図8に示す。回転画像は学習用画像に対して、 22.5° ずつの回転を与えた。評価用画像の認識率を表1に示し、それぞれの文字の認識率を図8に示す。上段の値は回転特性をもたない TAM ネットワークの認識率であり、下段の値は回転角度特性をもつ TAM ネットワークの認識率である。認識率はデータ順序を変えた30回の平均値を表している。表1と図8から、文字‘B’に対して認識率が向上しており、全体の認識率も良くなっていることがわかる。しかし、各文字に対しては、十分に認識できていない文字もあり、まだ検討の余地がある。




Fig. 5: Training Images

4. TAM ネットワークからの知識獲得

改良型 TAM ネットワークからファジィ知識を獲得して知識を再構築するアルゴリズムの概念図を図9に示す。基盤層のシナプス荷重では、受容野の処理量が分布

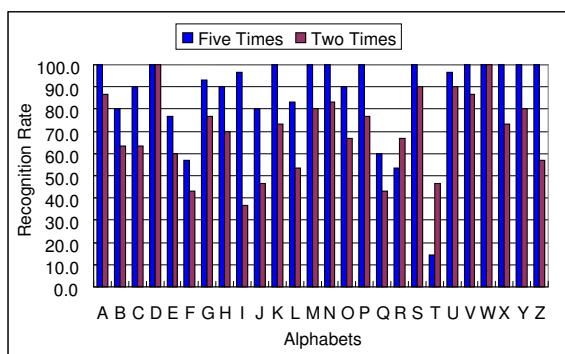


Fig. 6: Results of All Alphabets

Table 1: Recognition Rate

	Char. 'A' (%)	Char. 'B' (%)	Total (%)
TAM without Rotation	96.04	12.71	54.38
TAM with Rotation	98.33	30.42	64.38

型で学習され、カテゴリー層の抑制性ノードではその受容野を結合している。基盤層の分布型シナプス荷重をファジィ数とすれば、カテゴリーノードはファジィルールを表現しているといえる。学習後の TAM ネットワークは全結合されており、不必要なリンクとノードを削除するブルーニング手法を用いることにより、TAM ネットワークから必要なファジィルールを獲得することができる。リンクとノードのブルーニングは次の手順にしたがって行う。

[Step 1] 学習データ D に対して、第 i 番目の属性の情報量 $H(i)$ を計算する。

[Step 2] $i^* = \{i | \max_i H(i)\}$ を選択し、 $I^* = \{i^*\}$ とする。

[Step 3] しきい値 η と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。

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




Fig. 7: Training Images of 'A' and 'B'

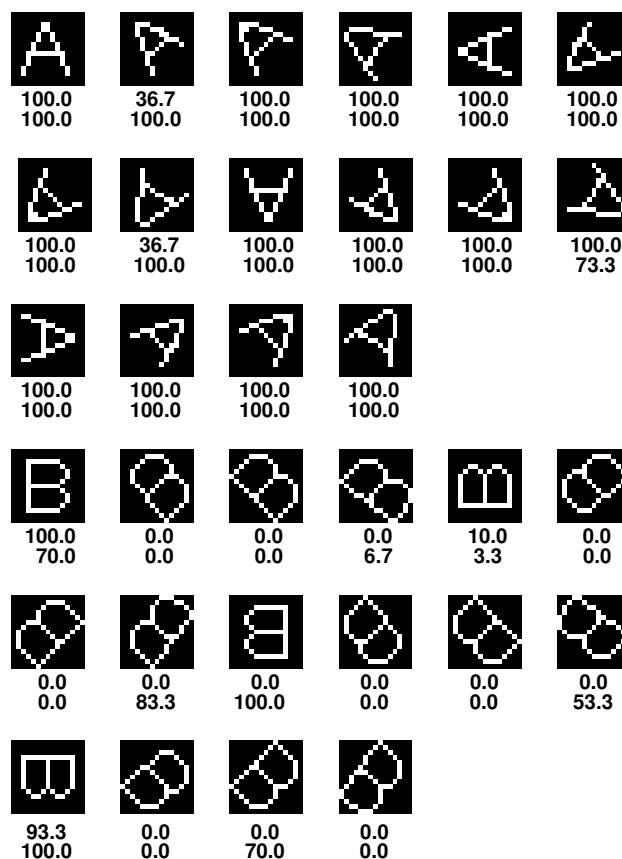


Fig. 8: Checking Images

$$G_{jk} = \frac{\sum_{s \in \psi_k} \gamma_{js} \times p_{jk}}{\sum_{s=1}^R \gamma_{js} \times p_{jk}} \geq \eta$$

[Step 4] しきい値 θ と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。

$$\frac{1}{R} \sum_{s=1}^R \gamma_{js} < \theta$$

[Step 5] しきい値 ξ と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 $j' \neq j$ 番目のカテゴリとの結合を削除する。ただし、 $\Gamma_K = \{s | K = K^*, K = \max_k \sum_{j=1}^N y_j p_{jk}\}$ である。

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

[Step 6] 全結合が削除されたノードを削除する。

[Step 7] ステップ 2 において、全ての属性が選択されるまで、ステップ 1 からステップ 5 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} により各カテゴリの重要度が表現される。なお、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、不必要な結合やノードが削除されたネットワークは、前件部のファジィ集合、後件部の実数が調整されたファジィルールを表し、カテゴリ層のノードはそのファジィルール数を表している。




Fig. 9: Knowledge Restructuring Type TAM Network

5. 視覚前野からの知識の再構築

ブルーニング手法によって TAM ネットワークから獲得されたファジィルールは次の形式でファジィ知識部に

格納される。

- r_1 : if f_1 is z_{11} and \dots and f_M is z_{1M}
then $C_1 = o_{11}, \dots, C_U = o_{1U}$
- r_2 : if f_1 is z_{21} and \dots and f_M is F_{2M}
then $C_1 = o_{21}, \dots, C_U = o_{2U}$
- \vdots
- r_j : if f_1 is z_{j1} and \dots and f_M is z_{jM}
then $C_1 = o_{j1}, \dots, C_U = o_{jU}$
- \vdots
- r_N : if f_1 is z_{N1} and \dots and f_M is z_{NM}
then $C_1 = o_{N1}, \dots, C_U = o_{NU}$

ここで、 z_{ji} $j = 1, 2, \dots, N, i = 1, 2, \dots, M$ は TAM ネットワークの重み w_{ji} であり、メンバーシップ関数である。また、実数 o_{jk} は出力ノードの重み p_{jk} である。なお、ファジィルールは (1) 式の φ_{jk} の値により並び替える。

- C_1 : $r_1(\varphi_{11}) \geq r_2(\varphi_{21}) \geq \dots \geq r_N(\varphi_{N1})$
- C_2 : $r_1(\varphi_{12}) \geq r_2(\varphi_{22}) \geq \dots \geq r_N(\varphi_{N2})$
- \vdots
- C_U : $r_1(\varphi_{1U}) \geq r_2(\varphi_{2U}) \geq \dots \geq r_N(\varphi_{NU})$.

ファジィ知識部では、“クラス”と“ケース”の概念を用いる。ケースとは、TAM ネットワークから獲得されたファジィルールを表現する。しかし、類似な内容の複数のケースはグループごとにまとめられ、そのグループを構成する名称としてクラスが付与される。図 10 に例題を示す。2つのクラス“Cups”と“Glasses”が存在し、“Cups”クラスには、3つのケースが属しており、“Glasses”クラスには2つのケースが属している。なお、ここでは、ケースのことをファジィケースと呼ぶ。

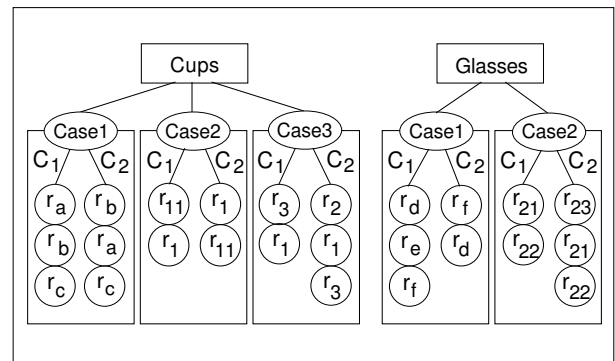


Fig. 10: Example of Knowledge Part

さて、TAM ネットワークから獲得されたファジィルールをファジィ知識部の各クラスに記憶させるとき、現存するファジィケースとの類似度を定義する必要がある。ファジィルールとファジィケースとの類似度を次の3種

類の指標で定義する．

$$\begin{aligned}
 1) \quad \Omega &= \begin{cases} - : -\tau < I_1^* < 0 \\ + : 0 \leq I_1^* < \tau \\ F : |I_1^*| \geq \tau \end{cases} \\
 I_1^*(W, Z) &= \{I_1 \mid \min_{Case} |I_1|\} \\
 I_1(W, Z) &= \frac{1}{UNL} \sum_{k=1}^U \sum_{j=1}^N \sum_{i=1}^{M+1} \sum_{h=1}^L \log \frac{\mu_{w_{ji}}(f_{ih})}{\mu_{z_{ji}}(f_{ih})} \\
 2) \quad \Omega &= \begin{cases} - : \max\{-, +, F\} \text{ count}_{k,j} \omega = \{-\} \\ + : \max\{-, +, F\} \text{ count}_{k,j} \omega = \{+\} \\ F : \max\{-, +, F\} \text{ count}_{k,j} \omega = \{F\} \end{cases} \\
 \omega &= \begin{cases} - : -\tau < I_2^* < 0 \\ + : 0 < I_2^* < \tau \\ F : |I_2^*| \geq \tau \end{cases} \\
 I_2^*(W, Z) &= \{I_2 \mid \min_{Case} |I_2|\} \\
 I_2(W, Z) &= \frac{1}{L} \sum_{i=1}^{M+1} \sum_{h=1}^L \log \frac{\mu_{w_{ji}}(f_{ih})}{\mu_{z_{ji}}(f_{ih})} \\
 3) \quad \Omega &= \begin{cases} - : \max\{-, +, F\} \text{ count}_{k,j \in N'} \omega = \{-\} \\ + : \max\{-, +, F\} \text{ count}_{k,j \in N'} \omega = \{+\} \\ F : \max\{-, +, F\} \text{ count}_{k,j \in N'} \omega = \{F\} \end{cases} \\
 \omega &= \begin{cases} - : -\tau < I_3^* < 0 \\ + : 0 < I_3^* < \tau \\ F : |I_3^*| \geq \tau \end{cases} \\
 I_3^*(W, Z) &= \{I_3 \mid \min_{Case} |I_3|\} \\
 I_3(W, Z) &= \frac{1}{L} \sum_{i=1}^{M+1} \sum_{h=1}^L \log \frac{\mu_{w_{ji}}(f_{ih})}{\mu_{z_{ji}}(f_{ih})}
 \end{aligned} \tag{3}$$

ただし, $\mu_{w_{jM+1}}(f_{M+1}) = p_{jk}$ であり, $\mu_{z_{jM+1}}(f_{M+1}) = o_{jk}$ である．また, “ $\text{count}_{k,j} \omega$ ” は, クラス k と j のおける ω の個数を表す．さらに, $N' \leq N$ と τ はしきい値である．

ファジィ知識を再構成するためのアルゴリズムを下記に示す．

[Step 1] φ_{jk} により TAM ネットワークのファジィルールを並び替える．

[Step 2] (2) ~ (4) 式により類似度を計算する．

[Step 3] $I_i^*(W, Z) = \{I_i(W, Z) \mid \min |I_i(W, Z)|, i = 1, 2, 3\}$ を満足するファジィケースを求める．

[Step 4] τ をしきい値とし, $|I_i^*(W, Z)| \geq \tau$ を満足する場合には, TAM ネットワークから獲得したファジィルールは新しいクラスの新しいファジィケースとして登録され, TAM ネットワークの学習は継続される．

[Step 5] $0 \leq I_i^*(W, Z) < \tau$ の場合には, ファジィルールは既存の $I_i^*(W, Z)$ を満足するクラスの新しいファジィケースとして登録される．TAM ネットワークの学習は継続される．

[Step 6] $-\tau < I_i^*(W, Z) < 0$ の場合には, そのファジィルールは $I_i^*(W, Z)$ のファジィケースと同等であるとみなし, $I_i^*(W, Z)$ のファジィケースの $b_{ji}, w_{ji}(z_{ji}), p_{jk}(o_{jk})$ を初期値として, TAM ネットワークを再学習する．学

習終了後, 獲得されたファジィルールを既存の $I_i^*(W, Z)$ のファジィケースと交換する．

6. 判別問題による例題

ファジィ知識の再構築の例を図 11 に示す．3 種類のデータが TAM ネットワークに投入されたとき, TAM ネットワークから獲得されるファジィルールについて検証する．なお, ここでは, 類似度の指標は I_1 を用いる．TAM ネットワークから獲得されたファジィルールはファジィ知識部に記憶される．各データは, “ Δ ” と “ \bullet ” の2つのパターンを持つ．第 1 と第 3 データは類似したパターン分類であり, 第 2 データのそれとは異なる．

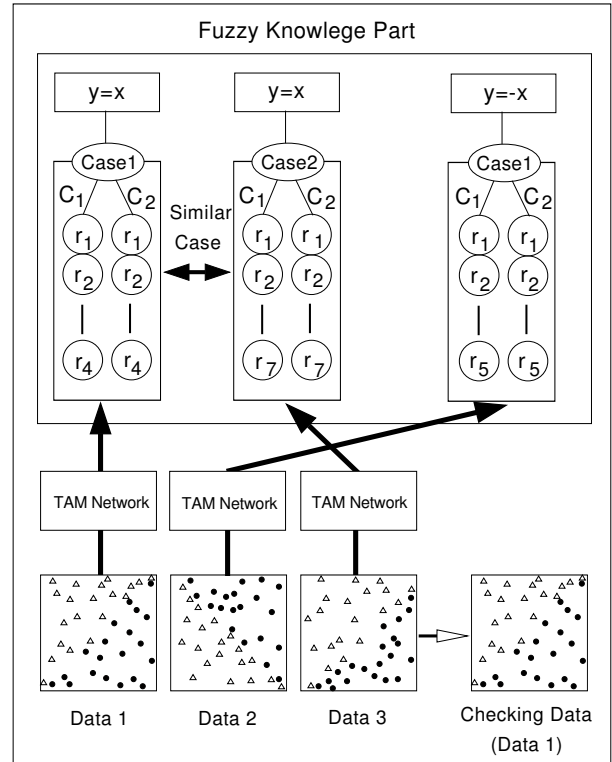


Fig. 11: Procedure of Fuzzy TAM Network

Table 2: Correct Rate and Categories

	Correct Rate		Categories	
	TAM	Fuzzy TAM	TAM	Fuzzy TAM
Data 1	97.5%	97.5%	4	4
Data 2	80.0%	80.0%	5	5
Data 3	80.3%	—	7	—
Data 3 after relearning	—	97.5%	—	6
Checking Data	50.0%	60.0%	7	5

まず, 第 1 データからのファジィルールがファジィケース “Case 1” として登録される．次に, 第 2 データのファ

ジールールとファジィケース “Case 1” との類似度が計算され、 $I_1^*(2, 1) = 13.5$ と得られる。 $\tau = 10.0$ と設定されており、第 2 ファジィルールは新たなファジィケース “Case 1” として登録される。第 3 データのファジィルールが獲得され、第 1 と第 2 のファジィケースとの類似度が計算される。 $I_1(3, 1) = -2.84$, $I_1(3, 2) = -1.88$ であり、 $I_1^*(3, 1) = -1.88$ であるので、第 1 ファジィケースの b_{ji} , $w_{ji}(z_{ji})$, $p_{jk}(o_{jk})$ を初期値として、TAM ネットワークを再学習する。学習後の TAM ネットワークのファジィルールが第 1 ファジィケースと交換され、新たな第 1 ファジィケースとして登録される。

ファジィ知識の再構築の有用性を示すため、第 1 データと同じデータを評価データとして投入し、従来の TAM ネットワークとの正解率を比較した。結果を表 2 に示す。従来の TAM ネットワークの正解率が 50.0%、カテゴリー層ノード数が 7 に対し、ファジィ TAM ネットワークの正解率は 60.0%、ノード数は 5 と得られ、本手法の有用性が示された。




Fig. 12: Circle Image and Square Image




Fig. 13: Ellipse Image

次に、画像の類似比較の例を示す。図 13 の (a) に楕円の画像を示す。この画像が図 12 の (a) の円画像か (b) の四角画像かを判別する。ただし、類似のための比較は、元画像で比較するのではなく、TAM ネットワークから

獲得されたファジィルールを比較して判別する。学習後の TAM ネットワークの出力画像を図 12 の (c) と (d) に示し、図 13 の (b) に示す。学習のためのパラメータを次に示す。

L	$=$	10	ρ init	$=$	0.0
OC	$=$	0.8	ρ step	$=$	0.1
α	$=$	0.0000001	ρ max	$=$	100.0
λ	$=$	0.33	$b_j^{(rate)}$	$=$	0.01
η	$=$	0.8	θ	$=$	0.03
ξ	$=$	0.5	N_{set}	$=$	6.

Table 3: Result of Similarity Measure 1

Similarity Measure 1	
Similarity between Circle and Ellipse	32.45
Similarity between Square and Ellipse	65.05

Table 4: Result of Similarity Measure 2

Similarity Measure 2				
Similarity between Circle and Ellipse	+	-	F	τ
		10	0	6
Similarity between Square and Ellipse	12	0	4	7.5
	0	0	24	5.0
	6	0	18	7.5

Table 5: result of Similarity Measure 3

Similarity Measure 3				
Similarity between Circle and Ellipse	+	-	F	τ
		10	0	2
Similarity between Square and Ellipse	12	0	0	7.5
	0	0	12	5.0
	6	0	6	7.5

3 つの指標の類似度で得られた結果をそれぞれ表 3、表 4、および、表 5 に示す。円の画像から 8 個のファジィルールが得られ、四角の画像から 11 個のファジィルールが得られた。また、楕円からは 6 個のファジィルールが得られた。すべての類似指標は楕円の画像が四角の画像よりも円画像に類似していることを示している。しかし、第 2 番目の類似指標と第 3 の類似指標は τ のしきい値に依存する。したがって、今後しきい値の決定方法について議論する必要がある。

7. おわりに

ここでは、ガボール関数を用いて、より広範囲な受容野入力構造を導入した改良型 TAM ネットワークを提案

し、その有用性を文字認識の例で検討した。また、ネットワークからファジィ知識を獲得して再構築するアルゴリズムについて提案し、その有用性を判別問題の例で検討した。

[連絡先]

林 勲 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
telephone 072-690-2448
e.mail ihaya@kcn.res.kutc.kansai-u.ac.jp

参考文献

- [1] 松田: 知覚心理学の基礎, 培風館 (2000)
- [2] 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)
- [3] H.Neumann and W.Sepp: Recurrent V1-V2 interaction in early visual boundary processing, *Biological Cybernetics*, Vol.81, pp.425-444 (1999)
- [4] J.R.Williamson: Self-organization of topographic mixture networks using attentional feedback, *Neural Computation*, Vol.13, pp.563-593 (2001)
- [5] 林, 前田: ガボール関数を用いた TAM ネットワークの受容野入力構造, 第 20 回ファジィシステムシンポジウム講演論文集, pp.410-413 (2004)
- [6] S.Marčelja: Mathematical description of the responses of simple cortical cells, *Optical Society of America*, Vol.70, No.11, pp.1297-1300 (1980)
- [7] J.Daugman: Uncertainty relation for resolution in space, spatial frequency, and orientation optimized by two-dimensional visual cortical filters, *Optical Society of America*, Vol.2, No.7, pp.1160-1169 (1985)
- [8] 岡島, 今岡: 情報量最大化と生体視覚細胞の受容野, 電子情報通信学会論文誌 A, No.J83-A, Vol.6, pp.620-628 (2000)
- [9] D.C.Lee: Adaptive processing for feature extraction: Application of two-dimensional Gabor function, *Remote Sensing*, Vol.17, No.4, pp.319-334 (2001)
- [10] 林, Williamson: TAM Network のブルーニング手法の提案, システム制御情報学会論文誌, Vol.17, No.2, pp.81-88 (2004)
- [11] 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)
- [12] 林, ウィリアムソン: ファジィ TAM Network における獲得知識の再構築法, 第 18 回ファジィシステムシンポジウム講演論文集, pp.63-64 (2002)