TAM Network による Aperture 問題の一考察
A Consideration on Aperture Problems Using TAM Network

林　勲
Isao Hayashi

阪南大学 大学院 企業情報研究科
Hannan University

Abstract　The TAM Network based on a biologically-motivated neural network is an especially effective model. We discuss here the feedback mechanism and show its usefulness through some examples.

1．はじめに

視覚系ニューラルネットワークの TAM[1] は，網膜の機能を模擬した入力層，外側膝状体の興奮性・抑制性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，ビジランス・パラメータによる抑制性学習を行う．しかし，過剰学習となる場合があり，結合とノードのプルーニング機能が付加された [2]．

一方，ディスプレイに円形の小窓を表示し，背後の線分移動の運動方向を知覚する実験として，Aperture 問題がある．岡田ら [3] は，運動知覚と線分呈示時間との関連を実験し，運動方向検出の局所性と情報拡散のモデルを提案して，フィードバック機能の必要性を議論している．本論文では，同様な視覚実験を行い，TAM ネットワークの認識率とフィードバック機能の必要性を議論する．

2．TAM ネットワーク

TAM ネットワークの構造を図 1 に示し，プルーニング機能を含んだアルゴリズムを下記に示す．

[Step 1] TAM ネットワークの出力値 K を得る．

$$K = \{k | \max_k z_k, \quad z_k = \sum_{j=1}^{N} \prod_{i=1}^{M} x_{ji} p_{jk}\} \tag{1}$$

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

ただし，f_{ih} は分布データ，ρ はビジランス・パラメータ，b_{ji} と p_{jk}，w_{jih} は学習パラメータである．

[Step 2] K が教師値 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．OC は評価のためのしきい値である．

$$z_k^* = 1 \text{ if } k = K^*; \quad z_k^* = 0 \text{ otherwise} \tag{3}$$

$$y_j^* = \frac{\prod_{i=1}^{M} x_{ji} \times \sum_{k=1}^{U} z_k^* p_{jk}}{\sum_{j'=1}^{N} \prod_{i=1}^{M} x_{j'i} \times \sum_{k=1}^{U} z_k^* p_{j'k}} \tag{4}$$

各学習パラメータ w_{jih}, p_{jk}, b_{ji} を更新する．

$$\triangle w_{jih} = \frac{\alpha y_j^* (f_{ih} - w_{jih})}{\alpha\beta(M) + n_j} \tag{5}$$

$$\triangle p_{jk} = \frac{\alpha y_j^* (z_k^* - p_{jk})}{\alpha + n_j} \tag{6}$$

$$\triangle b_{ji} = b_j^{(init)} y_j^* (x_{ji} - b_{ji}) \tag{7}$$

$$\triangle n_j = \alpha y_j^* (1 - n_j) \tag{8}$$

$$\beta(M) = \frac{\lambda^{1/M}}{1 - \lambda^{1/M}}, \quad \lambda \in (0, 1) \tag{9}$$

[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．次に，プルーニング・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．

$$H(i) = -\sum_{j=1}^{N} g_j \sum_{k=1}^{U} G_{jk} \log_2 G_{jk} \tag{10}$$

$$g_j = \frac{\sum_{s=1}^{R} x_{jis}}{\sum_{j=1}^{N} \sum_{s=1}^{R} x_{jis}} \tag{11}$$

$$G_{jk} = \frac{\sum_{s \in \psi_k} \gamma_{js} \times p_{jk}}{\sum_{s=1}^{R} \gamma_{js} \times p_{jk}} \tag{12}$$

$$\gamma_{js} = \prod_{i \in I^*} x_{jis} \times x_{jis} \tag{13}$$

ここで，学習データ D は，R 個の属性データ f_{si} と教師値のクラス k からなる．また，ψ_k は D でのクラス k をもつデータの集合である．

[Step 5] 次式の i^* を選択し，$I^* = \{i^*\}$ とする．

$$i^* = \{i | \max_i H(i)\} \tag{14}$$

[Step 6] 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．ただし，η はしきい値である．

$$G_{jk} \geq \eta \tag{15}$$

[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 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．

$$\frac{1}{R}\sum_{s=1}^{R}\gamma_{js} < \theta \tag{16}$$

[Step 8] 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．ただし，$\Gamma_K = \{s|\ K = K^*,\ K = \max_k \sum_{j=1}^{N} y_j p_{jk}\}$ であり，ξ はしきい値である．

$$\varphi_{jK} = \frac{\sum_{s\in\Gamma_K}\gamma_{js}\times p_{jK}}{\sum_{j=1}^{N}\sum_{s\in\Gamma_K}\gamma_{js}\times p_{jK}} \geq \xi \tag{17}$$

[Step 9] 全結合が削除されたノードを削除する．
[Step 10] ステップ 5 において，全ての属性が選択されるまで，ステップ 4 からステップ 9 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．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，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を調整したファジィルールが獲得できる．

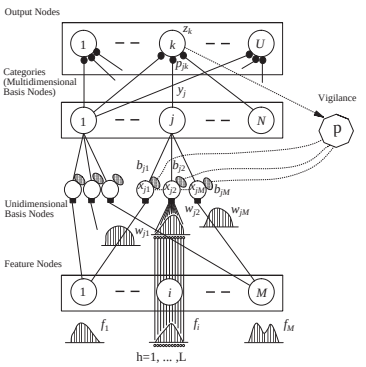

Fig. 1: TAM Network

タイタニック号の水難事故で，2201 名の全乗客の入力データに対して，救助された人と救助されなかった人との出力データが DELVE[4] にある．全乗客の船室別データ，年齢，性別の入出力データに対して，TAM ネットワークで学習用データと評価用データの正解率を求めた．学習用データの正解率は 100.0%となり，評価用データの正解率 (%) を表 1 に示す．ただし，**Cart** は決定木構成法，**1NN** と **KNN-Class** はクラスタリング手法である．

Table 1: Results of Titanic Data

Methods	20	40	80	160
TAM	72.9	75.6	77.5	78.2
Cart	68.4	73.8	76.6	75.3
1NN	68.7	67.8	68.8	69.5
KNN-Class	71.6	73.1	74.2	75.7

3．Aperture 問題への応用

Aperture 問題の実験構成を図 2 に示す．ディスプレイ中央に 1 個の円形の小窓が表示され，背後に線分が移動する．移動途中で両側の小窓が表示され，両小窓内に線分の端点が表示される．3 本の線分が接続していると知覚された場合には，中央小窓の線分は，その運動方向を知覚できる．岡田ら [3] は，運動方向の知覚が線分の呈示時間と関係あることを示し，運動方向検出の局所性と情報拡散に基づくモデルを提案して，フィードバック機能の必要性を議論している．いま，小窓の条件を (円の半径 (mm)，中心間距離 (mm)) = (35,90), (33,86), (38,96), (40,100) と変更した場合の呈示時間に対する線分の運動方向の知覚を図 3 に示す．岡田らが指摘しているように，呈示時間が長いほど運動方向の知覚認識率は高くなった．

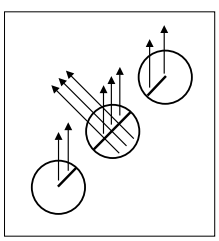

Fig. 2: Aperture Experiment

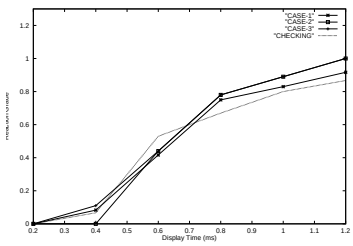

Fig. 3: Reaction of Subjects

運動方向の知覚は小窓間距離に依存していると考えられ，同距離では，呈示時間に対する認識率は同じであると仮定できる [5]．TAM ネットワークで，(円の半径，中心間距離) = (35,90), (33,86), (38,96) の 3 種類を学習データとして学習した後，(40,100) を評価データとして，$\eta = 0.5,\ \theta = 0.005,\ \xi = 0.1$ により正解率 (%) を求めた．また，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正解率 (%) を求めた．これらの結果を表 2 に示す．フィードバック機能を持たない TAM ネットワークは，プルーニングの操作に関わらず，正解率が低下することがわかる．

Table 2: Reaction of Checking Data by TAM Network

		TAM	Pruning TAM
with FB	Learning Data	82.8	85.0
	Checking Data	57.8	65.0
without FB	Learning Data	86.1	86.7
	Checking Data	54.4	60.0

参考文献

[1] J.R.Williamson: "Self-organization of Topographic Mixture Networks Using Attentional Feedback," *Technical Report CAS/CNS TR-99-027* (1999)
[2] 林，前田："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講演論文集，pp.127-130 (2000)
[3] 岡田；"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)
[4] *http://www.cs.toronto.edu/~delve* (1996)
[5] 松田："知覚心理学の基礎"，培風館 (2000)

[連絡先]
Isao Hayashi, Hannan University
5-4-33, Amami-higashi, Matsubara, Osaka 580-8502
e.mail ihaya@hannan-u.ac.jp