

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。

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

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

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。

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

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

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

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

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

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

$$\Delta n_j = \alpha y_j^* (1 - n_j) \quad (8)$$

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

[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。

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

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

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

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

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。

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

[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。

$$G_{jk} \geq \eta \quad (15)$$

[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

