

環境適応型のパターン分類ニューラルネット

5R-5

志田 武彦 中 基孫 吉田 邦夫
 松下技研(株) 研究開発グループ

1. はじめに

機器の設置現場における適応学習機能の具現化への関心が高い。機器組み込み型の適応学習は、追加学習が可能であると共に、処理機構が簡単で、記憶容量の制限条件下で達成されなければならない。筆者らは、使用者の操作を学習するニューラルネットを空調機器に組み込んで適応学習ができる制御方式を開発した⁽¹⁾。本方式には環境の変化に適応するカウンタ制御型モデルCCNN (Counter Controlled Neural Network) を用いている。本稿では、CCNNの特徴について検討を行ったので報告する。

2. CCNNのモデル

CCNNは、入力層を含めて3層型ネットワークである。中間層は、入力情報と中間層の各ニューロンが持つ参照情報との距離計算を行い、その距離と固定しきい値と比較して、小さい場合にニューロンが発火する。中間層のニューロンは属性を持ち、例えば、2種類の分類を行う場合では、その属性に合わせて+1/-1の出力を行う。出力層は、中間層の発火状態に基づいて多数決論理により、分類結果を出力する。前記の場合は、+1/-1/不明の分類に対応して+1/-1/0を出力する。初期状態のネットワークは、中間層にニューロンが存在せず、入力層から出力層への結合が無い。このため、入力情報を入れても出力層は0のみを出力する。中間層は、学習信号の入力により、学習信号の属性を持つニューロンが生成される。この方法により追加学習を容易にしている。生成されたニューロンには、学習信号が入力された時点の入力信号が参照情報として記憶される。中間層のニューロンは、内部にカウンタを持ち、初期値はマイナスの値が設定されており、生成されると0が設定される。カウンタ値が、マイナスの場合は、そのニューロンは消滅状態となる。ニューラルネットが予測を行った場合に、使用されたニューロンのカウンタ値は増加し強化される。また、学習時に学習信号の属性と異なった分類のニューロンが発火する場合は、そのニューロンのカウンタ値を減少し、カウンタ値がマイナスになると消滅状態になる。このニューロン内にカウンタを持つことにより、限られた記憶容量の効率的な運用を図っている。図1にネットワークの構造と中間層のニューロンの強化例を、図2に中間層のニューロンの消滅例を示す。

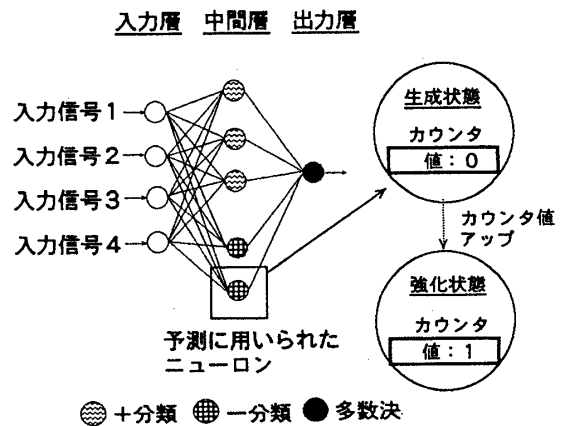


図1 ネットワークの構造と中間層のニューロンの強化

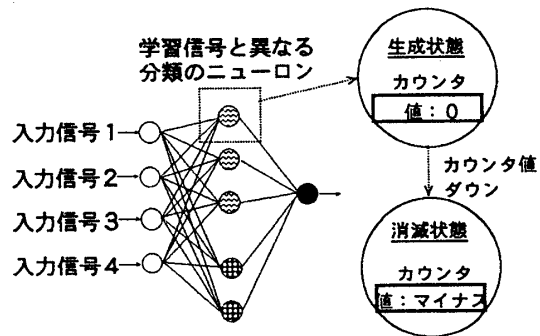


図2 中間層のニューロンの消滅

3. CCNNの特徴

CCNNは、競合学習型のパターン分類モデルである。この種のモデルとしては、LVQ⁽²⁾、RCE⁽³⁾やPDM⁽⁴⁾等がある。これらのモデルに各々特徴があるが、機器組み込みを考えた場合に、学習の速度や記憶容量等の点で問題がある。例えば、LVQは学習速

度が遅い。また、RCEでは生成されたニューロンが消去できず、記憶容量が決定できない。また、RCEを改良したPDMは、RCEよりも学習が複雑になる。そこで、CCNNでは次の様な特徴を満たすモデルとした。

- ① 追加学習が可能である。
- ② 学習機構が簡単である。
- ③ 記憶容量が少なくすむ。

3. 変化する学習環境への適応実験

機器組み込み後に想定される学習環境を作って、CCNN、LVQ、RCE、PDMで実行し、比較実験を行った。本実験では、空間を直線により区分して2つのパターンを分類させるようにした。ただし、パターン領域の分離直線にノイズを上乗せて、機器等で発生する操作の誤りや信号値に乘るノイズ成分の役割とした。

具体的には、1つの変数Xを入力(0から1までの実数)として、出力変数は1つ(0または1)とした。環境は性質が明確な場合を想定して次のような環境を作成した。

$$y = F(X) = X + A \cdot \text{rand}$$

そこで、 $y \geq 0.5$ ならば $\text{type} = 0$

$y < 0.5$ ならば $\text{type} = 1$

ここで、Aは0.05刻みで0から0.45までの係数である。randは-1から1までの一様乱数を発生させた。typeは、Xに対する分類(0または1)を示す。

学習方法は、Aが0.05から0.45までの9個の学習パターンを10回づつ学習させた後、Aが0.0の学習パターン5種類(Xを0から1までの一様乱数で発生させた)を10回づつ繰り返し学習させ、そのニューロンの生成数の変化と認識率を確認した。RCE、PDMの初期半径およびCCNNの半径は0.001にした。RCE、PDMの半径縮小値は0.0002にし、PDMの反証定数は1、限界定数を0.0001とした。CCNNはニューロンの強化を予測に使われたときに行うので、学習5回に対して1回の予測を実行させた。LVQは参照ベクトル数を1000個に決め、学習パターン提示手順を他のモデルと同様に行った。学習回数とニューロンの生成数の変化を図3に示す。表1に150回におけるの学習結果を示す。

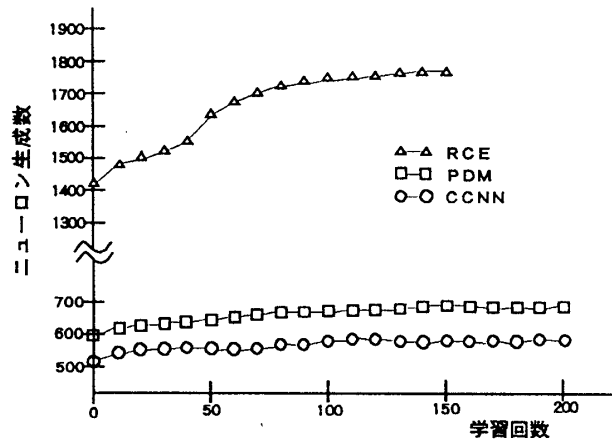


図3 学習回数とニューロンの生成数

表1 各モデルと認識率およびニューロンの最大生成数

モデル名	認識率(%)	ニューロンの最大生成数(個)
CCNN	98.8	580
PDM	99.2	672
RCE	100	1790
LVQ	78.9	-

4. まとめ

表1の結果より認識率は、RCEが100%の認識率であり、次に、PDM、CCNNであった。また、ニューロン最大生成数は、CCNNが最も少なく、PDM、RCEの順になる。LVQは参照ベクトルが識別に貢献しないものが多くあり、良い認識結果が得られなかった。PDMでは反証定数と限界定数を調整を学習パターンに合わせて調整することにより、より効率的な学習が行える可能性があるが、CCNNについても同様に半径の取り方と強化および消滅の増減定数の調整が可能である。機器への組み込みを考えた場合には、その用途に合わせて事前に最適な調整が行えるとすると、CCNNの簡略された学習方法が具現化時に有効であると言える。

5. 参考文献

(1) 中、志田、吉田、赤嶺：“ニューラルネットの空想への応用”、信学会ヒューマンコミュニケーション研究会、HC91-37、pp.9-16、1991
 (2) T.Kohonen, "Self-Organization and Associative Memory", 2ed, Springer-Verlag, 1988
 (3) D.L.Reilly et. "Neural Model Category Learning", Biol. Cybern, vol-25, 1982
 (4) 岡本：“環境の激しい変化に適応する神経回路モデル”、信学会誌 D-11、vol. J73 No. 8 pp. 1186-1191、1990