

環境の変化に適応する

6 E-8 ニューラルネットワークモデルに関する検討*

佐藤 正章[†] 志田 武彦 中 基孫 吉田 邦夫
松下技研(株)[‡]

1 はじめに

近年、様々な機器において、設置された環境の変化に対応するために、設置現場における適応学習の技術が求められている。機器の設置現場における適応学習に適したニューラルネットワークとしては、RCE(Restricted Coulomb Energy)[2]などがあるが、筆者らは前報[1]にて、ニューラルネットワークCCNN(Counter Controlled Neural Network)を示した。これは、パターン空間上の固定半径の超球で表されるリファレンスでパターン空間を複数のカテゴリに分割し、リファレンスそれぞれの持つカウンタを増減することでリファレンスの生成、消滅および強化、弱化を行なうモデルである。本報では、CCNNをベースとして、新たな学習則を用いるモデル(以下CCNN2)を提案する。CCNN2は、リファレンスの学習効率を向上させるために、学習データに対して最適な位置へとリファレンスを移動させる。CCNN2と各種モデルとの比較実験を行ない良好な結果を得たので報告する。

2 CCNN2の概要

2.1 変数構造

n次元空間においてCCNN2は、リファレンス1個毎に、表1に示す変数を持つ。また、全リファレンスに共通な定数を表1に示す。

表1: 変数および定数

変数		定数	
W	位置変数	R	しきい値
C	カウンタ値	DC_{up}	カウンタ増加値
P	カテゴリ値	DC_{down}	カウンタ減少値
		C_{start}	カウンタ初期値
		C_{limit}	カウンタ下限値
		DW	移動量

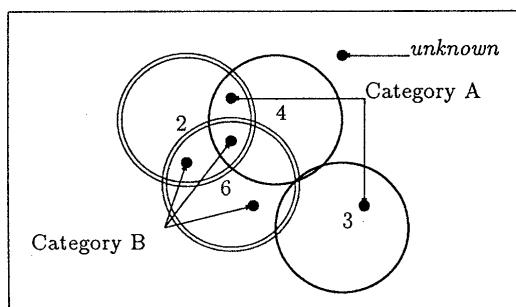
2.2 分類判定

ある入力 S が発火した場合、以下の条件を満たすリファレンス全てが発火し、カテゴリ値を出力する。

$$dist(S, W) \leq R$$

ここで、 $dist(A, B)$ は AB 間の距離を表すものとする。CCNNでは、複数のリファレンスが発火した場合には、各カテゴリ毎に集計し、発火したリファレンス数が最大のカテゴリを選択したが、CCNN2においては、カウンタが最大のリファレンスのカテゴリを選択する。発火するリファレンスがない場合は、*unknown*(不答)とする。分類判定の例を図1に示す。図1において、それぞれの円が半径 R のリファレンスであり、内部の数字がカウンタ値である。ここではカテゴリAに属するリファレンスが2つ(カウンタ値が4, 3)、カテゴリBに属するリファレンスも2つ(カウンタ値が2, 6)ある。図中の点が入力ベクトル S を表し、6点が示されている。どのリファレンスにも含まれない入力 S は、*unknown*と判定され、1つのリファレンスのみに含まれる入力は、そのリファレンスが属するカテゴリと判定される。複数のリファレンスに含まれる場合は、そのうちでカウンタ値が最大のリファレンスのカテゴリと判定する。

図1: 分類判定の例



2.3 学習

CCNN2は、選択したカテゴリと、教師信号を比較し、正しい場合と誤った場合でそれぞれ以下のように学習を行なう。

*A Neural Network Model for Adaptation to Environment

[†]Masaaki SATO(msatoh@mrit.mei.co.jp), Takehiko SHIDA,

Motohiko NAKA, Kunio YOSHIDA

[‡]Matsushita Research Institute Tokyo, Inc.

$$\text{正しい場合: } \begin{cases} W' = W + \frac{DW}{dist(S, W)}(S - W) \\ C' = C + DC_{up} \end{cases}$$

$$\text{誤った場合: } \begin{cases} W' = W - \frac{DW}{dist(S, W)}(S - W) \\ C' = C - DC_{down} \end{cases}$$

ここで, W' は調整後の位置変数, C' は調整後のカウンタ値である. その際, $C \leq C_{limit}$ となれば, そのリファレンスは消滅する. *unknown*の場合と誤った場合は, S の位置にカウンタ値 C_{start} のリファレンスを生成する. 生成する場合に, 距離 R 以内に同じカテゴリに属するリファレンスがある場合は, 生成は行なわない.

DW は, 固定値かまたは C や $dist(S, W)$ を変数とする関数で定義される.

3 比較実験

3.1 実験方法

2次元空間上で, 正規分布する近接した二つのカテゴリの分離という問題で比較実験を行なった. 亂数で2つのカテゴリのデータをそれぞれ500個作成し, 合わせて1セット1000個のデータとした. それを1回学習させた後, 同様に作成した別の1000個のデータで分類のみを行ない, 正答数, 誤答数, 不答数をカウントし, 最終リファレンス数と合わせて一組の評価値とした. これを100セットのデータについて行ない, それぞれの評価値の平均値, 標準偏差, 最大値, 最小値を算出した. 表2に実験結果を示す. 比較対象は, CCNN, RCEとした. 使用した各種パラメータを表3に示す.

表2: 実験結果

	正答率	誤答率	不答率	Ref数
CCNN2 平均値	89.3	9.2	1.5	25.9
標準偏差	10.4	10.8	7.4	2.4
最大値	91.7	12.3	4.2	32.0
最小値	86.5	6.6	0.4	20.0
CCNN 平均値	86.2	9.5	4.3	25.0
標準偏差	23.6	17.2	23.3	2.1
最大値	90.4	14.3	11.6	31.0
最小値	80.0	5.2	0.3	19.0
RCE 平均値	87.1	8.7	4.2	63.9
標準偏差	17.6	13.9	20.2	4.1
最大値	90.6	13.2	10.1	75.0
最小値	82.8	6.0	1.2	56.0

表3: パラメータの使用値

R (RCEの初期半径も同じ)	0.5
RCEの半径縮小率	20%
DC_{up}	1
DC_{down}	1
C_{limit}	-1
C_{start}	3
データの中心	(0, 0), (2, 2)
データの分散	1.0

3.2 実験結果

正答率はCCNN2, RCE, CCNNの順で高く, リファレンス数はCCNN, CCNN2, RCEの順で少なかつた. CCNN2は正当率, リファレンス数とともにRCEよりも良好な結果であった. リファレンス数ではCCNN2がCCNNより多くなっている. これは, CCNN2の方が不答率が小さいことからわかるように, CCNNでは, リファレンスの位置が固定であるため, パターン空間にすき間が生じているためである. これに対してCCNN2は移動によってすき間なくパターン空間を埋めている.

また, 標準偏差, 最大値, 最小値からわかるように, CCNNでは正答率の変動が大きいのに対し, CCNN2は安定して高い正答率を示した.

4 まとめ

RCEでは, 初期半径や半径縮小率を問題に合わせて調整することで, より効率的に学習を行なえる可能性がある. 同様にCCNN2においても, 半径やカウンタの増減法, 移動法などを調整することが可能である. RCE, CCNN2のような環境適応型のニューラルネットワークの調整要素として半径, 位置, カウンタの3つの要素をどのように調整するかで, モデルの特徴が決まってくる.

リファレンスの半径を固定とし, 位置およびカウンタの調整で学習を行なう本方式は, 機器組み込みなどの用途において, それぞれの場合に合わせた半径の設定が行なえれば, 簡易なアルゴリズムで, 認識率, 記憶容量とも優れたモデルであると言える.

参考文献

- [1] 志田武彦, 中基孫, 吉田邦夫, 環境適応型のパターン分類ニューラルネット, 情処学第44回全大5R-5, 1992
- [2] D.L.Reilly et al., Neural Model Category Learning, Biol.Cybern, Vol.25, 1982