

1 E-8

## 追記学習型ニューラルネット

佐藤 敦 山田 敬嗣 津雲 淳 天満 勉

日本電気(株) C&amp;C情報研究所

## 1.はじめに

適応型のパターン認識システムでは、誤認識したデータに対して再学習を行ない認識率を向上させる「追記学習」と呼ばれる学習が重要であるが、多層ニューラルネットを用いた場合いくつかの問題が生じる。多層ニューラルネットの学習には一般に誤差逆伝播法[1] (BPと略す) が用いられるが、学習に長時間を要することと誤認識したデータみならず過去の学習に用いたデータも含めて学習しなくてはならない問題があり、誤認識したデータのみを追記学習する目的には適さない。また、中間層のユニット数を固定した場合、追記学習によって学習すべきデータ量が増加すると学習の収束に問題が生じる。

これらの問題を解決するために、特徴空間のある部分空間のみに発火する興奮性および抑制性ニューロンを中間層に追加し、BPで学習されたネットワークと統合することにより追記学習を可能にするニューラルネットとその学習方法を提案した[2]。今回は既に提案したモデルの一般形である新たなモデルを提案する。

## 2. ネットワークの構造

## 2.1 従来のモデル(モデルA)

まず、既に提案した追記学習型ニューラルネット(モデルA)について簡単に述べる。このモデルの構造を図1に示す。入力層、固定中間層、出力層はBPによって既に学習が行なわれた3層のフィードフォワード型のネットワークである。追記学習の段階ではこれら各層間の結合は一切変更されず、追加中間層にニューロンが追加される。

追加中間層に追加されるニューロン(以後追加ニューロンと呼ぶ)の出力値 $z$ を次式で定義する。

$$z = 1 [\vec{w} \cdot \vec{x} / |\vec{x}| - h] \quad (1)$$

ここで、 $\vec{x}$ 、 $\vec{w}$ 、 $h$ はそれぞれ入力ベクトル、荷重ベクトル、しきい値である。1[]は階段関数を表す。また荷重ベクトルは大きさが1に正規化されている。入力ベクトルは大きさが1に正規化されるため、単位球の球面上に存在することになる。従って、(1)式で示される追加ニューロンの発火領域は、原点からの距離が $h$ である超平面より外側の球面上となる。

追加ニューロンの出力は統合層のニューロンへ興奮的あるいは抑制的に結合される。統合層のニューロンは、それに結合している追加中間層のニューロンのうち、発火している興奮性ニューロンがあればON、発火している抑制性ニューロンがあればOFF、それ以外の場合は出力層からの出力をそのまま出力する。

追加ニューロンによる特徴空間上のカテゴリ領域の変化の様子を図2に示す。2つの円はそれぞれ興奮性、抑制性ニューロンの発火領域、灰色はカテゴリ領域を示す。

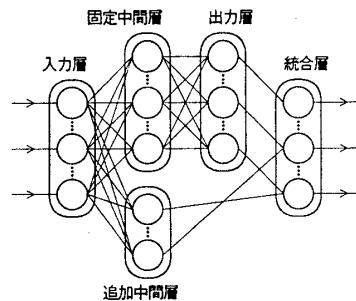


図1 追記学習型ネットワークの構造(モデルA)

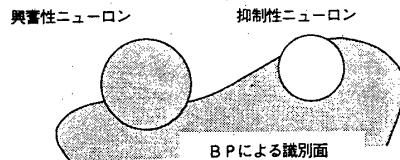


図2 カテゴリ領域の変化(モデルA)

## 2.2 提案するモデル(モデルB)

モデルAにおける統合層は、BPで学習されたネットワークの出力より追加ニューロンの出力を優先する働きをする。しかし、追加ニューロンの発火領域の大きさを決定するしきい値 $h$ の設定は難しく、発火領域を大きくすると認識率が低下する。この現象を少しでも抑えるために、BPで学習されたネットワークの出力分布を考慮した追記学習型ネットワーク(モデルB)を今回提案した。

図3にモデルBの構造を示す。入力層、固定中間層、出力層はモデルAに用いられているものと同じ3層のフィードフォワード型のニューラルネットである。追加中間層に追加されるニューロンもモデルAのものと同様で、(1)式に従う。モデルAとの違いは、追加ニューロンが出力層のニューロンと重み付き結合をしていることにある。

追加ニューロンによる特徴空間上のカテゴリ領域の変化の様子を図4に示す。2つの円はそれぞれ興奮性、抑制性ニューロンの発火領域、灰色はカテゴリ領域を示す。興奮性ニューロンの発火領域内では、識別面はカテゴリの外側へ移動し、抑制性ニューロンの場合はカテゴリの内側へ移動する。識別面の移動量は興奮性、抑制性結合の強さに依存し、十分大きな強度で結合した場合にはモデルAと同等の識別面を構成することから、モデルBはモデルAの一般形と考えられる。この結合強度の調整により追加ニューロンによる悪影響を少なくすることが可能で、モデルBはモデルAより誤認識の少ない識別面を記述できる。

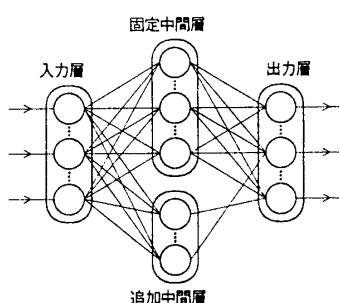


図3 追記学習型ネットワークの構造（モデルB）

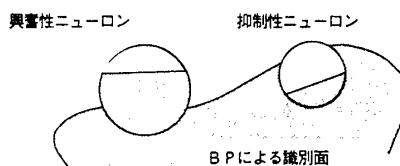


図4 カテゴリ領域の変化（モデルB）

### 3. 追記学習のアルゴリズム

学習はBPによる学習と追記学習2段階に分かれる。まず、学習データを用いて3層のネットワークをBPにより学習させる。この段階では、追加ニューロンは1つも存在しない。BPの学習が完了した後、認識過程において誤認識が生じた場合に追記学習を行なう。

モデルBの追記学習アルゴリズムを簡単に述べる。ニューラルネットを用いたパターン認識では、入力が属すべきカテゴリを表わすニューロンの出力が小さい、あるいは入力が属すべきでないカテゴリを表わすニューロンの出力が大きかった場合に誤認識と判断される。従って、誤認識した入力を正しく認識させるためには、出力層の各ニューロンの出力値を上げる手順と下げる手順を用意すればよい。

まず、出力値を上げる手順を述べる。出力層のニューロンに結合している追加ニューロンのうち、発火している抑制性ニューロンがあればそのしきい値を上げる。それでも出力値が上がらない場合は、発火している興奮性ニューロンを捜す。もしそのようなニューロンがあれば出力値が上がるまでその結合を強化し、なければ新しく興奮性ニューロンを追加して出力値を上げる。以上の手順で出力層ニューロンの出力値を必ず上げることができる。

次に、出力値を下げる手順を述べる。出力層のニューロンに結合している追加ニューロンのうち、発火している興奮性ニューロンがあればそのしきい値を上げる。それでも出力値が下がらない場合は、発火している抑制性ニューロンを捜す。もしそのようなニューロンがあれば出力値が上がるまでその結合を強化し、なければ新しく抑制性ニューロンを追加して出力値を下げる。以上の手順で出力層ニューロンの出力値を必ず下げることができる。

モデルAの追記学習アルゴリズムは、結合強度の変更がない点を除けば、モデルBの場合と同じである。

### 4. シミュレーション実験

モデルAおよびモデルBを用いた追記学習のシミュレーション実験結果をそれぞれ図5、図6に示す。この図は3

次元単位球面を2次元平面で表現したものであり、●、▲はそれぞれカテゴリA、Bに属する入力データである。まず、○で囲まれた●と△で囲まれた▲を学習データとしてBPを行なった。その結果構成された識別面を小さい○と△で示す。さらにカテゴリAに属するデータ5点、Bに属するデータ2点を用意し追記学習を行なった。実線および点線で示された楕円はそれぞれ興奮性、抑制性ニューロンの発火領域である。最終的なカテゴリA、Bの領域を横線および縦線で示す。黒で示したのは、カテゴリAとBの両方を含む領域である。両モデルとも、BPで学習されたネットワークでは誤認識するデータが追記学習によって正しく認識されることが示されたが、モデルBの方がモデルAより正確なカテゴリ領域を形成していることが分かった。追記学習に要した学習回数はモデルAが4回、モデルBが3回であった。また、追加されたニューロンの数は、モデルAの場合は興奮性ニューロンが4個、抑制性ニューロンが5個、モデルBの場合はそれぞれ4個であった。

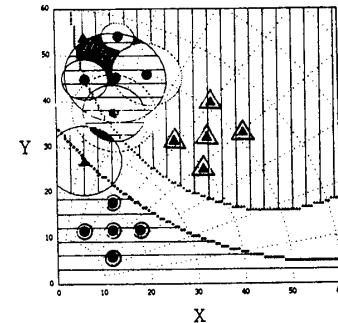


図5 シミュレーション実験（モデルA）

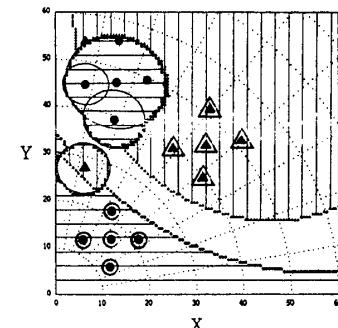


図6 シミュレーション実験（モデルB）

### 5.まとめ

追記学習を可能にするニューラルネットとその学習方法を提案した。BPで学習されたネットワークでは誤認識するデータが追記学習により正しく認識されることがシミュレーション実験により示された。モデルBはモデルAに比べ学習回数、追加ニューロン数が少なく、より正確なカテゴリ境界を構成することがわかった。これらのモデルを用いれば、個人用の認識辞書の作成も可能である。今後、さらに多くのデータを用いた実験を行ない、手書き文字認識などに応用して本モデルの有効性を示すつもりである。

### 参考文献

- [1] D. E. Rumelhart et al.: "Parallel Distributed Processing, vol. 1", MIT Press (1986).
- [2] 佐藤、山田、天満：「追記学習型ニューラルネット」信学秋全大'90