

4 G-4 ニューラルネットワーク構成アルゴリズムを用いた 手書き文字認識

岩佐武則 赤松則男
徳島大学 工学部

1. まえがき

近年、ニューラルネットワークは、文字認識、音声認識、画像処理等の分野で応用されている。ニューラルネットワークの利点として、以下のものが挙げられる。①並列処理を行う。②学習を行う。③学習パターンの補間性がある。また、バックプロパゲーション法(以下BP法)に代表される従来の学習方法の問題点として、以下のものが挙げられる。④ネットワークが大規模、あるいは学習パターンが多くなると、学習時間が増加する、または収束しない。⑤ハードウェアの集積化が難しい。④⑤の問題解決のためにいくつかの研究が行われているが、根本的な解決までには至っていない。本論文では、①～③のニューラルネットワークの利点を継承し、④⑤の問題点を克服するニューラルネットワーク構成アルゴリズムHPS(Hyper-Plane Separation)法を提案する。提案するアルゴリズムは、入力パターンが2値を対象とし、3層ネットワークで中間層を増加させることによりパターンの分離を行う。学習パターンを何回も提示させる必要がないため、学習が高速であり、ネットワークの重みが2値であるため、ハードウェア化が容易となる。将来、ハードウェアで実現されれば、リアルタイムな学習が可能と考えられる。

本論文では、アルゴリズムの原理を述べ、手書き入力文字に対してBP法との比較を行い、その有効性を検討する。

2. 学習アルゴリズムHPS法

2.1 構成されるネットワーク

本アルゴリズムで構成されるネットワークは3層ネットワークで、中間ユニットは全ての入力ユニットと結合し、特定の出力ユニットと結合する。

ネットワークのパラメータは次の値をとる。

入力値 : 1, 0
入力層と中間層の重み: 1, -1
中間層と出力層の重み: 1, 0
しきい値 : 整数+0.5
また、中間ユニット数は、学習時に決まる。

2.2 HPS法の基本的理論

出力ユニットaに発火させようとするパターン集合をAグループ、発火させないパターン集合をBグループとする。学習は、Aグループのパターンを追加していき、Bグループから分離する平面を作成する。ここで、入力パターンベクトル $X = (x_1, x_2, \dots)$ 、重みベクトル $W = (w_1, w_2, \dots)$ 、閾値をTHとする。ニューロンの特性関数

$$f(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases} \text{を定義する。}$$

入力パターンベクトルXに対して、 $y = f(X \cdot W^T - TH)$ とおくと、 $X \cdot W^T - TH > 0$ のとき
 $y = 1$: ニューロンが発火する。・・・①
 $X \cdot W^T - TH \leq 0$ のとき
 $y = 0$: ニューロンが発火しない。・・・②

最初に追加されたAグループのパターンを $X_{k,y}$ とおき、 $X_{k,y}$ が原点になるように、全ての学習パターンLに対して、次の座標変換を行う。
 $Trans(L) = (X_{k,y}, EXOR L)$
また、 $X_{k,y}$ と座標変換後のパターン $Trans(L)$ との距離Hを
 $H = Trans(L) \cdot W^T$ ・・・③と定義する。
ここで、次の初期設定を行う。
閾値 $TH = (X_{k,y}$ と $X_{k,y}$ に最も近いBグループのパターンとの距離)+0.5
重みベクトル $W = (-1, -1, -1, \dots)$

すると、 $X_{k,y}$ とBグループのパターンに対しては①②の条件より、パターンの分離ができる。次に、新しいAグループのパターンを追加したとき、学習は、Wの要素 w_k を-1→1に変更することにより行う。式③より、Wの要素 w_k を-1→1に変更するとXの要素 x_k が1である全てのベクトルと $X_{k,y}$ の距離が2だけ近くなる。したがって、 $X_{k,y}$ と全てのBグループのパターンとの距離を求め、Wの要素の中で、変更してもBグループのパターンが閾値を越えない所を変更し、追加されたパターンが閾値を越えるようにする。追加されたパターンが閾値を越える事ができないとき、つまり、変更するWの要素が無くなったとき、追加されたパターンを $X_{k,y}$ として、新しく重みベクトルWと、閾値THを作成する。

このようにして決められた最終的なWが入力ユニットと中間ユニットの重みとなり、閾値THが中間層の重みとなる。また、出力ユニットaと、このとき作成された中間ユニットの重みは1となり、それ以外の重みは0となる。

このように、 $X_{k,y}$ と他の全てのパターンとの距離を求めて、 $X_{k,y}$ を中心として学習を行う。

$w_2, \dots)$ 、閾値をTHとする。

ニューロンの特性関数

$$f(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases} \text{を定義する。}$$

入力パターンベクトルXに対して、

$y = f(X \cdot W^T - TH)$ とおくと、

$X \cdot W^T - TH > 0$ のとき

$y = 1$: ニューロンが発火する。・・・①

$X \cdot W^T - TH \leq 0$ のとき

$y = 0$: ニューロンが発火しない。・・・②

最初に追加されたAグループのパターンを $X_{k,y}$ とおき、 $X_{k,y}$ が原点になるように、全ての学習パターンLに対して、次の座標変換を行う。

$Trans(L) = (X_{k,y}, EXOR L)$

また、 $X_{k,y}$ と座標変換後のパターン $Trans(L)$ との距離Hを

$H = Trans(L) \cdot W^T$ ・・・③と定義する。

ここで、次の初期設定を行う。

閾値 $TH = (X_{k,y}$ と $X_{k,y}$ に最も近いBグループのパターンとの距離)+0.5

重みベクトル $W = (-1, -1, -1, \dots)$

すると、 $X_{k,y}$ とBグループのパターンに対しては①②の条件より、パターンの分離ができる。次に、新しいAグループのパターンを追加したとき、学習は、Wの要素 w_k を-1→1に変更することにより行う。式③より、Wの要素 w_k を-1→1に変更するとXの要素 x_k が1である全てのベクトルと $X_{k,y}$ の距離が2だけ近くなる。したがって、 $X_{k,y}$ と全てのBグループのパターンとの距離を求め、Wの要素の中で、変更してもBグループのパターンが閾値を越えない所を変更し、追加されたパターンが閾値を越えるようにする。追加されたパターンが閾値を越える事ができないとき、つまり、変更するWの要素が無くなったとき、追加されたパターンを $X_{k,y}$ として、新しく重みベクトルWと、閾値THを作成する。

このようにして決められた最終的なWが入力ユニットと中間ユニットの重みとなり、閾値THが中間層の重みとなる。また、出力ユニットaと、このとき作成された中間ユニットの重みは1となり、それ以外の重みは0となる。

このように、 $X_{k,y}$ と他の全てのパターンとの距離を求めて、 $X_{k,y}$ を中心として学習を行う。

2.3 学習アルゴリズム

●のパターンの集合を○のパターンの集合から分離するアルゴリズムを述べる。

①最初の●の追加パターンを $X_{k,y}$ とする。

- ② $X_{k,y}$ が原点になるように座標変換を行う。
 $Trans(L) = (X_{k,y}, EXOR L)$
- ③ 閾値 $TH = (X_{k,y}$ と $X_{k,y}$ に最も近いBグループのパターンとの距離) + 0.5
 重みベクトル $W = (-1, -1, -1, \dots)$ とおく。
- ④ 条件：まだ分離されていない●のパターンがある。
 True : ⑤へ
 False: 終了
- ⑤ 条件：●のパターンと $X_{k,y}$ の距離 > TH
 True : ④へ
 False: ⑥へ
- ⑥ 条件：Wの重みを $-1 \rightarrow 1$ にすることにより、分離することに成功すると、
 True : ④へ
 False : ⑦へ
- ⑦ 新しい平面の作成を行う。④へ。

2.3 パターン空間

HPS法が対象とする入力値は、'0'、'1'であるため、入力ユニット数がn個の場合の入力ベクトルはn次元空間内での超立方体の頂点となる。

3次元空間内でのパターン分離例を図1に示す。




図1. 3次元パターン空間

図1のように平面が作成された場合のネットワークを図2に示す。




図2. 作成されたネットワーク

本アルゴリズムはBP法等のようにネットワークの重みを変更しながら学習するのではなく、中間ユニットを増加することにより分離するため速く学習し、ネットワークの規模にかかわらず学習する。しかし欠点として異なる種類のパターンのグループに似たパターンが存在すると、他の学習方法と比較して中間層の数が増加する傾向がある。

3. HPS法とBP法との比較実験

3.1 実験内容

ペン入力装置により入力された手書き文字データ、'あ'～'お'に対して、本学習法とBP法について以下の実験を行った。

- ① 各10パターンの学習。(学習パターン50個)
- ② 各20パターンの学習。(学習パターン100個)

③ 各30パターンの学習。(学習パターン150個)

④①～③に対して、未学習パターン各20個の認識。

入力データとして図3のように、ペン入力によって得られる端点座標データを用いた。また、本学習法が対象とするネットワークは入力値が2値であるため、次の変換で、整数値を2値データにする。

$$0 \rightarrow 00000\dots \quad 1 \rightarrow 10000\dots \quad 2 \rightarrow 11000\dots$$

これにより、整数値での距離と2値データ化後のハミング距離が同じに保たれる。




図3. 文字パターン(32×32)

3.2 実験結果

BP法は、中間ユニット数20個、モーメント法を用い、 $\alpha = 0.2$, $\beta = 0.2$, $moment = 0.8$ とした。

表1 HPS法の中間層の数

	学習パターン		
	50個	100個	150個
HPS法	5個	6個	6個

表2. 未学習パターン100個に対する認識率

	学習パターン		
	50個	100個	150個
HPS法	86%	88%	87%
BP法	89%	95%	99%

本学習法は重みが2値であるため、BP法と比較した場合に汎化能力が劣るが、高い認識率であった。また学習時間も高速であった。

4. おまわり

本論文では学習アルゴリズムを提案し、BP法との比較を行った。本アルゴリズムは学習が速く、入力値が2値であるため、ハードウェア化が容易になる反面、認識率が下がる。今後の課題として入力データの工夫をしなければならない。

参考文献

- (1) 岩佐：“文字認識におけるニューラルネットワークのパターン分離アルゴリズムの提案”，平成3年度電気関係学会連合大会論文，pp461-462，1991。
- (2) 甘利監訳：“PDPモデル認知科学とニューロン回路網の探索”，産業図書，1989。
- (3) Scott, E.F. and Christian, L: “The Cascade-Correlation Learning Architecture”, Computer Science, 1990
- (4) 立木，木下：“ニューラルネットワークによる手書き文字認識”，沖電気研究開発，vol. 58 No. 2 pp53-56 1991