

パターン認識用ニューラルネットは いかにして構成できるか?

1L-10

阿部重夫 鹿山昌宏 武長寛

(株) 日立製作所 日立研究所

1. はじめに

教師データを用いてシナプスの重みを学習することにより容易にパターン認識用のニューラルネット¹が構成できるため、パターン認識はニューラルネットの重要な応用分野となっている。しかしながら、アルゴリズムが必要であること、あるいはニューラルネットがブラックボックスとして扱えるというメリットが逆にデミメリットとなることがある。例えば誤認識が生じたとき認識率を改善する方法はそのデータを追加して再学習するしか今のところ手がない。このような問題を解決して実用的なニューラルネット技術するために我々はニューラルネットの特性の解明を進めた。その結果ニューロンの飽和特性の意味、パターン認識用ネットが如何にして構成しうるかについて解明できた。

2. 飽和特性はパターン認識に必須である

図1の3層ニューラルネットについて考える。
図において

$$Z_j(i) = f(X_j(i)) = 1/(1 + \exp(-X_j(i)/T)) \quad (1)$$

$$X_j(i) = \sum_{k=1}^{n(i-1)+1} w_{kj}(i-1) Z_k(i-1) \quad (2)$$

$$Z_n(i-1)+1=1$$

ここで $Z_j(i)$: i層ニューロン j の出力

$X_j(i)$: i層ニューロン j への入力

$w_{kj}(i-1)$: i-1層ニューロン k と i 層ニューロン j




図1 3層ニューラルネット

とを結ぶシナプスの重み

 $n(i)$: i層のニューロン数

Kolmogorovの定理によれば任意の連続関数は単調増加関数の四重の合成関数でいくらでも詳細に近似できる²。従って多層ネットの非線形関数は、飽和特性を持つシグモイド関数でなくてもよいはずである。飽和領域では微係数が0となるため学習の収束性を考えれば飽和特性のないほうがよいといえる。

これに対する答えは次の問題に答えることによって得られた。

中間層のニューロンの数が入出力のニューロンの数よりも少なくともパターン分離は出来るか?

$n(2) < n(3)$, $n(2) < n(1)$ として中間層と出力層との関係を考える。 $n(3)$ 個のパターン入力に対応する中間層出力及び出力層の入出力を $Z_{ij}(2), X_{ij}(3), Z_{ij}(3)$, $i, j = 1, \dots, n(3)$ とすると

$$\{Z_{ij}(3)\} = \begin{bmatrix} 10 & 0 \\ 01 & 0 \\ \dots & \dots \\ 00 & 1 \end{bmatrix} \quad n(3) \times n(3) \text{ 次 } \quad (3)$$

とされる。すなわち行列 $\{Z_{ij}(3)\}$ のランクは $n(3)$ である。これに対して

$$\{X_{ij}(3)\} = \{W_{ik}(2)\} \times \{Z_{kj}(2)\} \quad (4)$$

のランクは $n(2) < n(3)$ であるから行列 $\{W_{ik}(2)\}, \{Z_{kj}(2)\}$ のランクは $n(2)$ で従って $\{X_{ij}(3)\}$ のランクも $n(2)$ となる。すなわちランクが $n(1)$ の入力情報から $n(2)$ に落ちた中間層情報に基いてランク $n(3)$ の情報が再生できるかという問題となる。問題を解く鍵は飽和特性にある。ここでネットワーク出力 $1, 0$ を $1 - \epsilon, \epsilon$ ($\epsilon > 0$) とし指定値の $\pm \epsilon$ 以内に入ったとき収束したとしよう。このとき $Z_i(3)$ の値は、

$$1 \geq Z_i(3) \geq 1 - 2\epsilon \quad \text{あるいは} \quad 2\epsilon \geq Z_i(3) \geq 0 \quad (5)$$

となるから、これに対する $X_{ij}(3)$ は

$$\infty > X_{ij}(3) \geq -T \log(1/(1-2\epsilon)-1)$$

あるいは $-T \log(1/2\epsilon-1) \geq X_{ij}(3) > -\infty$ (6)

となる。これより $\{X_{ij}(3)\}$ のランクが $n(2)$ でも $\{Z_{ij}(3)\}$ のランクは $n(3)$ となりうるのである。すなわち、中間層の数は入出力ニューロンの数より少なくても分離はできるのである。このように飽和特性がパターン分離に重要な役割を果たしているのである。以上のように収束判定を行うとすると1入力 n 出力の1層のニューラルネットの能力に関して次のことを証明できる。

一つの変数 $Z(1) = [0,1]$ の n 個の連続成分は1層のニューラルネットで分離できる。

一つの変数 $Z(1) = [0,1]$ の異なる連続成分は1層のニューラルネットでは同一パターンに分類出来ない。

2番目の性質は Minsky の Perceptron の能力に関する証明と同じ意味を持つ。

3. パターン認識は3層ネットで行えるか?

文献2)によれば任意の連続関数は3層ニューラルネットで構成できる。これに対し文献3)では関数近似を行うときは3層より4層の方が近似の精度、及びニューロン数の点から有利であると述べている。しかしながらどのようにすればネットが構成されるかについては分かっていない。本節では次のことを示す。

n 次元データを m 個のパターンに分類することを考える。 n 次元空間に k 個の超平面が存在しそれらの超平面により m 個の各パターンが単連結領域に分離できるとき、入力 n 、中間層 k 、出力 m の3層ニューラルネットでパターン分離が可能である。

証明の概略を以下に示す。 k 個の超平面を表現する一次方程式の係数を n 個の入力と k 個の中間層の間の重み $W_{ij}(1)$ として設定する。これにより分離平面上の点に対応する中間層出力は $1/2$ となり各パターンに対応する点では $1/2$ とはならない。従って重みを定数倍することにより各パターンに対する中間層出力を 1 、あるいは 0 とすることができます。

中間層と出力の重みはパターンごとに合成でき i 番目の出力ニューロンではパターン i が入力のとき出力が 1 でそれ以外のときは 0 になればよい。ここで $X_{ij}(3) \geq \alpha$ のとき 1 に対応し $X_{ij}(3) \leq -\alpha$ のとき 0 に対応するとすると、パターン i の領域を決定するのに貢献している中間層ニューロンと出力ニューロンと間の重みを中間層出力が 1 のとき 2α 、 0 のとき -2α とすればよい。(証明終わり)

あるパターンが複数の単連結領域からなるときは、各単連結領域に対して上記手順を行い4層目でそれらを合

成すればよい。なおこの証明では証明を簡単にするために、中間層出力を $1,0$ としたが実際にはその必要はない。

図2の2次元パターンについて上記手順を行うと図3のように合成できる。このときパターンIIは単連結でないでパターンIIのみ4層となる。また平面P1はパターンIを分離するのに貢献していないからP1に対応する中間層ニューロンはパターンIに対応する出力ニューロンに接続されていない。




図2 平面上の点の分離




図3 図2のパターンを分離するネット

4. おわりに

パターン認識に対する多層ニューラルネットの飽和特性は必須であること示した。またパターンが超平面により単連結領域に分離できるときは3層ニューラルネットで構成できることを明らかにした。これに基いた学習の高速化⁴に関しては別報に譲りたい。

参考文献

1. D.E.Rumelhart et al, "Parallel Distributed Processing", Vol. 1,2, MIT Press, Cambridge, Mass
2. K.Funahashi, "On the Approximate Realization of Continuous Mapping by Neural Networks," Neural Networks, Vol. 2, No. 3, pp183-192, 1989
3. D.L.Chester, "Why Two Hidden Layers are Better Than One," Proc. IJCNN-90-WASH-DC, pp I-265 - I-268, January 1990
4. 阿部重夫, "多層ニューラルネットの並列順伝播学習法," 人工知能基礎論研究会(SIG-FAI), 1990年6月