

手書き数字認識における階層型ニューラルネットワークの 中間層に関する考察[†]

立石 雅彦^{††} 山崎 晴明^{††}

階層型ニューラルネットワークによる手書き数字認識システムを試作し、中間層の機能を考察した。階層型ニューラルネットワークによる文字認識に関しては多くの研究があり、認識率を上げるための様々な手法が提案されている。しかし認識に重要な機能を果たす中間ユニットそのものについては十分な議論がなされていない。一般にニューラルネットワークは、学習によって獲得した知識を中間層に蓄えると考えられており、中間層の解析は文字認識のしくみを解明する上で重要である。本稿ではニューラルネットワークのシミュレーション結果について述べた後、中間層の役割、および中間ユニットが持つべき重み分布について説明する。また、ニューラルネットワークの冗長度を少なくすることにより、中間層に望ましい重み分布を学習させることができることを示す。

1. はじめに

近年、情報処理の分野では、ニューラルネットワークへの関心が高まり、基礎的な理論や、実用をめざした応用例が数多く報告されている^{2)~5)}。中でもバックプロパゲーション法による階層型ニューラルネットワークは最も活発に研究されているものの一つであり、文字、音声認識等への応用が期待されている。

階層型ニューラルネットワークは学習により獲得した知識を中間層に蓄える。そのため、中間層を解析することによりその知識を if-then の形で取り出したり、ニューラルネットワークの中間層の機能を解明できるものと考えられている。現在のところ、中間層のユニットは、入力パターンのある特徴に選択的に反応することが知られている^{2), 6)}。しかし中間層全体における各ユニットの位置づけ、および中間層と出力層との関係についてはまだ十分な解明がなされていない。

筆者らはバックプロパゲーション法による階層型ニューラルネットワークを手書き数字認識に応用し、認識における中間層の機能について考察した。この学習法では、ユニットの発火関数としてロジスティック関数 $1/(1+\exp(-x))$ を使うのが普通である。しかし我々のモデルでは代りに双曲線関数 $\tanh(x)$ を用いている。発火関数を $\tanh(x)$ に代えたことは、バックプロパゲーション法に本質的な変化をもたらさない。しかしこのモデルは、従来のモデルより中間ユニットの

働きを解釈するのを容易にする。本稿では上述のモデルに基づき、数字認識における中間層の機能を説明する。また、ニューラルネットワークの冗長度を減らすことにより、中間層を効果的に学習させることができ、認識能力が向上することを示す。筆者らは冗長度を減らすのに重みの制限という手法を用いたが、これにより入力パターンの変形やノイズに強い重み分布を得ることができる。

2. ニューラルネットワーク

2.1 構造

筆者らの試作した手書き数字認識システム（以後、本システムと呼ぶ）で使用するニューラルネットワークの構造について述べる。ニューラルネットワークの最小単位であるユニットは複数個のユニットと接続されており、各ユニットから重み付けされた入力信号を受け取る。また、ユニットは自己バイアスを持っており、入力信号に自己バイアスを加えた総和から決まる一つの出力を発生する。このユニットの発火関数は双曲線関数 $\tanh(x)$ である（図 1）。発火関数にシグモイド関数を使う場合はロジスティック関数 $1/(1+\exp(-x))$ を用いるのが普通である。ユニットの出力値は $(0, 1)$ の範囲にあり、その大小によって真／偽を表す。これに対し、 $\tanh(x)$ のモデルでは出力値が $(-1, +1)$ の範囲にあり、正負の符号で真／偽を示し、絶対値が大きいほどその度合が強い。

ユニットを接続する重みは従来のモデルと同様、正負の値をとる。ユニットがある事象の論理値を表すものとみなすと、正の重みはそれをそのまま、負の重みはその否定を相手ユニットに伝えるものと考えること

[†] A Consideration for the Hidden Layer of the Multilayered Neural Network for Hand-written Numeral Recognition by MASAHICO TATEISHI and HARUAKI YAMAZAKI (Systems Laboratories, Oki Electric Industry Co., Ltd.).

^{††} 住電気工業(株)総合システム研究所

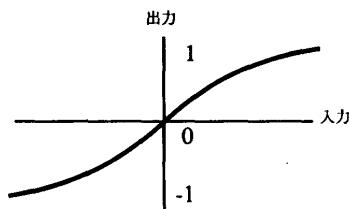


図 1 ユニットの発火関数
Fig. 1 Output function of a unit.

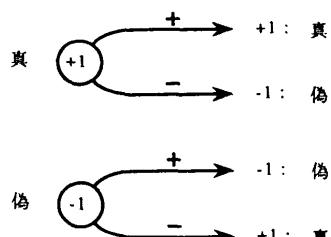


図 2 正負の重みの動作
Fig. 2 Behavior of positive and negative weights.

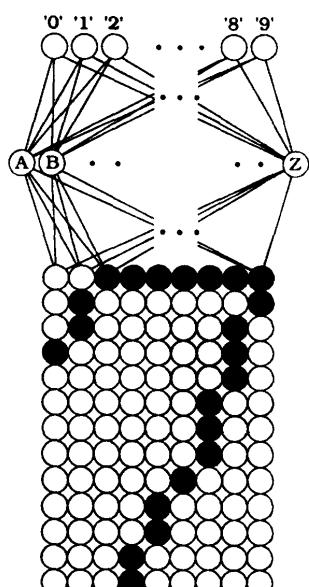


図 3 ユニット間の結合
Fig. 3 Synaptic connections between units.

ができる(図 2).

本システムのニューラルネットワークは、入力層 $9 \times 13 = 117$ 個、中間層 26 個、出力層 10 個のユニットから構成され、隣接する層間はお互いに密結合されている(図 3)。入力層には、前処理によって正規化されたパターンがそのまま表示され、パターンのストロークが乗ったユニットに +1 が、乗らなかったユニットに -1 が設定される。出力層の各ユニットは 0 から 9 の数字に対応し、入力パターンの表す数字に相当

するユニットが最大値を出力する。以後本稿では中間層のユニットに $A, B, C \dots$ 、出力層のユニットに '0' ~ '9' の名前を付け、その名前でユニットを区別する。例えば、ユニット A は中間層の最初のユニットを、ユニット '0' は数字 0 に対応する出力層のユニットを指す。

2.2 学習アルゴリズム

本システムではニューラルネットワークの学習アルゴリズムとして、バックプロパゲーション法を用いている¹¹。ユニット i から j への重みを w_{ji} とすると、一回の学習における重みの変更量 Δw_{ji} は(1)に従う。

$$\Delta w_{ji}(t) = \eta \delta_j u_i + \alpha \Delta w_{ji}(t-1). \quad (1)$$

ここで η は学習率、 δ_j はユニット j における誤差、 u_i はユニット i の出力値、 α は慣性モーメント、 t は学習回数である。

ニューラルネットワークは複雑になるほど学習パターンを適合させるのが容易になり、学習速度も速くなる場合が多い。しかし必要以上にニューラルネットワークを複雑にすると、学習パターンの間にのみ成立する特殊性も学習してしまい、かえって問題の性質を一般化する能力が低下する¹⁰。これを防ぐにはネットワークの冗長度をできるだけ少なくするのがよい。本システムではネットワークの冗長度を減らすため重みの絶対値に制限を設けており、重みの変更は(2)または(3)に示す範囲内で行われる。ここで $|w_{ji}|$ は重み w_{ji} の絶対値を示す。制限値 $\varepsilon_0, \varepsilon_1$ には適切な範囲が存在し、大きすぎる、または小さすぎる場合はよい結果が得られない。

$$\text{入力層-中間層間の重み: } |w_{ji}| \leq \varepsilon_0. \quad (2)$$

$$\text{中間層-出力層間の重み: } |w_{ji}| \leq \varepsilon_1. \quad (3)$$

重みの絶対値を評価する方法としては、例えば絶対値がある閾値 θ を超える重みだけを残し、 θ 以下の重みを消滅させる方法が提案されている⁹。これに対し(2)、(3)は重みをある値以下に押さえ、一つのユニットにかかる負荷を他のユニットに分散する働きをする。その効果については 4.2 節で解説する。

本システムでは、各出力ユニットの誤差が 0.1 以下になった時点でニューラルネットワークが収束したものとみなす。なお、学習開始前のニューラルネットワークの各重みには(4)を満たす値をランダムに与えておく。

$$0 < |w_{ji}| < \varepsilon/2. \quad (4)$$

3. シミュレーション

3.1 ニューラルネットワークの学習

重みの制限の効果を調べるために、中間ユニット数が 10, 14, 18, 22 個のニューラルネットワークを使い、入力層-中間層間の制限値を 0.07 に固定し、中間層-出力層間の制限値 ϵ を $0 < \epsilon \leq 10$ の範囲で変えたときの認識率を調べた。学習パターンには、0~9 の手書き数字を表 1 に示す個数ずつ使用した。各数字のパターンの個数は同一ではなく、複雑な数字、誤認識されやすい数字には多くのパターンを用いている。なお、同一数字のパターンはドット数の比較的少ない 1 を除き、お互いのハミング距離が 6 以上になるよう選択した。

学習時のパラメタは一律に、学習率 $\eta = 0.1$ 、慣性モーメント $\alpha = 0.9$ とした。また 500 回の学習を行っても収束しなかった場合は、その時点で学習を打ち切った。

3.2 認識結果

3.1 節で学習させたニューラルネットワークに未学習の数字パターンを入力し、認識率を調べた。数字パ

ターンは 0~9 それぞれにつき 50 個ずつ用意し、同一数字のパターンは学習パターンと同様、お互いのハミング距離が数字 1 では 4 以上、その他の数字では 6 以上になるよう選択した。これらのパターンを呈示したとき、次の二つの条件を満たした場合にそのパターンが正しく認識されたとみなした。

(i) 入力パターンの表す数字に対応する出力ユニ

表 1 学習パターン数とハミング距離

Table 1 Number and Hamming distance of training patterns for each numeral.

数字	パターン数	ハミング距離
0	60	6 以上
1	33	4 以上
2	60	6 以上
3	84	"
4	66	"
5	83	"
6	70	"
7	72	"
8	79	"
9	77	"
計	684	—

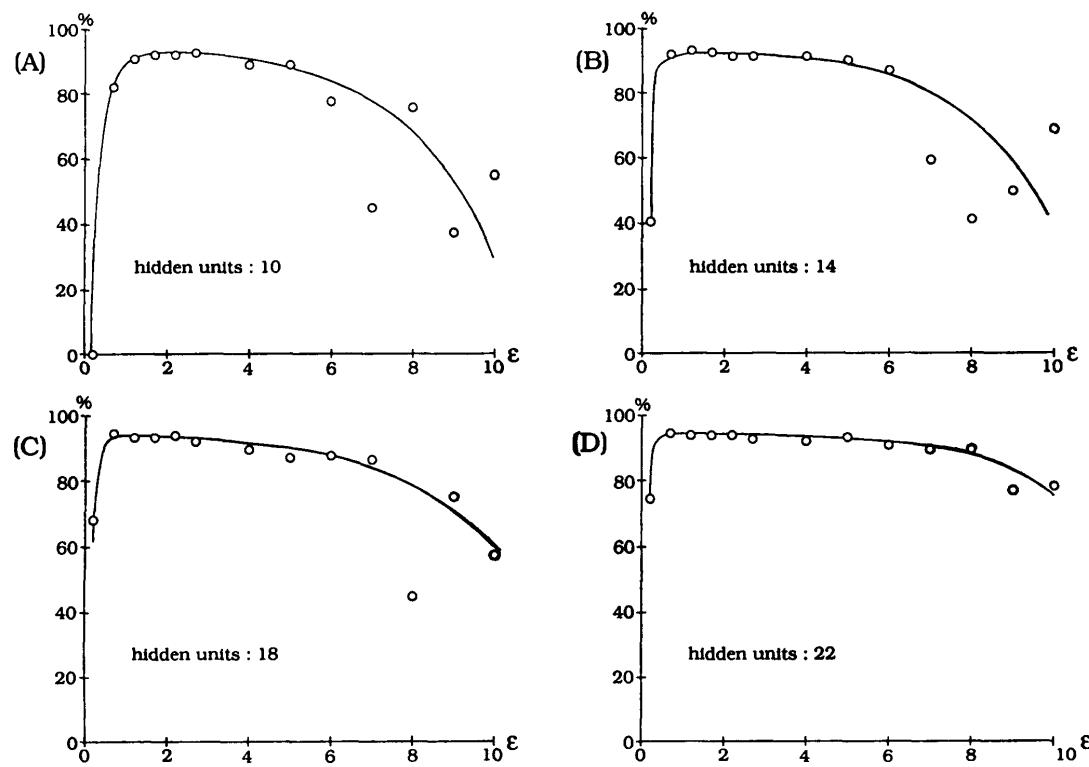


図 4 未学習パターンの認識率
Fig. 4 Recognition rate of test set.

ットが最大値を出力している。

- (ii) (i)の最大値と二番目に大きい出力を示す
いるユニットの出力の差が0.5以上ある。

図4に認識結果を示す。

どのニューラルネットワークも制限値0.7から2.5付近で最もよい認識率を示した。しかし中間ユニットの少ないニューラルネットワークは制限値の増大とともに認識率が下がり、ばらつきが多くなった。一方、中間ユニットの多いニューラルネットワークは広範囲の制限値で安定した認識率を示した。

認識率に関しては、最良の認識率を取って比較する限り、どのニューラルネットにも大きな差はみられなかつた。そこで学習パターン、未学習パターンを入力したときの誤差二乗和を比較した(図5)。誤差二乗和が大きいということは、あいまいな認識が多いことを意味する。たとえば、+1を出力すべきユニットが+0.5を出力し、-1を出力すべきユニットが-0.7を出力するといった場合である。この場合でも条件(i), (ii)は満たされるため、パターンは認識されたものとみなされるが、各ユニットには誤差が生じており、誤差二乗和は増える。

未学習パターンの誤差二乗和は中間ユニットが増えほど全体的に小さくなり、その値が最小となる点は原点寄りになった。これは中間ユニットが増えるほど、最適な制限値が小さくなることを意味する。もう一つ興味深いのは、学習パターンの誤差二乗和が3.0から7.0付近で最小になったのに対し、未学習パターンの誤差二乗和はそれより小さい0.7から2.7付近で最小になったことである。これは学習パターンを完全に学習したニューラルネットワークが、必ずしも未学習パターンに対して最良の認識率を示すわけではないことを意味する。

4. シミュレーション結果の考察

4.1 中間層の機能

数字認識では、中間層が重要な機能を果たす。本システムのニューラルネットワークにおける中間層の各ユニットは以下の働きをする。

入力層のパターンがある特徴を持つか否かを調べ、持っているれば正の値、持っていないければ負の値を出力する。

中間ユニット22個、制限値0.7のニューラルネット

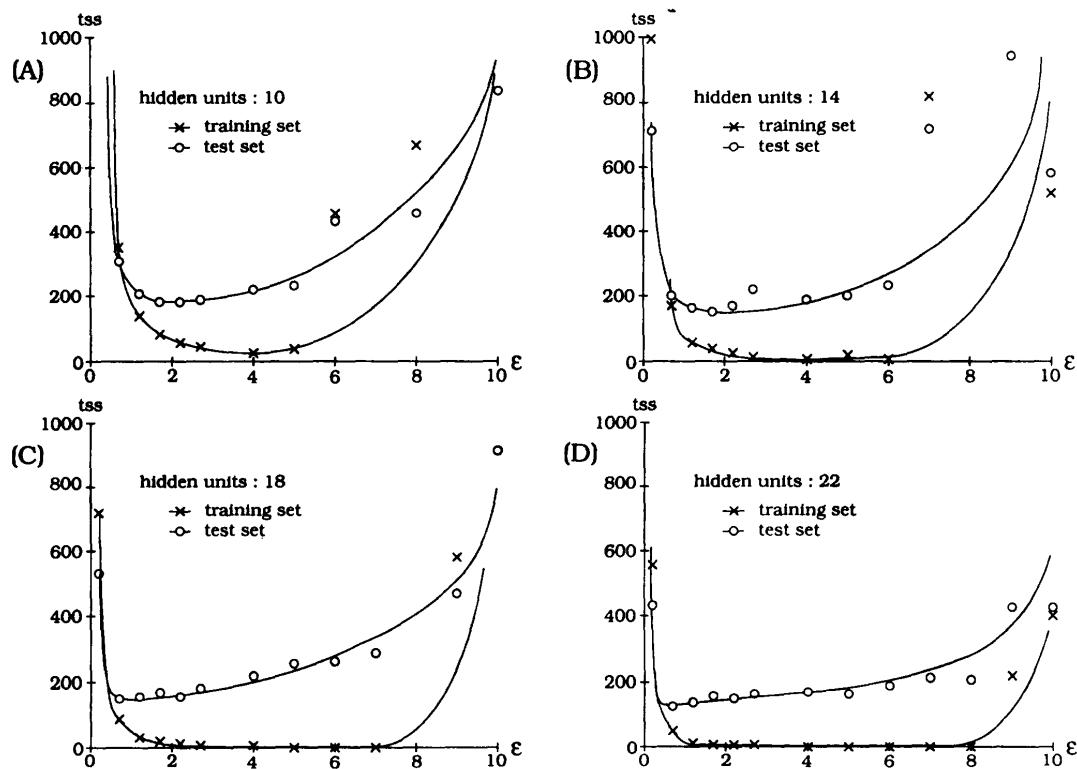


図5 学習パターン、未学習パターンの誤差二乗和
Fig. 5 Total sum of squared error resulting from training and test sets.

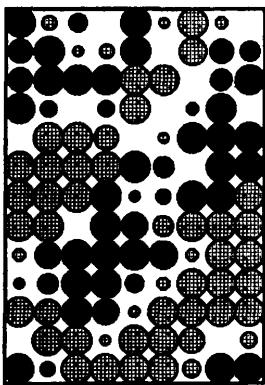


図 6 中間ユニット A の重み分布

Fig. 6 The weights of the hidden unit A: Black and gray circles represent positive and negative weights, respectively. The diameter of each circle is proportional to the absolute value of the weight.

ワークの中間ユニット A を取り出し、入力層間との重みを調べると図 6 の分析図が得られた。ここで黒、灰色の円形領域はそれぞれ正、負の重みを示し、直径がその絶対値に比例するように描かれている。この重み分布は右上から左下の対角線方向に正の重みが集中している。そのためユニット A は「右上から左下に伸びる線を持つ」という特徴に対する特徴抽出器として働き、パターン 2, 7 には肯定を示す正の値を、それ以外のパターンには否定を示す負の値を出力する。

したがって、中間ユニットの抽出する特徴は、ある数字に特有の特徴でなければならない。一般的に、抽出特徴はそれほど単純ではなく、いくつもの特徴を組み合わせた複合的なものであることが多い。また中間ユニットの出力値も +1, -1 とは限らず、入力パターンによっては +0.5, -0.3 といった中間値をとる。つまり出力値はその抽出特徴に関し、入力パターンがどの程度その性質を帯びているかを示す評価値と考えられる。以下、本稿では中間ユニットの抽出特徴をまとめて F (ユニット名) と略記する。(例 $F(A) = \{$ 右上から左下に伸びる線を持つ, … $\}$)。

一方、中間ユニットと出力層間は、以下のようない重みで結合される。

中間ユニットの抽出特徴に関し、ある数字がその特徴を持つなら、それに相当する出力ユニットとの間は正の重みで、持たないなら負の重みで結合される。

重みの正負をそれぞれ中間ユニットの特徴の肯定、否定と捉えると、この結合方法は我々の感覚にもよく合致する。中間ユニット A を例にとると、出力ユニット '2', '7' とは正の重みで、それ以外の出力ユニット

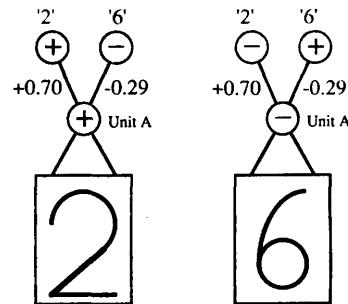


図 7 中間ユニット A と出力ユニットとの接続
Fig. 7 The connections between the hidden unit A and output units.

とは負の重みで結合する。このように接続された中間ユニットは、入力パターンが抽出特徴を持つか否かを調べ、その有無に関して入力パターンと性質の一致する数字の出力ユニットに正の重み付け出力を、一致しない数字の出力ユニットに負の出力を送る。図 7 を用いてその働きを例示する。図中の +0.70, -0.29 は実際に得られた重みの値である。入力層に 2 が表示されると、2 は右上から左下に伸びる線を持つので、中間ユニット A は出力ユニット '2' に正、'6' に負の値を出力する。6 が表示されると、6 は上述の線を持たないので、'2' に負、'6' に正の値を出力する。

中間ユニットが抽出する特徴はほかに、

$$F(B) = \{\text{中心線を持つ}, \dots\}$$

$$\rightarrow 1, 4$$

$$F(C) = \{\text{上部の凸状曲線}, \dots\}$$

$$\rightarrow 0, 2, 3, 6, 8, 9$$

等があり、ユニットによりどの特徴を抽出するのかが異なる。これらは各自の抽出特徴に関し、入力パターンと性質の一致する数字の出力ユニットに正の値を、それ以外のユニットに負の値を送る。こうして、各中間ユニットの抽出特徴 $F(A), F(B), \dots$ に関し、入力パターンに一番近い性質を持つ数字の出力ユニットが最も多くの中間ユニットから正の重み付け入力を受けて最大値を出力する。

4.2 重みの制限の効果

ニューラルネットワーク学習時における重みの変更是(1)にしたがって行われる。しかし無制限に変更を許すと、一部の重みが他に比べて著しく大きくなるという現象が起きる。これは次に述べる理由から、入力パターン全体の特徴を評価するのを妨げ、耐変形、耐ノイズ性を低下させる。

(2), (3)に示したように、本システムでは、入力層-中間層間、中間層-出力層間の重みを制限してい

る。重みの制限はニューラルネットワークの冗長度を減らし、パターンの一般的な性質を抽出させるのに有用である。その具体的な効果について以下に述べる。

4.2.1 入力層-中間層間の制限

入力層に認識対象のパターンをそのまま表示するニューラルネットワークでは、パターンが多少変形したり、ノイズによって数個のユニットが反転しても同じような結果を出力するのが望ましい。そのためには入力層の一部の領域ではなく、全体をほぼ均一に評価する必要がある。

しかし入力層上に大きな重みを持つユニットが存在すると、そのユニットを含む入力層上的一部の領域が強調され、極端な場合は一つのユニットが状態を変えただけで出力層には全く違った結果が現れる。このように訓練されたニューラルネットワークは、変形やノイズがわずかであっても、その影響が重みの大きいユニットに及んだ場合、文字を正しく認識することができない。

入力層-中間層間の重み制限は、上述のユニットの発生を防ぎ、特定のユニットにかかる負荷を周囲のユニットに分散する。そのため入力層の各ユニットの影響力は平均化され、パターン全体の特徴を評価する重み分布が得られる。

4.2.2 中間層-出力層間の制限

重みには(4)を満たすランダムな初期値が与えられているが、学習の進行にともない、中間ユニットは徐々に特徴抽出機能を獲得する。図8(A), (B), (C)はそれぞれ50, 100, 500回の学習を繰り返したときの中間ユニットAの重み分布である。(B)ではかなり特徴抽出が進んでいるが、(C)に比べ正負の大きな重みがと

なり合わせになっている箇所が多い。このような重み分布を持つ中間ユニットは同一数字のパターンであっても、変形や位置ずれが重みの境界にかかったとき出力が大きく変動する。

しかし中間層-出力層間の重みに制限を加えない場合、ニューラルネットワークは出力の変動を中間層-出力層間で補正して学習を完了してしまう。そのため重み分布は(B)の状態にとどまり、(C)の状態に移行しない。しかも上述の補正是学習パターンの間にのみ正しく働く特殊性の強いものになりやすく、未学習パターンの出力の変動にはうまく動作しない。

重みに制限を加えると、中間ユニットの出力を補正する作用は抑えられ、ニューラルネットワークの一般化能力は向上する。また、重み分布は変形の影響を受けにくい(C)の状態へ移行していく。

4.3 適切な重みの制限値

バックプロパゲーション法には、極小値に陥る、収束に時間がかかるという欠点がある。中間ユニットの個数にもよるが、本システムのニューラルネットワークにおいて、中間層-出力層間の重みの制限値 ϵ と収束状態にはほぼ次の関係が成り立つ。

(1) 制限値が小さい場合 ($0 < \epsilon \leq 3$ 付近)

ニューラルネットワークの冗長度が小さく、限られた状態で解を見つけなければならない。そのため、すべての学習パターンを適合させるのは難しく、ニューラルネットワークは収束しない。誤差二乗和は最終的にはほぼ一定の値になる。

(2) 制限値が中間的な場合 ($3 < \epsilon \leq 7$ 付近)

誤差二乗和はほぼ0になり、完全に収束するかまたはそれに近い状態になる。学習時間は最も短い。

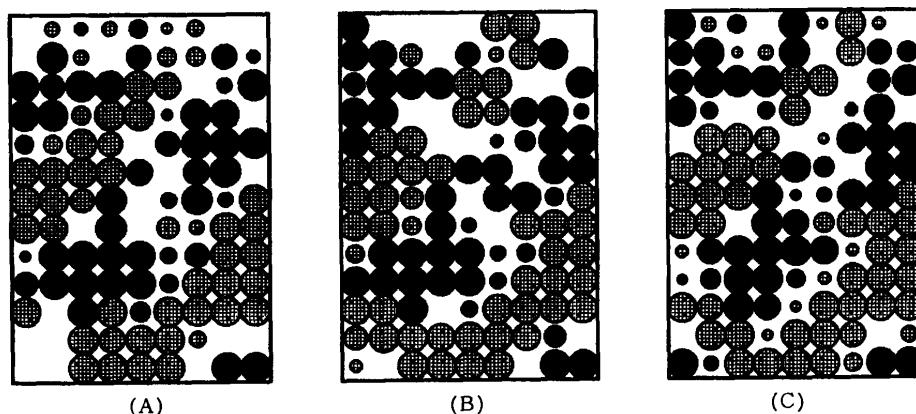


図8 学習過程における重み分布の変化

Fig. 8 Three phases in the development of the weights in course of training: The weights are shown (A) after 50, (B) after 100, and (C) after 500 learning cycles.

(3) 制限値が大きい場合 ($7 < \epsilon$ 付近)

ニューラルネットワークの冗長度が大きすぎるため、安定した状態に落ち着かない。誤差二乗和は増減を繰り返し収束しない。中間ユニットが少なくなるほど誤差二乗和の増減の幅は大きくなり不安定さが増すが、これは一つあたりの中間ユニットの役割が大きく、そこで生じた間違った修正が大きく影響するためと考えられる。

図5において、誤差二乗和が制限値7付近から急増するのはニューラルネットワークが(3)の状態に陥るためである。また、その値は学習を打ち切った時点の誤差二乗和の大小に依存し、ばらつきが多い。

収束という点では(2)が優れている。しかし3.2節で述べたように未学習パターンに対しては、(1)の範囲から制限値を選んだ方がよい結果が得られる。未学習パターンの誤差二乗和は一般化能力の尺度と考えられるが、3.2節の結果は冗長度を小さく設定したニューラルネットワークの方が一般化能力に優れていることを示す。冗長度に余裕を持たせれば学習パターンをすべて適合させるのは容易になるが、これはニューラルネットワークの一般化能力を阻害する。(具体的には、中間ユニットの重み分布が図8(B)の状態にとどまる。)そのため、未学習パターンの認識率はかえって悪くなる。

最適な制限値は中間ユニット数にも依存し、図5に観察されるように中間ユニットが増えるほど小さくなる。この理由は次のように考えられる。

中間ユニットが少ない場合、制限値を小さく設定すると個々の重み付け入力が小さくなり、出力ユニットは肯定=+1、否定=-1を出力するだけの十分な重み付け入力を受け取ることができない。これでは入力パターンを正しく認識できないので、制限値を大きくしなければならない。逆に中間ユニットが多い場合、出力ユニットはより多くの重み付け入力を受け取る。したがって個々の重み付け入力は平均的に小さな値でよく、制限値を小さくすることができます。

5. おわりに

手書き数字認識システムの階層型ニューラルネットワークについて、中間層の機能、重みを制限する方法を論じた。不特定筆記者の手書き文字認識では、ニューラルネットワークに標準的なパターンのほかに、入力される可能性のある変形パターンも学習させる。しかし、英記号のような単純な文字をとっても、多種多様

の変形が存在する。その一つ一つにパターンを用意したのでは、学習パターンの数は膨大になり、ニューラルネットワークの学習はひどく時間のかかるものになる。しかし学習パターン数の増大は、ニューラルネットワークと従来手法との組み合わせによりある程度避けることができる。例えば与えられた文字パターンを最初に従来手法で判別し、認識できなかった文字だけをニューラルネットワークに判別させる方法がある。この方法は従来手法で認識可能な文字パターンをニューラルネットワークに学習させる必要がないので、それらを学習パターンから取り除き、パターン数を減らすことができる。

本システムの問題の一つに、4.1節で述べた中間ユニットによる重み付け評価では、パターンの大まかな特徴しか判別できないことがあげられる。この性質は細かい特徴を見なければならない漢字などには向かない。細かい特徴を判別できない理由の一つとして、本システムで扱ったニューラルネットワークが、各層間のユニットを密結合した単純な構造であることが考えられる。しかしバックプロパゲーション法は、ユニット間の結合を動的に変える能力を持たない。したがって問題に応じた構造は人間が経験的に見つけなければならない、多くの試行が必要となる。バックプロパゲーション法に結合を変える能力を加え、問題の性質に応じたニューラルネットワーク構造を自動的に発見する学習アルゴリズムを考察するのが今後の研究課題である。

謝辞 ニューラルネットワーク・シミュレーションに関して貴重なご意見をいただいた当社総合システム研究所の木下哲男氏、岩根典之氏、中国北方交通大学の羅四維氏に感謝する。また、シミュレータ作成にあたり、UNIX上のプログラミングをご指導いただいた同研究所の中嶋憲吾氏に感謝する。

参考文献

- 1) Rumelhart, D. E., Hinton, G. E. and Williams, R. J.: *Parallel Distributed Processing*, Vol. 1, Chapter 8, The MIT Press (1986).
- 2) Sejnowski, T. J. and Rosenberg, C. R.: NET-talk: A Parallel Network that Learns to Read Aloud, The Johns Hopkins University Electrical Engineering and Computer Science Technical Report, JHU/EECS-86/01, p. 32 (1986).
- 3) Fukushima, K., Miyake, S. and Ito, T.: Neocognitron: A Neural Network Model for a

- Mechanism of Visual Pattern Recognition,
IEEE Trans. Systems, Man, and Cybernetics,
 SMC-13, pp. 826-834 (1983).
- 4) 長田, 木本, 浅川: ニューロコンピュータの原理
 とロボット制御への応用, FUJITSU, Vol. 39,
 No. 3, pp. 175-184 (1988).
- 5) 船橋: ニューラル・ネットワークの capability
 について, 電子情報通信学会技術研究報告,
 MBE 88-52, pp. 127-134 (1988).
- 6) 森, 横澤, 梅田: PDP モデルによる手書き漢字
 認識, 電子情報通信学会技術研究報告, MBE 87-
 156, pp. 407-414 (1988).
- 7) 香田, 高木, メ木: ニューラルネットによる手書
 き英数字認識, 電子情報通信学会技術研究報告,
 PRU 88-57, pp. 71-77 (1988).
- 8) 山田, 上, 溝口, 天満: ニューラルネットを用い
 た文字認識, 電子情報通信学会技術研究報告,
 PRU 88-58, pp. 79-86 (1988).
- 9) 石川: コネクションニストモデルの忘却を用いた
 構造化学習, 電子情報通信学会技術研究報告,
 MBE 88-144, pp. 143-148 (1989).
- 10) 稲葉: ニューラルネット, バックプロパゲーション型改良が進む, 日経エレクトロニクス, No.
 455, pp. 153-160 (1988).
- 11) 麻生: ニューラルネットワーク情報処理, p. 69,
 産業図書, 東京 (1988).

(平成元年1月31日受付)
 (平成元年7月18日採録)



立石 雅彦 (正会員)

昭和37年生。昭和59年名古屋大学工学部電気電子工学科卒業。同年沖電気(株)入社。逐次型推論マシン(PSI)のOSの開発を経て、昭和63年よりニューラルネットワークの研究に従事。OS一般、パターン認識などに興味を持つ。



山崎 晴明 (正会員)

昭和23年生。昭和45年名古屋大学理学部数学科卒業。同年沖電気工業(株)入社。データ通信、ならびに日本語情報処理システムの開発に従事。昭和50年より52年まで、米国、イリノイ大学(アーバナ・シャンペイン校)計算機科学科修士課程にてマルチプロセッサの性能評価に関する研究に従事。昭和53年より沖電気工業(株)総合システム研究所にて、データベース、分散処理、知識情報処理、並列システムアーキテクチャとニューラルネットワーク等の研究に従事。工学博士(名古屋大学)。情報処理学会マルチメディア通信と分散処理研究会幹事。認知科学会会員。