

論文

選択的に教師なし学習を行うニューラルネットワーク

正員 宮嶋 照行[†] 正員 長谷川孝明[†]

正員 羽倉 幸雄[†] 正員 羽石 操[†]

Performance of a Selectively Unsupervised Learning Neural Network

Teruyuki MIYAJIMA[†], Takaaki HASEGAWA[†], Yukio HAKURA[†] and
Misao HANEISHI[†], Members

あらまし ニューラルネットワークをパターン認識に適用する場合、学習データ以外の未知のデータに対してもうまく応答する汎化能力が重要である。特にパターン分布が時間と共に変化する動的環境においては、パターン分布の変化に追従して正しく応答する能力(追従能力)が必要となる。本論文では、選択的に評価データを教師なし学習で学習することで、パターン分布が時間的に変化しないような静的なパターン認識においては高い汎化能力を有し、動的なパターン認識においては追従能力を有するニューラルネットワークについて述べている。静的なパターン認識として、雑音を含む排他的論理問題と手書き漢字認識を行い、本ニューラルネットワークは従来のバックプロパゲーションで学習する3層ニューラルネットワークより、高い汎化能力をもつことを示している。また動的なパターン認識として、直流成分が時間と共に徐々に増加する信号の識別を行い、本ニューラルネットワークが高い追従能力をもつことを示し、静的、動的両面で、本ニューラルネットワークが有効であることを示している。また従来のバックプロパゲーションを用いた階層型ニューラルネットワークは、本ニューラルネットワークの特別な場合という位置付けができる。

キーワード：ニューラルネットワーク、教師なし学習、パターン認識、追従能力

1. まえがき

脳に学んだ情報処理を行うニューラルネットワークは、その学習能力と並列計算性のために、さまざま分野で従来の手法より優れた性能をもつことが報告されている^{(1),(2)}。特にバックプロパゲーションで学習する階層型のニューラルネットワークは、パターン認識の応用分野で注目されている^{(3),(4)}。

ニューラルネットワークをパターン認識に適用する場合、学習に用いたデータ(学習データ)以外の未知の評価データに対してもうまく応答する汎化能力が重要なとなる。実世界のパターン認識問題では、学習データのパターン分布が必ずしも評価データのパターン分布と一致しないため、汎化が困難となっている。

従来の研究では、手書き漢字認識などパターン分布

が時間に不变(静的)なパターン認識を主に対象にしていた。これまでに行われている静的なパターン認識における汎化能力の向上に関する実験的な研究として、中間層のニューロン数を適切に設定する方法⁽⁵⁾、学習データの与え方を工夫する方法⁽⁶⁾、評価関数を工夫する方法^{(7),(8)}などがある。しかしながら実世界のパターン認識問題において工学的に実現が可能で決定的な方法はまだ確立されていない。

一方、経年変化をする音声による話者認識など、パターン分布が時間と共に徐々に変化する(動的な)パターン認識へのニューラルネットワークの適用については、これまでにほとんど検討されていない。動的なパターン認識においては、評価データのパターン分布が変化しても、その変化に追従して正しく応答する能力が必要である。その場合汎化能力は、評価データのパターン分布の変化に対するニューラルネットワークの追従能力としてとらえることができる。

動的なパターン認識においては、学習データによる

[†]埼玉大学工学部電気工学科、浦和市

Faculty of Engineering, Saitama University, Urawa-shi, 338 Japan

学習だけでは評価データの変化に追従することは不可能である。そこで評価データについて学習を行う必要がある。岡本⁽⁹⁾によって、PDM という、パターン分布が不連続に変化する環境に実時間で適応するニューラルネットワークが提案されており、PDM が優れた結果を与えることが報告されている。しかし PDM は教師あり学習に基づくものであった。環境(パターン分布)が不連続に大きく変更してしまう場合には、変化前の環境の情報から変化後の環境を推定することが困難なので、教師によって環境の情報を提供し、ニューラルネットワークの内部を大きく変更しなければ環境の変化に追従できないと考えられる。しかし環境が連続に徐々に変化していく場合には、変化前後の環境間には強い相関があるので、変化前の環境の情報がニューラルネットワーク内にあれば、これを利用することで、外部からの教師がなくても環境の変化に追従できると考えられる。

また静的なパターン認識においても、評価データに対して学習を行うことで、認識性能の向上が期待できるが、そのような手法はほとんどみられない。

また静的、動的いずれのパターン認識についても、学習データで学習済みのニューラルネットワークを作成させた後は、ニューラルネットワークが正しく動作しているかを外部から監視し、状況に応じてニューラルネットワークの動作を一たん停止し再学習するよりも、このような管理をせずにニューラルネットワーク自身で環境に適応していく方が実用上望ましい。従って、教師なし学習により評価データを学習するニューラルネットワークの構築が望まれる。

そこで著者らは、評価データを教師なし学習で選択的に学習する新しいニューラルネットワークを提案⁽¹⁰⁾しているが、本論文では更に詳細な検討を行う。本ニューラルネットワークは、従来のバックプロパゲーションで学習する階層型ニューラルネットワークを含む形式になっている。計算機シミュレーションにより、本ニューラルネットワークは、静的なパターン認識においては高い汎化能力を有し、かつ動的なパターン認識において追従能力を有することを確認する。

2. 選択的に教師なし学習を行うニューラルネットワーク

2.1 選択的に教師なし学習を行うニューラルネットワークの構成⁽¹⁰⁾

図1に本ニューラルネットワークを示す。従来の3

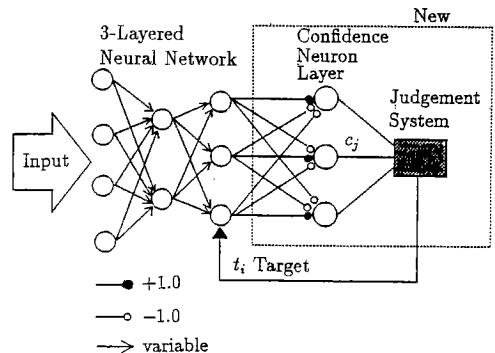


図1 新しいニューラルネットワークの構成
Fig. 1 Structure of the novel neural network.

層ニューラルネットワークに波線で示した新しい部分を付加した構成になっている。出力層のニューロンは認識対象の各カテゴリーに対応している。現在の入力に対して最大の出力を出したニューロンに対応するカテゴリーを認識結果とする。新しく付加した部分は、「確からしさニューロン層」と「判断システム」である。確からしさニューロン層は、出力層のニューロンと同じ数の「確からしさニューロン」からなる。 j 番目の確からしさニューロンは出力層の j 番目のニューロンと 1 対 1 で対応している。判断システムは最大値検出および教師信号の生成を行う。

2.2 自己判断学習

新しく付加した部分の動作を説明する。通常のバックプロパゲーションによる学習でニューラルネットワーク内の各重みが形成された後、ニューラルネットワークは認識動作に入る。2.3で述べるように、このとき同時に新しく付加した部分が動作をはじめる。確からしさニューロン層の j 番目のニューロンと出力層の j 番目のニューロンとの結合の重み w_{jj} は正の定数である。ここでは $w_{jj}=1$ とした。また、確からしさニューロン層の j 番目のニューロンと、出力層の j 番目以外のニューロンとの結合の重み w_{ji} ($j \neq i$) は負の定数であり、ここでは $w_{ji}=-1$ とした。確からしさニューロンは、出力層のニューロンの出力の重み付け加算を計算する。

$$c_j = \sum_{i=1}^N w_{ji} o_i \quad (1)$$

ここで c_j は j 番目の確からしさニューロンの出力、 o_i は出力層の i 番目のニューロンの出力、 N は出力層および確からしさニューロン層のニューロン数である。確からしさニューロンの出力 c_j を「確からしさ」と呼

ぶことにする。確からしさ c_j は、現在の入力が j 番目のカテゴリーに属する確信度を意味している。

判断システムは、確からしさをもとに、現在の入力データを学習するかどうかを決定する。まず判断システムは最大の確からしさを検出する。

$$c_m = \max_j c_j \quad (2)$$

ここで c_m は最大の確からしさである。 m 番目のカテゴリーがニューラルネットワークの認識結果である。もし c_m が、「自己判断のしきい値」と呼ばれる、あらかじめ設定したしきい値 T_s を超えればニューラルネットワークは現在の入力データをバックプロパゲーションで学習する。それ以外の場合は学習は行わない。もし学習すると判断された場合には、判断システムが教師信号を生成する。最大の確からしさを出した m 番目の確からしさニューロンに対応している、出力層の m 番目のニューロンに 1 を、それ以外には 0 の教師信号を与える。以上をまとめて次式に表す。

$$\begin{cases} c_m > T_s \text{ の場合: } t_i = \begin{cases} 1 & (i=m) \\ 0 & (i \neq m) \end{cases} \\ c_m \leq T_s \text{ の場合: 学習は行わない} \end{cases} \quad (3)$$

ここで、 t_i は出力層の i 番目のニューロンの教師信号である。この教師信号はあくまでニューラルネットワーク自身が推定、生成した信号であることに注意を要する。上に述べた学習法を「自己判断学習」と呼ぶことにする。

自己判断学習を定性的に説明すると、認識結果に自信があるときは、現在の入力は m 番目のカテゴリーに属するとして学習を行い、自信がない場合は学習を行わないというものである。

バックプロパゲーションは教師ありの学習法であり、自己判断学習でもバックプロパゲーションを用いているため、計算手続き上教師信号が必要であるが、教師信号を外部から与えずニューラルネットワーク自身が生成するという意味で、自己判断学習を教師なし学習と呼ぶことができる。

2.3 動作モード

本ニューラルネットワークは、「BP モード」と「自己判断学習モード」と呼ぶ二つのモードで動作する。本ニューラルネットワークの動作モードを図 2 に示す。BP モードにおいては、本ニューラルネットワークはバックプロパゲーションで学習するニューラルネットワークと同様に学習データを十分収束するまで学習する。自己判断モードでは 2.2 でも述べたように、評価データについて評価を行いながら、同時に自己判断学習によつ

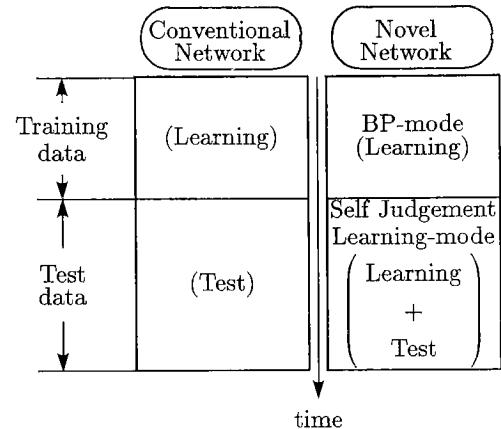


図 2 動作モード
Fig. 2 Operation mode.

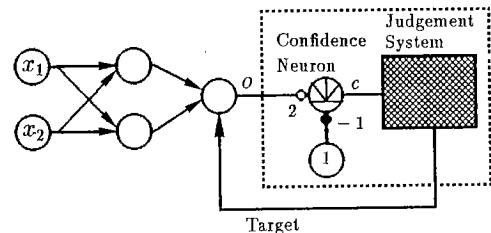


図 3 排他的論理和問題のニューラルネットワーク
Fig. 3 A neural network for exclusive-OR problem.

て選択的に評価データを学習する。

式(1)より明らかのように、確からしさは、 $-(N-1)$ から 1 の値をとる。従って自己判断のしきい値 T_s を 1 に設定したときには評価データに対する学習は行わない。これは従来のバックプロパゲーションで学習を行うニューラルネットワークと等価である。

3. 静的なパターン認識への適用

本ニューラルネットワークの汎化能力を計算機シミュレーションにより評価する。

3.1 排他的論理和問題

静的なパターン認識の基礎的実験として、排他的論理和問題の実現を行う。排他的論理和問題のためのニューラルネットワークの構成を図 3 に示す。論理関数の実現では出力層に一つのニューロンを用意し、その出力値が 0.5 より上か下かで 1 か 0 かを判定すればよい。従って出力層のニューロンが一つのため、前章で説明した確からしさニューロンをそのまま適用することはできない。出力層のニューロンが一つの場合には、

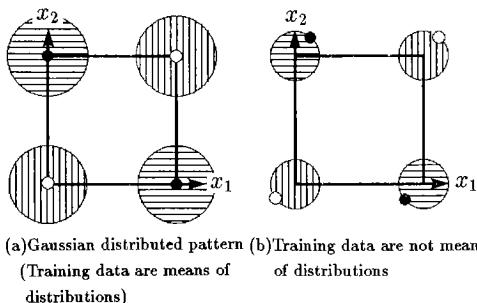


図4 パターン分布
Fig. 4 Pattern distribution.

確からしさニューロンの特性を次式のように改めることが前章で説明したものと等価と考えることができる。

$$c = f(2o - 1) \quad (0 \leq o \leq 1) \quad (4)$$

$$f(u) = |u|$$

ここで \$c\$ は確からしさ, \$o\$ は出力層のニューロンの出力, \$f(\cdot)\$ は出力関数で入力の絶対値をとる。また出力層のニューロンと確からしさニューロンの結合の重みは 2.0 であり, しきい値は 1.0 である。

2種類のパターン分布について検討する。それぞれのパターン分布を図4に示す。(a), (b)いずれのパターン分布も超立方体の各頂点を平均としてガウス分布に従うものとする。学習データは丸印で示してあり、教師信号は白丸に対して0, 黒丸に対して1を与えた。(a)は学習データが超立方体の各頂点にあり、各分布の平均の位置にある場合である。(b)は学習データとして各分布から1点ずつ選択した4点を用いる場合である。評価データは各分布からランダムに選択した。識別するカテゴリーは2種類で、出力が0になるカテゴリーと、1になるカテゴリーで、それを縦線と横線で表している。(a), (b)のいずれも、学習データに対する学習だけでは、評価データをもっとうまく分離する分離面が得られない分布である。

3.1.1 学習データに白色ガウス雑音を付加した場合

図4(a)は評価データとして学習データに白色ガウス雑音を付加した場合であり、学習データはそれぞれの分布の平均の位置にある。これは信号検波などに相当する。雑音のない信号が学習データに相当し、これに伝送路で白色ガウス雑音が付加されたものが評価データに相当する。評価データはランダムに1,000個選択した。

図5に雑音の標準偏差が0.4のときの自己判断のしきい値 \$T_s\$ と認識率の関係を示す。この図より適切な \$T_s\$

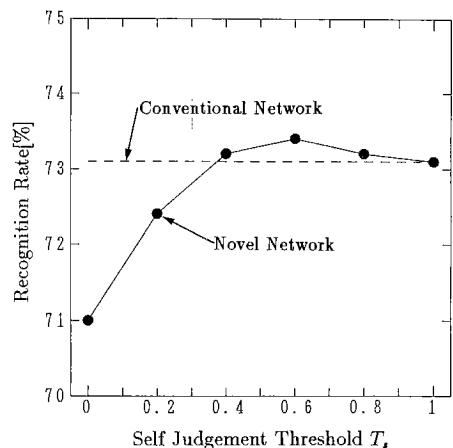


図5 自己判断のしきい値 \$T_s\$ と認識率の関係 (標準偏差 0.4)
Fig. 5 Relation between the self judgement threshold \$T_s\$ and recognition rate (standard deviation 0.4).

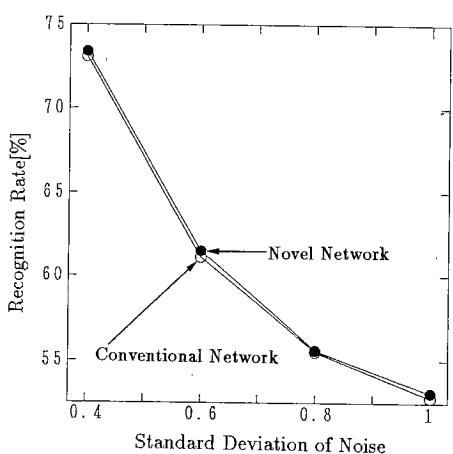


図6 雑音の標準偏差と認識率の関係
Fig. 6 Relation between standard deviation of noise and recognition rate.

に設定すれば、従来のBPで学習する3層ニューラルネットワーク(\$T_s\$が1.0に相当し、その認識率を波線で示した)より認識率(汎化能力)が高いことがわかる。以下の実験では、自己判断のしきい値 \$T_s\$ が適切に設定してあるものとした。

図6に従来のニューラルネットワークと本ニューラルネットワークの雑音の標準偏差と認識率の関係を示す。自己判断のしきい値 \$T_s\$ は、標準偏差が0.4, 0.6, 0.8, 1.0のときそれぞれ0.6, 0.4, 0.6, 0.0を用いた。

この図よりいずれの標準偏差においても、本ニューラルネットワークの方が認識率が高いことがわかる。

表1 学習データがパターン分布の平均でない場合の認識率

ネットワーク	認識率[%]
従来のネットワーク	89.2
本ネットワーク	90.7

表2 手書き漢字認識の認識率

ネットワーク	認識率[%]	
	学習データ	評価データ
従来のネットワーク	100	77
本ネットワーク	100	79

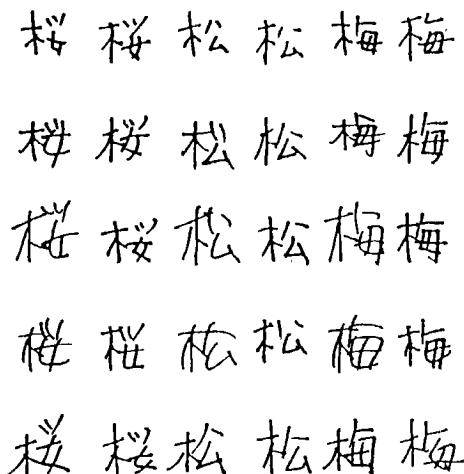


図7 手書き漢字データの例

Fig. 7 Examples of hand written Chinese characters.

3.1.2 学習データがパターン分布の平均でない場合
図4(b)はパターン分布が超立方体の各頂点を平均としてガウス分布に従っており、学習データとして各分布から1点ずつ選択した4点を用いる場合である。これは手書き漢字認識などに相当する。手書き漢字認識などでは、学習データは入手可能なデータの中から任意に選ぶので、必ずしもカテゴリーを最も代表するようなデータを選ぶことはできないからである。評価データはランダムに1,000個選択した。

表1に従来のニューラルネットワークと本ニューラルネットワークの評価データに対する認識率を示す。自己判断のしきい値 T_s は0.3を用いた。認識率は従来のニューラルネットワークでは89.2%，本ニューラルネットワークでは90.7%であり、本ニューラルネットワークの方が認識率が高いことがわかる。

3.2 手書き漢字認識

静的なパターン識別の応用として手書き漢字認識を行う。

手書き漢字データは、10人が「桜」「松」「梅」の3文字をそれぞれ5個ずつ書いたもので、合計150個である。その内、学習データとして60個、評価データと

して90個用いた。手書き漢字データの例を図7に示す。ニューラルネットワークへの入力データとして手書き漢字データの2次元空間スペクトルのパワー情報を用いる。これは、空間スペクトルの位相情報を無視し、パワー情報をのみを用いるため、位置ずれに強く、文字の形状のみに依存する特徴量が抽出でき、位置ずれによる認識率の低下を抑えることができる⁽¹¹⁾。

入力データの処理手順を以下に説明する。

[STEP 1] 128×128のメッシュ状の2値画像である漢字データを、8×8のメッシュごとにまとめ、黒の占める面積から64値化し、16×16のメッシュ状の64値パターンに変換する。

[STEP 2] 2次元FFTを用いて16×16のスペクトル強度を求め、これをニューラルネットワークへの入力データとする。

ここで用いたニューラルネットワークの構成は、入力層のニューロン数が256個、中間層が3個、出力層が3個である。出力層の各ニューロンはそれぞれの文字に対応している。確からしさニューロンの数は、出力層と同じで3個である。

表2に従来のニューラルネットワークと本ニューラルネットワークの認識率を示す。自己判断のしきい値 T_s は0.8を用いた。評価データに対する認識率は、従来のニューラルネットワークでは77%，本ニューラルネットワークでは79%であり、本ニューラルネットワークの方が認識率が高いことがわかる。

「桜」「松」「梅」の識別は比較的類似したパターンの識別であると考えられる。これに対して比較的類似していないパターンの識別として「埼」「玉」「大」の3文字の識別を行った。その結果、評価データに対する認識率は、従来のニューラルネットワークでは約85%，本ニューラルネットワークでは自己判断のしきい値が0.9のときに約86%の認識率が得られた。この場合「桜」「松」「梅」の識別の場合より認識率の高いところでの比較となるので一概に論ずることはできないが、本ニューラルネットワークは、類似していないパターンの識別よりむしろ類似したパターンの微妙な識別に

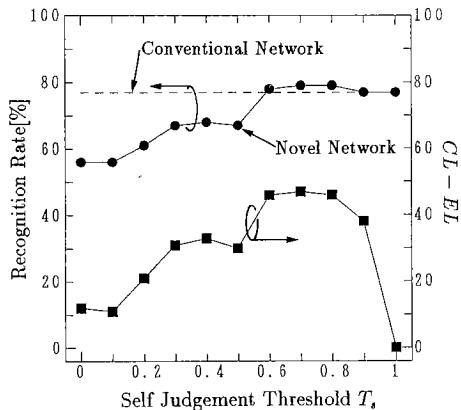


図 8 自己判断のしきい値 T_s と認識率、および $CL-EL$ の関係

Fig. 8 Relation between the self judgement threshold T_s and recognition rate and relation between the self judgement threshold T_s and $CL-EL$.

において従来のニューラルネットワークより認識率が向上するのではないかと考えられる。

以上の結果より、自己判断のしきい値 T_s が適切に設定してあれば、本ニューラルネットワークは従来のニューラルネットワークより汎化能力が高いことがわかつたが、本ニューラルネットワークでは、ニューラルネットワークの出力情報のみから教師信号を生成するので、誤った教師信号を生成し不適切な学習をしてしまう可能性があり、それによって著しく認識率が低下することが予想される。

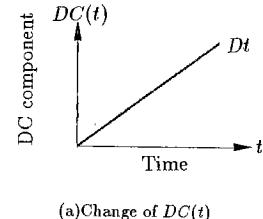
この現象を明かにするために、自己判断学習モードにおいて学習した評価データ数と認識率の関係を調べた。正しく学習したデータ数を CL 、誤って学習したデータ数を EL として、自己判断のしきい値 T_s と認識率、および $CL-EL$ の関係を図 8 に示す。この図より、 $CL-EL$ が高いところ、すなわち正しく学習したデータが多く、かつ誤って学習したデータの少なくなるように、自己判断のしきい値 T_s を設定したとき認識率が高いことがわかる。しかし静的なパターン認識に適用する場合、最適なしきい値を一意に決定する方法は今のところなく、今後の課題である。

4. 動的なパターン認識への適用

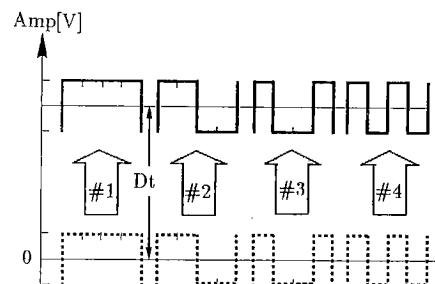
時間と共に徐々に変化するパターン分布に対する、本ニューラルネットワークの追従能力を計算機シミュレーションにより評価する。



図 9 4 ビットの相互に直交した学習データ
Fig. 9 The 4bit orthogonal training data.



(a)Change of $DC(t)$



(b)Examples of the test data

図 10 評価データ
Fig. 10 The test data.

4.1 入力データ

動的なパターン認識として、直流成分が時間と共に徐々に変化する、4 ビットの相互に直交した 4 種類のデータの識別を行う。学習データに用いた 4 種類のデータを図 9 に示す。データを #1 から #4 までを順に表示し、これを 1 サイクルと呼ぶことにする。評価データは、学習データに徐々に変化する直流成分を付加したものである。直流成分の変化は 1 サイクルごとに一定量ずつ増加していく場合について行った(図 10(a))。評価データの例を図 10(b)に示す。

t サイクルでの # i のデータを、 $X_i(t)=(x_{i1}(t), x_{i2}(t), x_{i3}(t), x_{i4}(t))$ ($i=1, 2, 3, 4$) と表す。 t サイクルでのデータ # i の j 番目の要素は、

$$x_{ij}(t)=x_{ij}(0)+DC(t)$$

$$DC(t)=D \cdot t$$

と表される。ここで $DC(t)$ はサイクル t での直流成分、 D は直流成分の増加率である。

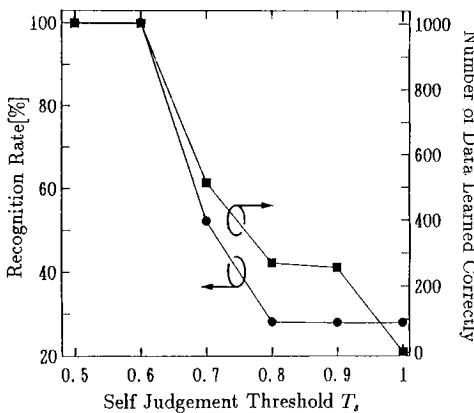


図 11 自己判断のしきい値 T_s と認識率、および正しく学習したデータ数の関係 ($D=0.1$)

Fig. 11 Relation between the self judgement threshold T_s and recognition rate and relation between the self judgement threshold T_s and number of data learned correctly ($D=0.1$).

ここでニューラルネットワークの構成は、入力層のニューロン数が 4 個、中間層が 2 個、出力層が 4 個であり、確からしさニューロンは 4 個である。

4.2 計算機シミュレーション

まず自己判断のしきい値 T_s の最適な値を求めるためにしきい値 T_s を変えたときの認識率を調べた。評価データ数は 1,000 個とし、直流成分の増加率 D を 0.1 とした。図 11 にしきい値 T_s と認識率および正しく学習したデータ数の関係を併せて示す。この結果よりしきい値 T_s が低くなるにつれて、正しく学習した評価データ数が多くなり、同時に、認識率も向上することがわかる。増加率 D を変えて、いくつかの実験を行った結果、図 11 と同様に、いずれの増加率 D においてもしきい値 T_s を適当に低くすると、すべてのデータを正しく学習するようになり、認識率が向上することがわかった。これよりパターンが徐々に変化していく場合には、すべての評価データを学習すると良いことがわかった。以下の実験ではすべての評価データを学習するようにしきい値 T_s を十分低く設定した。

次に追従能力を調べるために、サイクル数 t と認識率の関係を調べる。図 12 に増加率 D が 0.04 のときのサイクル数 t と認識率の関係を、本ニューラルネットワークと従来のニューラルネットワークについて示す。この図より、本ニューラルネットワークはパターン分布の変化にうまく追従し、2,250 サイクルまで認識率が 100 % であり、高い追従能力をもつことがわかる。ま

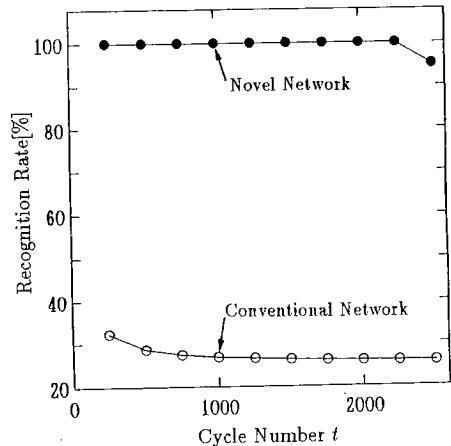


図 12 サイクル数 t と認識率の関係 ($D=0.04$)

Fig. 12 Relation between cycle number t and recognition rate ($D=0.04$).

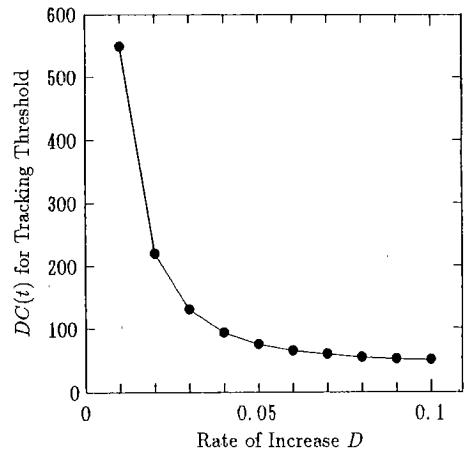


図 13 増加率 D と追従限界の直流成分 $DC(t)$ の関係
Fig. 13 Relation between rate of increase D and $DC(t)$ for tracking threshold.

た従来のニューラルネットワークは、追従能力をもたないため、増加率 D の値によらず直流成分 $DC(t)$ が 0.9 を超えてからは全く認識することができなかった。この結果より、本ニューラルネットワークは、限界はあるが増加率 D が小さければパターン分布の変化に非常に良く追従できることがわかった。

次に本ニューラルネットワークの追従の限界を調べる。増加率 D に対する、#1 から #4 の 4 種類の評価データすべてを正しく認識できた限界の直流成分 $DC(t)$ を図 13 に示す。この図より直流成分の増加率 D が小さくなるにつれて、評価データを完全に認識できる限界

の直流成分 $DC(t)$ は指数的に増加することがわかる。これらの結果より本ニューラルネットワークは、パターン分布が連続に徐々に変化するパターン認識において有効であると言える。

5. むすび

本論文では、評価データに対して選択的に教師なし学習を行う新しいニューラルネットワークについて詳細に検討を行った。

静的なパターン認識として雑音を含む排他的論理和問題と手書き漢字認識を行った。その結果、本ニューラルネットワークは、従来のバックプロパゲーションで学習する階層型ニューラルネットワークに比べ高い汎化能力をもつことを示した。また動的なパターン認識として、時間と共に直流成分の変化する信号の識別を行った。その結果、本ニューラルネットワークは直流成分の変化がゆっくりになるにつれて、追従限界が指数的に増大することを示した。本ニューラルネットワークは、特にパターン分布が連続に徐々に変化する場合のパターン認識に有効である。

本論文で提案したニューラルネットワークを、時間と共に伝送特性の変化する電灯線におけるスペクトル拡散信号の検波に用いた場合に、従来の検波方式に比べて約 5~13 [dB] 性能が向上することが報告されている⁽¹²⁾。これは、評価データが学習データに白色ガウス雑音を付加したものであり、かつ時間と共に徐々に変化する非常に複雑な問題であるが、本ニューラルネットワークの有効性が示された好例である。

今後の課題として、静的なパターン認識に適用する場合の自己判断のしきい値の設定法が挙げられる。2.で述べたように、本ニューラルネットワークは自己判断学習モードにおいて評価データを学習すると判断した場合に、その評価データについてバックプロパゲーションで 1 回だけ学習を行うが、バックプロパゲーションは最急降下法に基づく学習方法であるので、反復計算を必要とするものである。従って対象とする処理内容によって、複数回の学習が可能であれば、評価データについて反復学習することで性能の向上が期待できる。また原理的にはバックプロパゲーション以外の学習方法を用いることも可能である。

文 献

- (1) 麻生英樹：“ニューラルネットワーク情報処理”，産業図書（1988）。
- (2) Lippmann R. P. : “An Introduction to Computing with

- Neural Nets”, IEEE ASSP Magazine, 4, pp. 4-22 (1987).
- (3) Rumelhart D. E., Hinton G. E. and Williams R. J. : “Learning representation by back-propagating error”, Nature, 323, pp. 533-536 (1986).
- (4) Lippmann R. P. : “Pattern Classification Using Neural Networks”, IEEE Communication Magazine, 27, pp. 47-64 (1989).
- (5) 栗田多喜夫：“情報量基準による 3 層ニューラルネットの隠れ層のユニット数の決定法”，信学論(D-II), J73-D-II, 11, pp. 1872-1878 (1990-11).
- (6) 城 和貴, 森 吉弘：“ニューラルネットワークの学習における新しいタイプの教師”，信学技報, PRU88-94 (1988).
- (7) 木村義政：“誤差および出力変動を最小化する学習アルゴリズムとその低品質手書き漢字認識への応用”，信学論(D-II), J73-D-II, 6, pp. 840-847 (1990-06).
- (8) 松岡清利：“誤差逆伝搬法の汎化問題に対する一手法”，信学論(D-II), J73-D-II, 6, pp. 897-905 (1990-06).
- (9) 岡本義則：“環境の激しい変化に適応する神経回路モデル”，信学論(D-II), J73-D-II, 8, pp. 1186-1191 (1990-08).
- (10) Hasegawa T., Miyajima T. and Hakura Y. : “SELECTIVELY UNSUPERVISED DYNAMICAL LEARNING NEURAL NETWORK”, Proc. of ISITA'90, pp. 691-694 (1990-11).
- (11) 長谷川孝明, 津田雄則, 羽倉幸雄：“2 次元空間スペクトルとニューラルネットワークを用いた手書き文字の筆者認識”，信学論(D-II), J73-D-II, 12, pp. 2083-2085 (1990-12).
- (12) Hasegawa T., Daihoji T. and Hakura Y. : “NEURAL NETWORK DETECTION SYSTEMS FOR THE ELECTRIC POWER LINE SPREAD-SPECTRUM COMMUNICATIONS”, Proc. of ISITA'90, pp. 879-882 (1990-11).

(平成 3 年 3 月 29 日受付, 7 月 17 日再受付)

宮嶋 行



平1埼玉大・工・電気卒。平3同大大学院博士前期課程了。現在同大大学院博士後期課程在学中。ニューラルネットに関する研究に従事。

長谷川孝明



昭 56 慶大・工・電気卒。昭 61 同大大学院博士課程了。工博。同年、埼玉大・工・電気助手。現在、同助教授。スペクトル拡散通信システム、ニューラルネット、ヒューマンテクノロジーに興味をもつ。平 2 年度篠原記念学術奨励賞受賞。著書に「スペクトラム拡散技術の基礎と応用」(分担執筆)、「プライマリー C 言語ノート」がある。IEEE 会員。

羽倉 幸雄



昭 26 京大・工・電気卒。郵政省電波研究所にて電離層嵐、太陽地球系擾乱とその予報に関する研究に従事。昭 44 年宇宙空間研究室長、昭 51 年調査部長、昭 53 NASDA 出向(地球観測担当部長)、昭 55 電波部長、昭 59 埼玉大・工・電気科教授。平 3 定年退官。工博。日本地球電気磁気学会賞、山路自然科学奨学賞等受賞。

羽石 操



昭 42 埼玉大・理工・電気卒。昭 44 都立大学院修士課程了。同年埼玉大・工・助手。以来、表面波アンテナ、マイクロストリップアンテナ、通信方式等の研究に従事。現在、同教授。工博。昭 51 年度学術奨励賞受賞。