

階層的ニューラルネットワークを用いた手書き文字認識

正員 朱 小燕[†] 非会員 山内康一郎[†]

正員 神保 孝志[†] 正員 梅野 正義[†]

Hand-Written Character Recognition by Layered Neural Network

Xiao-yan ZHU[†], Member, Koichiro YAMAUCHI[†], Nonmember, Takashi JIMBO[†]
and Masayoshi UMENO[†], Members

あらまし 生体の優れた機能と構造を学び、特に生体の視覚系に注目して、情報が網膜から脳に伝わる間にかかなり処理されることを考え、階層ニューラルネットワークを用いた手書き文字認識モデルを提案した。認識すべきパターンが限られた個数の特徴だけで識別可能なら、特徴検出部分は固定結合構造にすれば十分であり、学習が速くなる。本モデルは、特徴検出部分(固定構造)と認識部分(可変結合構造)に分けて、文字認識を行う。固定部分、可変結合部分ともに教師あり学習法により結合重みを設定するが、固定部分は初期設定終了の時点で結合を固定する。また、入力パターンを特徴パターンに圧縮してから認識するので、ネットワークが簡単にデバイス化しやすい。今回は数字と英大文字についてシミュレーションを行い、手書き数字をはじめ、かなり変形した文字でも正しく認識することを確認した。あらかじめ、学習させておけば、文字に限らず特徴のあるパターンならどのようなパターンでも認識させることができる。

1. ま え が き

近年、ニューラルネットワークが文字・音声認識などの分野に応用され、かなりよい成果を上げているが⁽¹⁾⁻⁽³⁾、柔軟性をもたせてさまざまなパターンを認識できるようにすると、ネットワークが膨大になり、学習機能をもたせる場合、大量の学習が必要になる。また、LSI チップ上にニューラルネットワークの並列性を生かしたパターン認識デバイスを作り込むことが困難になるなど問題がある。従来視覚パターン認識の際には特徴(重要な情報となる部分)が抽出されていると考えられており⁽⁴⁾、最近、メッシュ特徴(64次元ベクトル)やLDC特徴(256次元ベクトル)などの入力特徴データを用いて、PDPモデルによる文字認識の研究もされている⁽⁵⁾。

ここでは特徴検出・認識をシステム全体として考え、特徴を36次元ベクトルにまで圧縮して検出する学習可能な特徴検出器を用いた手書き文字認識モデルを提案

する。本モデルは階層構造であり、前処理部分と認識部分からなる。前処理部分は目・網膜の働きを果たし、パターンの特徴を検出しパターンデータを特徴データに圧縮する。認識部分は脳の働きを果たしてパターン認識を行う。各部分は異なるタイプの細胞をもつ多層構造のネットワークである。同じ特徴だけから構成されるパターンを識別・認識するには、特徴検出部分の設定は初期設定のみでよい。従って、前処理部分の結合重みは認識対象となるパターンがもつ代表的な特徴で設定したあと、固定し、認識部分の結合重みのみを逆伝搬学習法で変化させるようにすれば、ネットワークの構造が簡単になり、かつ学習に要する時間も短くなる。また、パターンデータを特徴データに圧縮してから認識するので、細胞の結合重みの可変部分が少なく済み、デバイス化には有利である。このモデルは文字に限らず他のパターン認識にも応用できる。

本論文ではモデルの原理・構造を述べ、シミュレーションにより、数字や英大文字など手書き文字を認識できることを確かめ、問題点も含めて検討を行う。

[†] 名古屋工業大学電気情報工学科, 名古屋市
Department of Electrical and Computer Engineering,
Nagoya Institute of Technology, Nagoya-shi, 466 Japan

2. モデルの構成

人間はものを見るとき、まず、網膜からパターン情報を受け取って、外側膝状体を介して脳に伝え、そこで情報を解釈・同定・認識する。網膜は多層構造であり、その一連の網膜層の中の最後の細胞は神経節細胞と呼ばれ、多くの種類があり、それぞれ、特定のパターン(特定の波長、ある方向のスリット、特定の方向に動く線など)にしか応答しない。網膜上に映った刺激はさまざまな神経節細胞で処理され、神経に沿って脳に伝わってくる。脳の中で情報処理を担っている基本素子は神経細胞である。一つの神経細胞はシナプスを介して $10^3 \sim 10^4$ もの他の神経細胞と結合し、神経系を構成している^{(6),(7)}。

我々は生体の網膜と脳にある神経細胞をまね、モデルを前処理部分と認識部分に分け、階層的なネットワーク構造にした。

前処理部分では、入力パターンの特徴(端点、交差点、斜線など)が検出され、パターン信号を特徴信号に変換する。認識部分は、 C^1 と C^2 の2層からなり、前処理部分からの信号に従って認識を行う。バックプロパゲーション学習法で、 C^1 層と C^2 層の前層との結合重みを決めることにより、モデルに学習機能をもたせる。モデルの構成の模式図を図1に示す。

各細胞層は、細胞と呼ばれる多入力/1出力型のしきい値特性をもつ飽和型非線形素子を n_k 個並べて構成される。これらの細胞は生体内でのニューロンに相当する動作をする。モデル化されたものを図2に示す。 k 番目の細胞層の i 番目の細胞の出力 O^k_i は

$$O^k_i = F^k(u^k_i) \quad (1)$$

$$u^k_i = \sum_j W^{k,k-1}_{ij} O^{k-1}_j - \theta^k \quad (2)$$

である。ここで、 θ^k はしきい値、 $W^{k,k-1}_{ij}$ は $k-1$ 層の




図1 モデルの構造
Fig. 1 Structure of the model.

j 番目の細胞と k 層の i 番目の細胞との間の結合重みである。

各層における細胞は入力層から中間層、中間層から出力層という向きに結合しており、各層内での結合および出力層から入力層に向かう結合は存在しない。 k 番目の層にある i 番目の細胞は $k-1$ 番目の層の細胞のうちで、ある領域 S^k_i に存在する一群の細胞からだけ入力を受けている。 S^k_i は $k-1$ 層にある細胞のうち、 k 層の i 番目の細胞に結合している細胞の集合を表し、これを受容野と呼ぶことにする。一つの i に対して、

$$W^{k,k-1}_j \neq 0 \quad (j \in S^k_i)$$

となる。層の働きにより、細胞の受容野の大きさは異なる。層と層の間の細胞の結合には、初期状態において既に結合が完成している固定結合と外部から与えられる刺激の状態に応じて結合の強さが変化していく可変結合の両者がある。可変結合をもつ部分の結合重みが学習によって変わり、学習機能を実現する。

各細胞は入力 O^{k-1}_j に対する活動レベル u^k_i をもっている。細胞は活動レベルにより、非線形出力関数 F^k を通して出力 O^k_i を出す。この出力がまた、次の層の多数の細胞の入力として使われる。各層はそれぞれの機能に応じた出力関数をもつ。

2.1 前処理 T^1 , T^2 層

本論文では特に手書き文字パターンに対するモデルの構造および細胞の種類などについて検討する。

特徴検出、つまり、前処理部分は T^1 と T^2 の2層からなる。 T^1 層は入力パターンと同じサイズのいくつかの細胞面をもつ。各細胞面には異なるタイプの細胞が並んでおり、それらの細胞によりパターンの特徴を検出する。 T^2 層では T^1 層で得られた特徴データから、特徴ベクトルを作る。 T^1 層と T^2 層は併せて特徴検出機能を実現するので、特徴検出層とも呼ばれる。

文字パターンの場合には端点、交差点、斜線などが特徴としてみられる。このような特徴を検出するために、4種類の細胞を用意し、それぞれ、端点“|”，交差点




図2 細胞の工学的モデル
Fig. 2 Model of the cells.

“+”, 斜線 “/” および “\” に反応するよう結合重みを設定する。

ここでは、例として端点に反応する on 中心型細胞と交差点に反応する off 中心型細胞の入力パターンに対する反応を説明する。図 3 は棒状および T 字状の刺激パターンと各細胞の反応の位置関係を示している。on 中心型の場合、棒状パターンの端部で強い信号が出るが、off 中心型の場合では、T 字状のパターンの交差部の付近で強い信号が出ることがわかる。

すべての細胞の出力は式(3)と式(4)で表すことができる。但し、 T^1 層内では細胞のタイプにより結合重みとしきい値が異なり、 T^1 層と T^2 層では受容野のサイズが異なる。

$$O^k_i = F^k \left(\sum_j^{N^k} W^k_{i,j} O^{k-1}_j - \theta^k \right) \quad (3)$$

$$F^k(u) = \begin{cases} 1 & (u > 0) \\ 0 & (u \leq 0) \end{cases} \quad (4)$$

ここで、0 層の細胞として扱われる $O^0_j = X_j$ は入力パターン (0, 1), N^k は k 層の受容野のサイズ、また、 $W^k_{i,j}$ は前層の細胞との結合重みである⁽⁸⁾⁻⁽¹⁰⁾。各層の結合重みとしきい値の設定方法は後で述べる。

図 4 に示しているように、 T^1 層では各細胞面の受容

野が互いに重なっている上に、同じ細胞面にある細胞、つまり、同じタイプの細胞の受容野も互いに重なっている。 T^2 層は T^1 層と違い、各細胞面の受容野、同じ細胞面にある細胞の受容野ともに重なっていない。

出力がゼロより大きい場合はこの細胞が興奮し発火していると言い、発火している細胞を発火点と呼ぶ。パターン信号は T^1 層を通して発火点信号になる。それぞれのタイプの細胞が発火するかどうかにより、そのタイプの細胞に対応する特徴があるかどうかがわかる。 T^2 層では T^1 層の発火点信号がいっそうまとめられ、パターン信号は特徴信号になり、次の認識部分へ伝わる。図 5 は “A” のパターンが入力されたときの T^1 層の各種類の細胞の活動と T^2 層の出力である。図に示されているように、各種類の細胞は期待どおりにそれぞれに対応した特徴のあるところで発火している。 T^1 層の細胞を M 種類、 T^2 層の細胞の受容野のサイズを n



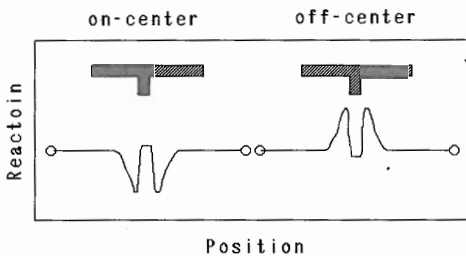


図 4 各層の受容野の位置関係
Fig. 4 Relation of the receptive fields of each layer.



(a) Rod Stimulus Pattern



(b) Cross Stimulus Pattern

図 3 刺激パターンに対する細胞の反応の例 (on 中心型と off 中心型細胞)

Fig. 3 Examples of reactions of the on-center and off-center types cells to rod stimulus pattern (a) and cross stimulus pattern (b).

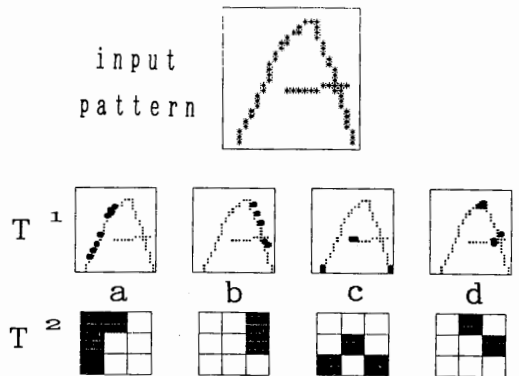


図 5 パターン “A” に対する前処理部分各層の反応。 T^1 層は 4 種類の細胞 a, b, c, d で構成され、それぞれ “/”, “\”, “|” (端点), “+” (交差点) に反応する。 T^2 層も T^1 層の各細胞に対応する 4 組の細胞で構成されている。

Fig. 5 Example of the responses of layers T^1 and T^2 . The layer T^1 consists of 4 types cells a, b, c, d which respond to pattern “/”, “\”, “|” (edge), and “+” (cross point), respectively. The layer T^2 also consists of 4 sets of cells corresponding to T^1 .

$\times n$ とすれば、 T^2 層から出てきたデータはパターンデータに比べ $M/(n \times n)$ に圧縮される。

2.2 認識 C^1 、 C^2 層

認識を行う C^1 層と C^2 層は、それぞれ異なる数の細胞をもつ。 C^1 層は隠れ層として動作し、任意のパターンを認識できる能力をもたせるために加えたものである。 C^2 層が出力層である。

C^1 層と C^2 層の結合重みの値は逆伝搬学習法により決める。図5に示したように、各層の細胞が前層の全ての細胞とつながっている。すなわち、 C^1 層と C^2 層の受容野のサイズは前層の細胞面のサイズと同じである。

各層の細胞の出力は次の式で求める。

$$O^k_i = F^k \left(\sum_j W^k_{i^{k-1}j} O^{k-1}_j - \theta^k \right)$$

出力関数としてはシグモイド関数

$$F^k(u) = 2 / (1 + \exp(-u)) - 1 \quad (5)$$

を用いるのが一般的であるが、シミュレーションを高速化し、かつハード化を容易にするために、 C^1 層の出力関数 F^3 として次のような3値関数を用いた。

$$F^3(u) = \begin{cases} 1 & u > a \\ 0 & -a < u \leq a \\ -1 & u \leq -a \end{cases} \quad (6)$$

ここで、 a は試行により決め、実際のシミュレーションでは 0.2 が最適であった。 C^2 層(出力層)の各細胞はそれぞれ一つのパターン(例えば文字)を表す。その中で出力値が最大になる細胞がシステムの出力となる。

3. 細胞間の結合

すべての細胞の結合重みを可変にすれば、教師あり、また教師なしの学習法により、モデルは学習、パターン認識する能力を獲得できるが⁽⁶⁾、それと同時にモデルが複雑になる。デバイス化する場合には固定結合と可変結合ではその結合が占める空間も必要な技術も全く異なるので、可変結合の多いデバイスは実現が困難になる。

本モデルではネットワークを二つの部分に分けることにより、細胞の結合重みを固定したものと同変できるものの2種類にした。特徴検出部分の結合重みは検出したい特徴に従って設定される。認識部分の細胞の結合重みは可変であり、その値を決めるには逆伝搬学習法を用いた

3.1 T^1 、 T^2 層の結合重み付け

まず、 T^1 層の各種類の細胞が定めた特徴にしか反応

しないようにするため、各細胞面については、次のように結合重みの値を設定する。

一つのタイプの細胞面に対しては、与えられたパターン系列 $P(t)$, $t=1, 2, \dots$ は反応すべきパターンの集合 $U(+)$ と反応すべきでないパターンの集合 $U(-)$ に分けられる。但し、 $U(+)$ と $U(-)$ は十分大きな集合とする。細胞がパターン $P(t)$ を誤って出力するとき、つまり、

$$P(t) \in U(+)$$
 and $O(t) \leq 0$

または

$$P(t) \in U(-)$$
 and $O(t) > 0$

を満足するときだけ、重みとしきい値を次のように修正する。

$$\begin{aligned} W_j(t) &= W_j(t-1) + \delta_j \\ \theta(t) &= \theta(t-1) - \delta_\theta \end{aligned} \quad (7)$$


但し

$$\delta_j = -\epsilon O X_j \quad (X_0 = 1)$$

$$O = \sum_j W_j X_j - \theta \quad (8)$$

である。ここで、 X_j は入力パターン、 O はそれに対する細胞の出力、 t は計算段階を表す変数、 ϵ は計算速度に関する比例定数である。与えられるパターンが線形分離可能であれば、このアルゴリズムが有限回で終了することの証明を付録に示す。これを実際に各種の細胞について適用し、有限回で計算が終了することを確認した。

与えられたパターンは目的の認識パターンすなわち手本パターンからその一部を切り取ることにより得られる。図6には今回用いた4種類の細胞の結合重み付けに使用したパターンの例を示す。最初の2個に対してのみ発火するように結合重みを設定する。



(a) Patterns for the cell detecting “/” types of line.
 (b) Patterns for the cell detecting “\” types of line.
 図6 T^1 層の結合重み付けに用いたサンプルパターンの例
 Fig. 6 Examples of patterns which were used to train cells of Layer T^1 .

T^2 層は特徴データを特徴ベクトルに変換するために設けたもので、受容野の中に入力信号があれば、出力を出す。従って、結合重みをすべて1にすればよい。

3.2 C^1 , C^2 層の結合重み付け

さまざまなデータを柔軟性をもって処理させるには、ネットワークの結合重みを適応的に変化させる必要がある。本モデルでは C^1 層および C^2 層の細胞の結合重みだけをバックプロパゲーション(誤差逆伝搬)学習法により変化させるようにした⁽¹¹⁾。

バックプロパゲーション法とは、教師ありの学習で、ネットワークに誤差フィードバックを導入し、このフィードバックに基づいて、結合重みを調整するものである。結合重みの修正量は

$$\Delta W^{k_i k-1}_j(t+1) = \eta d^{k_i} O^{k_j} + \alpha \Delta W^{k_i k-1}_j(t)$$

である。ここで、 O^{k_j} は k 層の j 番目の細胞の出力、 t は学習段階を表す変数、 η は学習速度を決める学習定数、 α は学習速度が大きい場合にも安定に動作するように導入された安定化定数である。

C^2 層の誤差信号 d^{m_i} は、教師信号 T_i と C^2 層の出力 O^{m_i} を用いて

$$d^{m_i} = (T_i - O^{m_i}) F^{m'}(u^{m_i})$$

C^2 以外では

$$d^{k_i} = (\sum d^{k+1}_i W^{k+1}_i{}^{k_i}) F^{k'}(u^{k_i})$$

で定義される。ここで、 $F^{k'}$ は出力関数 F^k の微分である。

第3層(C^1 層)の出力関数 F^3 が微分できないので、信号処理流れと誤差修正流れの数学処理を分け、誤差信号の計算には、次の関数

$$F(u) = 2 / (1 + \exp(-u)) - 1 \quad (4')$$

を用いた。

学習の結果は出力層における2乗誤差評価関数で評価する。 Ep を p 個の入力パターンに関する2乗誤差

$$Ep = \sum_i \sum_j (T_j(i) - O^{m_j}(i))^2$$

とする。ここでは、 $O^{m_j}(i)$ はパターン i に対する出力層の j 番目細胞の出力であり、 $T_j(i)$ はこれに対する教師信号である。 Ep が極小になるまで、結合重みを変化させ、学習を続ける。

学習の収束を速くする方法はいろいろ検討されている^{(12),(13)}。 η が大きいほど収束が速いが、大き過ぎると振動してしまう。 α は振動を減衰させるが、大き過ぎると遅くなる。これらの定数の最適値はパターンの数にも、誤差の大きさにも関係がある。本研究では誤差が小さくなると共に η と α を徐々に大きくすることによ

り、振動せず速く収束させることができた。すべてのパターンに対してネットワークのダイナミクスを物理的に理解して定数を決めることができないので、各パラメータは試行で設定している。これは今後の課題となる。

4. シミュレーション

これまで述べてきたモデルによる数字、英大文字認識のシミュレーションをパーソナルコンピュータで行った。このとき用いたパラメータを表1に示す。

入力パターンは 24×24 の画素に分け、これを前処理部分(網膜層 T^1 、特徴検出層 T^2)で36次元の特徴ベクトルに変換する。この特徴ベクトルはメッシュ特徴(64次元)やLDC特徴(256次元)などの特徴データに比べるとはるかに簡単化されているため、認識部分(C^1 、 C^2 層)のネットワークの構造が簡単になり、学習も容易になる。また、同じ特徴をもつパターンなら共通の特徴検出器が利用でき、認識学習によって変換しなければならない部分が少ないので、ハードウェア化に有利である。

まず、前処理部分の、パターンの特徴分離能力を確かめるために、50人の手書きによる英大文字26種類とアラビア数字10種類について、各文字の特徴を取り出し、特徴ベクトルに変換する実験を行った。その結果、文字種類が異なれば、変換して得られる特徴ベクトルは必ず異なることを確認した。

次に、実際の手書き文字について認識の実験を行った。英文字とアラビア数字について別々に10人と9人が書いたパターンを学習させた。図7はその学習に用いたパターンの一部である。

学習したネットワークの反応を種々の入力パターンを用いて調べた。図8はパターン“3”に対する各層の細胞の反応を示している。黒い点は正の出力、白い点は負の出力を表し、点のサイズが出力の大きさを表している。出力層では“3”を表すユニットが他のユニットより大きい出力を出しており、入力パターンを正しく認識したことを示している。図9は正しく認識したパターンの例を示している。図に見られるように、

表1 シミュレーションのパラメータ

	パターン	T^1 層	T^2 層	C^1 層	C^2 層
細胞数	24×24	$24 \times 24 \times 4$	$3 \times 3 \times 4$	40	26
受容野サイズ		5×5	8×8	36	40

かなり変形したパターンでも認識することができた。英文字とアラビア数字について、50人の手書き文字の認識率を調べた結果を図10に示す。平均認識率はそれぞれ90.2%、92.0%である。




図7 認識部分の結合重み付けに用いたパターンの例
Fig. 7 Examples of patterns which were used to train layers C^1 and C^2 .

5. むすび

階層的ネットワークを使って、手書き英文字とアラビア数字を認識率90%以上で正しく認識できることを示した。認識部分の C^1 層と C^2 層のユニットの結合重みは学習で決めるので、原理的にはどんなパターンで




図9 認識できた文字の例
Fig. 9 Examples of patterns which were recognized correctly.

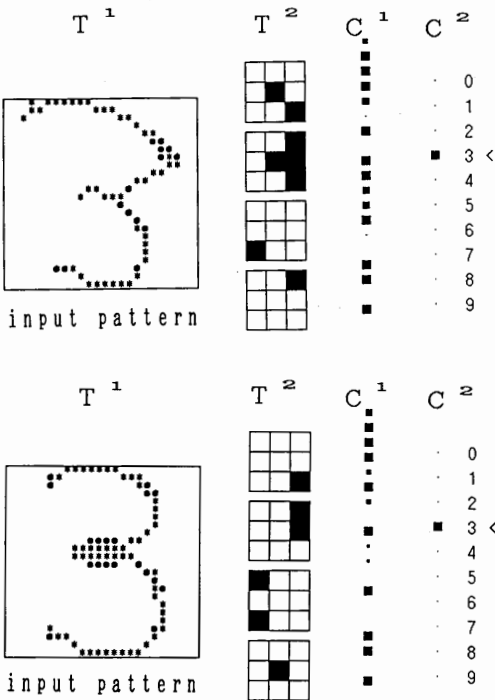


図8 “3”のパターンに対する各層の反応
Fig. 8 Examples of responses of each layers in the model to pattern “3”.

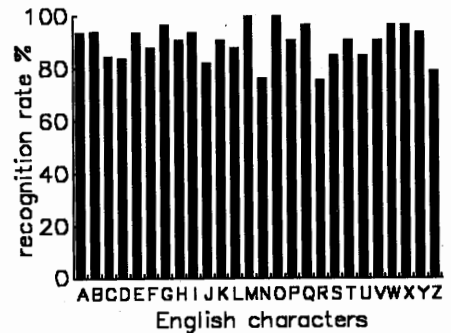



図10 数字と英大文字の認識率
Fig. 10 Recognition rates for digits and English characters.

も認識できる。モデル自身が簡単で、かつ並列処理アルゴリズムなので、ハードウェアも容易で人工網膜や特徴検出センサの入力部分などへの応用も期待できる。

なお、今回はパーソナルコンピュータでシミュレーションをしたため、時間とメモリの関係で10人のデータしか学習させていない。もっと多くのデータを学習させれば、更に認識率を向上できると思われる。

文 献

- (1) 福島邦彦, 三宅 誠, 伊藤崇之: “ネオコグニトロン の原理を用いた数字パターン認識”, 信学論(D), **J66-D**, 2, pp. 63-70 (1988).
- (2) T. F. Pawlicki, D. S. Lee, J. J. Hull and S. N. Srihari: “Neural network models and their application to handwritten digit recognition”, IEEE International Conference on Neuron Networks, **2**, pp. 63-70 (1988).
- (3) 田中啓夫, 古村光夫: “ニューラルネットワークを用いた音声生成システムの能力の分析について”, 信学技報, **PRU88-118** (1988).
- (4) 藤井克彦, 森田竜弥: “視覚神経系を模倣した手書き文字認識機構”, 信学論(C), **52-C**, 7, pp. 392-398 (昭45-07).
- (5) 森 吉弘, 横澤一彦, 梅田三雄: “PDPモデルによる手書き漢字認識”, 信学技報, **MBE87-156** (1987).
- (6) K. T. スベアー, S. W. レムクール/葦阪直行訳: “視覚の情報処理”, サイエンス社 (昭57).
- (7) 塚原伸晃: “脳の情報処理”, 朝倉書店 (昭59).
- (8) 梅野正義, 朱 小燕, 中村雅司: “生体の視覚系モデルによる文字パターン認識”, 電学論, **108-C**, 7, pp. 453-456 (1988).
- (9) 梅野正義, 清水昇市, 野間敏弘, 太田正光: “人工網膜のアプローチ”, 名古屋工業大学学報, **35**, pp. 191-196 (昭59).
- (10) 梅野正義, 琵琶木孝恒: “文字パターン認識における自己組織を利用した特徴量の検出”, 信学論(D), **J69-D**, 10, pp. 1443-1449 (昭59).
- (11) D. E. Rumelhart and J. L. McClelland: “Parallel Distributed Processing”, MIT Press, London (1986).
- (12) N. Watanabe, S. Nagata and K. Asakawa: “Mobiike robot control by neural networks and their associated learning algorithm”, IECON'88, 1054 (1988).
- (13) 賈 棋, 戸田尚宏, 臼井支朗: “Back-Propagation アルゴリズムの加速化”, 昭63 東海連大論文集, p. 512.

付 録

[命題] 与えるパターン集合 $U = U(+) \cup U(-)$ が線形分離可能であり、パターン系列 $P(t)$, $t=1, 2, \dots$ は $U(+)$ と $U(-)$ に属するパターンを十分含んでいるとする。このとき、以下のアルゴリズムによる $W_j(t)$ の計算は有限回で終了する。

$$P(t) \in U(+) \text{ and } O(t) \leq 0$$

or

$$P(t) \in U(-) \text{ and } O(t) > 0$$

という条件を満足するときだけ、次の計算を行う。

$$W_j(t) = W_j(t-1) + \delta_j$$

$$\theta(t) = \theta(t-1) - \delta_\theta \tag{A.1}$$

但し

$$\delta_j = -\varepsilon O X_j \quad (X_0 = 1)$$

$$O = \sum_j W_j X_j - \theta \tag{A.2}$$

ここで、 X_j は入力パターン、 O はそれに対する細胞の出力、 t は計算段階を表す変数、 ε は計算速度に関する比例定数である。

(証明) t 回計算した結合重みを $W(t)$, t 回目の重みの変化量を $\delta(t)$, 見せるパターンを P とおく。重みとしきい値をまとめて考えるため

$$W(t) = (\theta(t), W_1(t), W_2(t), \dots, W_n(t))$$

$$\delta(t) = (\delta_1(t), \delta_2(t), \dots, \delta_n(t))$$

$$P(t) = (-1, X_1(t), X_2(t), \dots, X_n(t)) \tag{A.3}$$

とすれば、(A.1) は

$$\dot{W}(t) = \dot{W}(t-1) + \delta(t)$$

$$= \dot{W}(t-2) + \delta(t-1) + \delta(t)$$

$$= \dot{W}(0) + \delta(1) + \delta(2) + \dots + \delta(t) \tag{A.4}$$

となる。

式(A.2)により

$$\dot{W}(t) \cdot P(t) > 0 \text{ のとき, } \dot{W}(t) \cdot \delta(t) < 0$$

$$\dot{W}(t) \cdot P(t) < 0 \text{ のときも, } \dot{W}(t) \cdot \delta(t) < 0$$

従って

$$\dot{W}(t) \cdot \delta(t) < 0 \tag{A.5}$$

が成立する。

$U(+)$, $U(-)$ が線形分離可能であるから、 $U(+)$, $U(-)$ に対して

$$V \cdot \delta(i) > 0 \quad (0 \leq i \leq t-1)$$

となるベクトルが存在する。ここで

$$b = \min\{V \cdot \delta(i) \mid 0 \leq i \leq t-1\}$$

$$M = \max\{\|\delta(i)\| \mid 0 \leq i \leq t-1\}$$

とすれば、コーシー・シュワルツの公式より

$$\|V\| \cdot \|\dot{W}(t)\| \geq V \cdot \dot{W}(t)$$

$$= V \cdot \dot{W}(0) + V \cdot \delta(1)$$

$$+ \dots + V \cdot \delta(t)$$

$$\geq V \cdot \dot{W}(0) + tb \tag{A.6}$$

であるから

$$\|\dot{W}(t)\| \geq \frac{V \cdot \dot{W}(0) + tb}{\|V\|}$$

ここで、 $\|V\| = s$, $V \cdot \dot{W}(0) = a$ とおけば

$$\|\dot{W}(t)\| \geq \frac{a}{s} + \frac{tb}{s} \quad (\text{A}\cdot 7)$$

一方, (A・4) より

$$\|\dot{W}(t)\|^2 = \|\dot{W}(t-1)\|^2 + \|\delta(t)\|^2 + 2\dot{W}(t-1)\cdot\delta(t)$$

(A・5) より

$$\begin{aligned} &< \|\dot{W}(t-1)\|^2 + \|\delta(t)\|^2 \\ &< \|\dot{W}(t-2)\|^2 + \|\delta(t-1)\|^2 + \|\delta(t)\|^2 \\ &\vdots \\ &< \|\dot{W}(0)\|^2 + \|\delta(1)\|^2 + \dots + \|\delta(t)\|^2 \end{aligned}$$

ところが,

$$\|\delta(t)\|^2 \leq M^2$$

であるから

$$\|\dot{W}(t)\|^2 < \|\dot{W}(0)\|^2 + tM^2 \quad (\text{A}\cdot 8)$$

ここで, (A・7) は $\|\dot{W}(t)\|^2$ が t^2 のオーダーで増えていくことを意味し, (A・8) は t のオーダー以上に離れないことを意味している。この二つは, t を大きくすると矛盾する。これは, t が無限に大きくなることはできず, 重み W の計算が有限回で終了することを意味している。

(証明終了)

(平成元年4月17日受付, 8月7日再受付)



神保 孝志

昭45名大・電子卒, 昭50名大大学院博士課程了。同年各大・電気系助手, 昭61同講師, 昭62名工大・電気情報工学科助教授。現在に至る。この間, 60年6月~61年8月在外研究員としてニューヨーク市立大学。半導体材料, 光デバイス, 非線形光学, 光情報処理の研究に従事。工博。電気学会, レーザー学会, 応用物理学会, 物理学会各会員。



梅野 正義

昭35名工大・電気卒, 昭37東工大大学院修士課程了, 同年名大・工・電子助手, 昭42同大講師, 昭44同大助教授, 昭53名工大教授。この間, 半導体と光およびマイクロ波との相互作用の研究, 半導体光デバイス, 特にフォトンドラッグ光検出器, 半導体レーザー, 光トランジスタ, 高効率太陽電池, イメージセンサ等の研究, 半導体デバイス用の各種結晶成長を行ってきた。最近では, 特にMOCVD法による多層薄膜結晶成長とシリコン上へのGaAsのヘテロエピタキシャル成長の研究とその光集積回路への応用, および人工網膜等の3次元回路と画像の並列処理の研究に従事している。昭42米沢記念学術奨励賞, 工博, テレビジョン学会, 計測自動制御学会, 応用物理学会, 物理学会, IEEE各会員。



朱 小燕

昭57中国北京鋼鉄学院・工・自動制御卒, 昭62神戸大・工・大学院修士課程了。同年, 名古屋工業大学・工・大学院博士後期課程に進学。現在, 同課程在学中。ニューラルネットワークを用いたパターン処理, 認識

および人工網膜等画像の並列処理デバイスの研究に従事。



山内康一郎

平成元年名工大・電気情報卒。同年名工大大学院工学研究科電気情報工学専攻進学。現在, 同課程在学中。ニューロンネットワークを用いたパターン処理の研究に従事。応用物理学会学生員。