

コントローラーとしてのニューラルネットワークの学習

逢 坂 一 正

岡山理科大学工学部機械工学科

岡山市理大町 1-1

(1989年9月30日 受理)

1. はじめに

現在、工業界においては機械装置類の知能化に対する要求が強く、それらに関する研究はある程度の成果を生み出しつつある。機械の知能化のための手段として、当然のこととして人間の頭脳のもつ情報処理機能を応用することが考えられる。頭脳の構造は非常に複雑でその情報処理的機能といえども全て解明されているわけではない。しかし、脳の構造の核になるニューロン（神経細胞）、ニューラルネットワーク（神経回路網）についてはかなりのことが分かってきている。

ニューラルネットワークの情報処理に関する研究¹⁾は、1960年代の後半から1970年代にかけて盛んに行われていた。近年、人工知能、ロボットに関する研究が盛んになるにつれて、ニューラルネットワークのそれらへの応用研究²⁾がかなり報告されている。ニューラルネットワークをロボット制御系のコントローラとして用いる研究としては、視覚情報処理の分野に関する報告³⁾、ロボットの四肢の運動制御の分野に関する報告^{4)・5)}などがある。しかしながら、これらの報告ではニューラルネットワークがコントローラとしてどの程度の性能を有するかがあいまいである。

そこで本研究では、ニューロンの数理モデルに基づくニューラルネットワークの構造を数式表現し、それを制御系のコントローラとして用いる場合の学習機能について考察し、市販のニューロコンピューティングソフトウェア⁶⁾を用いた数値シミュレーション結果を用いてニューラルネットワークの学習機能、連想機能などについて検討する。

2. ニューラルネットワーク

本章では、ニューラルネットワークの情報処理的機能、つまりニューラルネットワークを電気パルスの発生、伝達を行う装置とみなすときの機能について考察する。

2. 1. ニューラルネットワークの数式表現

1個のニューロンの生物学的（生理学的）構造は、図1の上図に示すような形をしていて、その情報処理素子としてのモデルは図1の下図のようになる。ニューロンは細胞体と

呼ばれる本体、本体から突き出た樹状突起と呼ばれる部分、軸索と呼ばれる一本の長い纖維の部分からなる。軸索は途中で何本にも枝分かれしてその末端が他のニューロンの樹状突起に結合している。この結合部分はシナプスと呼ばれる。

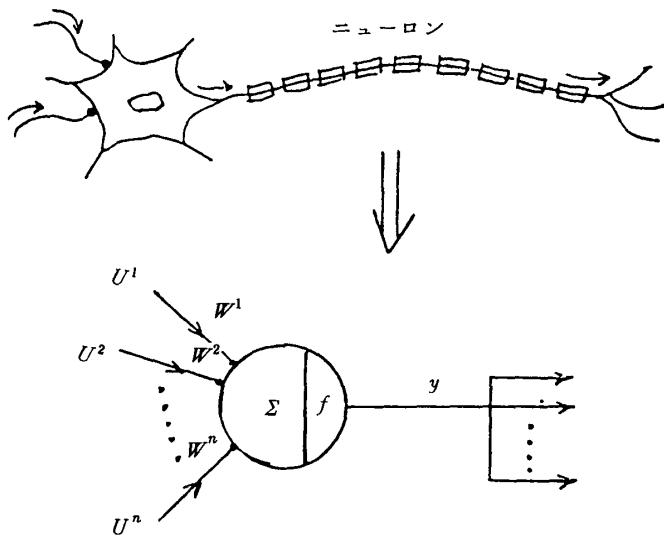


図1 ニューロンのモデル

ニューロンの有する機能の簡単な素描¹⁾はつきのとおりである。細胞体内部の電位は膜電位と呼ばれ、ニューロンは興奮すると外部の電圧を基準として高圧側30mV程度、低圧側-65mV程度、高圧持続時間1ms程度のパルスを発生し、そのパルスは軸索を毎秒100m程度の速度で他のニューロンとのシナプスに伝達される。ニューロンは、シナプス結合している他のニューロンの膜電位を高めるように作用するパルスを出す興奮性ニューロンと低めるように作用するパルスを出す抑制性ニューロンに分類される。

図1のニューロンを次式のような多入力一出力の情報処理素子としてモデル化する。

$$z = \sum_{i=1}^n w^i u^i - h \quad (1)$$

$$(2)$$

ただし、 u^i はニューロンへの入力、 y は出力、 w^i は結合荷重（シナプス荷重）で興奮性ニューロンに対しては $w^i > 0$ 、抑制性ニューロンに対しては $w^i < 0$ 、 h は閾値、そして $f(\cdot)$ は出力関数で、

$$f(z) = 1 / (1 + e^{-z/T}) \quad (3)$$

とする。ここで、 T はパルスの立ち上がりの速さを決めるパラメータである。(1)式は膜電位がある閾値以上になるとパルスができる（発火）、(3)式はニューロン出力の飽和特性を意識した表現である。この関数は、飽和特性をもつS字形曲線（シグモイド曲線）を表

す。

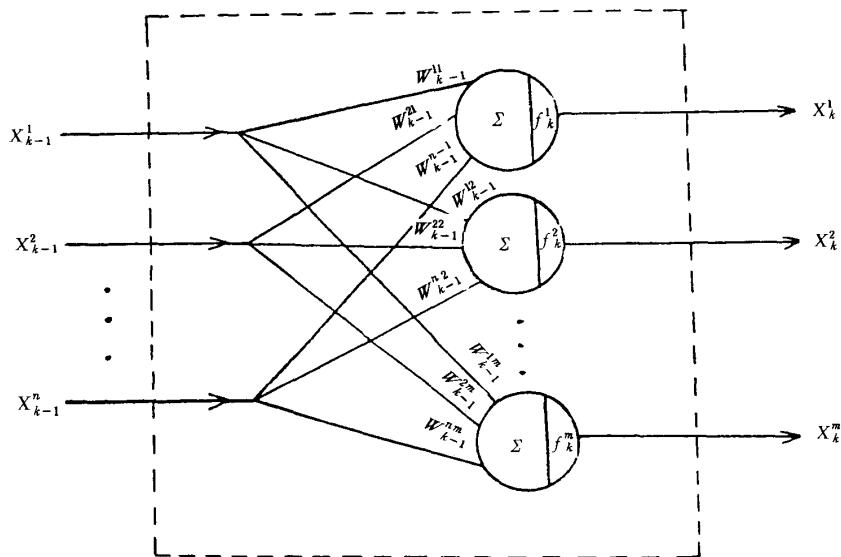


図2 ニューロンの層状結合

このようなニューロンを m 個並列に結合させると、図2に示すようなニューロンの層ができる。ここではこの層をニューラルユニットと呼ぶことにする。このニューラルユニットを簡略化して数式に表すと次式となる。

$$\begin{aligned} z_k &= W_{k-1} x_{k-1} \\ x_k &= f(z_k) \end{aligned} \quad (4)$$

ただし、簡単のため閾値 $h = 0$ 、パラメータ $T = 1$ と固定する。またベクトル $x_{k-1} = [x_{k-1}^1, \dots, x_{k-1}^n]^T$ はユニットへの入力、ベクトル $x_k = [x_k^1, \dots, x_k^m]^T$ はユニットからの出力を表している。ここで、 $[\cdot]^T$ は転置を意味する。また行列 W_{k-1} は荷重行列で次式のように書ける。

$$W_{k-1} = \begin{bmatrix} w_{k-1}^{11} & w_{k-1}^{12} & \cdots & w_{k-1}^{1n} \\ \vdots & \vdots & & \vdots \\ w_{k-1}^{m1} & w_{k-1}^{m2} & \cdots & w_{k-1}^{mn} \end{bmatrix} \quad (5)$$

要素 w_{k-1}^{ij} は x_{k-1}^i から z_k^j への荷重を意味するものとする。さらに、出力関数は次式で表される。

$$f(z_k) = [f(z_k^1), \dots, f(z_k^m)]^T$$

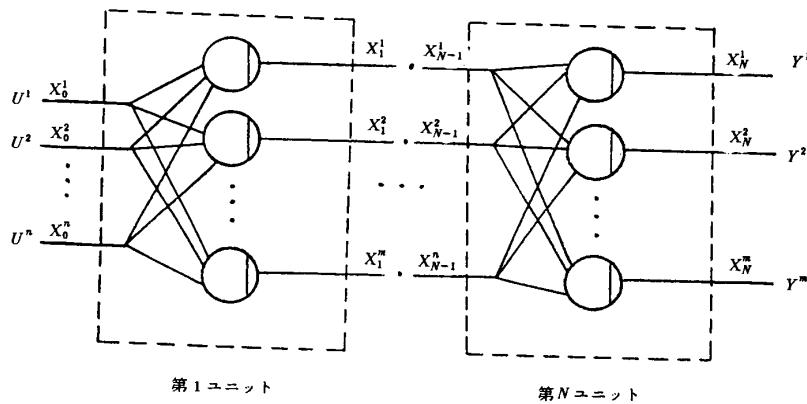


図3 ニューラルネットワーク

ニューラルユニットN個を直列に結合すれば、図3に示すような多層ニューラルネットワークが構成できる。このニューラルネットワークを数式で表すと次式になる。

$$\mathbf{x}_0 = \mathbf{u}$$

$$\mathbf{z}_k = \mathbf{W}_{k-1} \mathbf{x}_{k-1}$$

$$\mathbf{x}_k = f(\mathbf{z}_k)$$

$$\mathbf{y} = \mathbf{x}_N \quad (6)$$

ここで、 $\mathbf{u} = [u^1, \dots, u^n]^T$ はニューラルネットワークへの入力、 $\mathbf{y} = [y^1, \dots, y^m]^T$ はニューラルネットワークからの出力を表し、また $1 \leq k \leq N$ である。あるいは(6)式は、一般には非線形関数Hを用いて次式にまとめられる。

$$\mathbf{y} = H(\mathbf{W}_0, \dots, \mathbf{W}_N; \mathbf{u}) \quad (7)$$

ここで、 \mathbf{W}_k のサイズは k によって異なることに注意しなければならない。多層ニューラルネットワークのブロック線図を図4に示す。多層ニューラルネットワークは、入力 \mathbf{u} から出力 \mathbf{y} への情報処理を行う装置とみなせる。

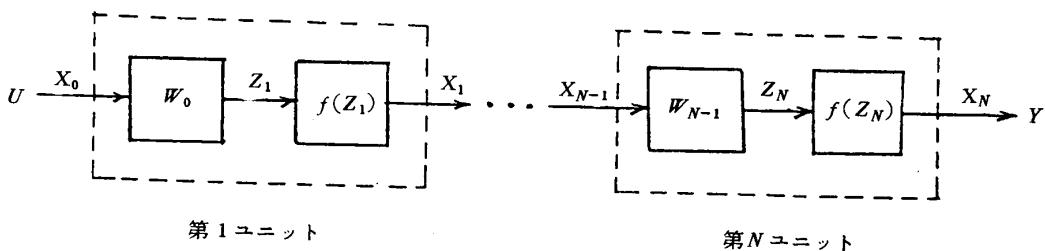


図4 ニューラルネットワークのブロック線図

2. 2. ニューラルネットワークの学習機能

図3に示すような多層ニューラルネットワークの機能の一つとして、入出力関係の“学習”がある。すなわち、ある入力 \mathbf{u} に対する望ましい出力 \mathbf{y}_d が与えられたとき、なんらかの学習をさせることで $\mathbf{y} \rightarrow \mathbf{y}_d$ を達成することである。この学習は、“教師付き学

習”と呼ばれる。その学習方法の一つは、(7)式の荷重行列 W_k の変更による学習で、バックプロパゲーション法⁷⁾としてよく知られている。

バックプロパゲーション法のアルゴリズムを以下に示す。本アルゴリズムは次式で表される誤差ノルム e の極小値を求める最急降下法である。

$$e = \|y - y_d\|^2 \quad (8)$$

いま、 e は(7)式より結合荷重 $w_{k^{ij}}$ の関数であるから、 $w_{k^{ij}}$ を次式のように繰り返し修正することが e に関する最急降下法である。

$$w_k^{ij} = w_k^{ij} - \eta \frac{\partial e}{\partial w_k^{ij}} \quad (9)$$

ここで、 η は補正係数で範囲 $0 < \eta < 1$ 内の値が採用される。アルゴリズムの手順はつぎのとおりである。

(I) 初期設定

$$s = 0 \quad (s : \text{学習回数})$$

$$w_k^{ij} = 0$$

(II) 出力計算

$$x_0(s) = u$$

$$x_k(s) = f(W_{k-1}(s)x_{k-1}(s))$$

$$(k = 1, \dots, N)$$

$$y(s) = x_N(s)$$

(III) 逆伝播学習 ($k = N \rightarrow 1$)

$$\delta_k^j(s) = \begin{cases} (y^i(s) - y_a^i)y^i(s)(1-y^i(s)) & \text{for } k=N \\ (\sum_{l=1}^n \delta_{k+1}^l(s)w_k^{lj}(s))x_k^j(s)(1-x_k^j(s)) & \text{for } k \leq N-1 \end{cases}$$

$$w_{k-1}^{ij}(s+1) = w_{k-1}^{ij}(s) - \eta \delta_k^j(s) \cdot x_{k-1}^i$$

(IV) 収束判定

$$\sum_{k=1}^N \sum_{j=1}^n (\delta_k^j)^2 < \varepsilon \quad (\varepsilon : \text{正の微小量})$$

を満足すれば終了、そうでなければ $s = s + 1$ として手順(II)に戻る

以上の学習は望ましい入出力の組(u, y_d) (教師値) が与えられた場合の学習である。

制御系のコントローラの機能は、制御誤差などの入力 u に対して操作量などの出力 y を作り出すことである。これは、数学的には u から y への写像を求ることで、一般に(7)式

に表せ，その関数形はシグモイド曲線で合成できる形のクラスに限られる。このとき，(7)式の W_k は関数に含まれるパラメータと見なせる。この観点では，ニューラルネットワークをコントローラとして用いるときの学習は，教師値に対する一種のパラメータ調整であるといえる。

学習が終了したニューラルネットワークに教師値と異なる u を入力すれば，適当な y が出力される。これは，一種の“連想”機能である。連想機能は，パターン認識によく用いられている。結局，ニューラルネットワークは，教師値付き学習を手段とする，入出力間の非線形関数発生器であるといえる。ニューラルネットワークは教師値付きでない学習も可能であるが，本報告では省略する。

3. 数値シミュレーション

本章では，ニューラルネットワークの関数発生器としての性能を数値シミュレーションの結果として示し，学習機能について検討する。文献(6)のシミュレータは，閾値 h に関する学習機能も有し，パラメータ T の変更が可能である。

ニューラルネットワークはパーセプトロン¹⁾を模して3層とし，第1層を入力層，第2層を中間層，第3層を出力層と呼ぶことにする。また学習する関数（教師値を発生する関数）には，簡単な下記の1次関数と2次関数を採用する。

$$y = a_1 u \quad (10)$$

$$y = a_2 u^2 \quad (11)$$

ここで， a_1 ， a_2 は正の定数とする。ここでは，主として中間層のニューロンの数，教師値の数を変えたときの学習を取り上げ， $a_1 = a_2 = 2$ とした。

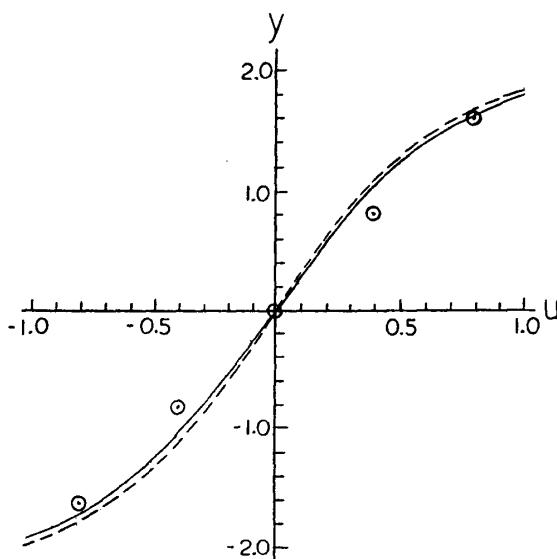


図5 1次関数の学習結果（パラメータ：中間層ニューロン数）

入出力層が各 1 ニューロン、つまり 1 入力 1 出力で 10 式の学習において、中間層のニューロンの数を変えたときの学習結果の一例を図 5 に示す。横軸が入力 u （簡単のため $-1 \leq u \leq 1$ に限定、他の結果も同様）、縦軸が出力 y を表し、 \odot が教師値、実線、点線はそれぞれ中間層ニューロン 4 個、16 個の学習結果を示す。両者の間にほとんど差異はない。同様の学習において、教師値の数を変えたときの学習結果の一例（中間層ニューロン 12 個）を図 6 に示す。実線、点線はそれぞれ教師値 5 個、21 個の結果である。教師値の数が増えても関数近似の精度はあまり変わらないことが分かる。発生した関数にシグモイド曲線の特徴が現れ、 u が ± 0.4 の近くで近似精度が悪くなっている。

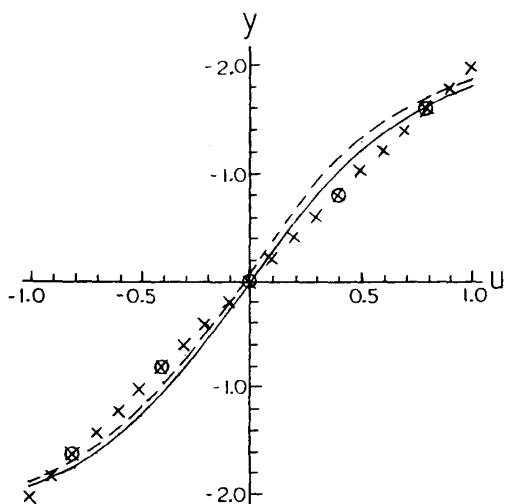


図 6 1 次関数の学習結果（パラメータ：教師値数）

学習の進展は、学習時間（機種：PC-9801VXでの計算時間）に対する誤差 e の減少状況で表され、中間層ニューロンが 10 個、教師値の数が 11 個で 10 式を学習した例を図 7 に示す。横軸が計算時間 t （単位は秒）、縦軸が誤差 e （最大値で割って正規化）を表す。この曲線は学習曲線と呼ばれ、学習時間がある程度の長さになると誤差は飽和する。

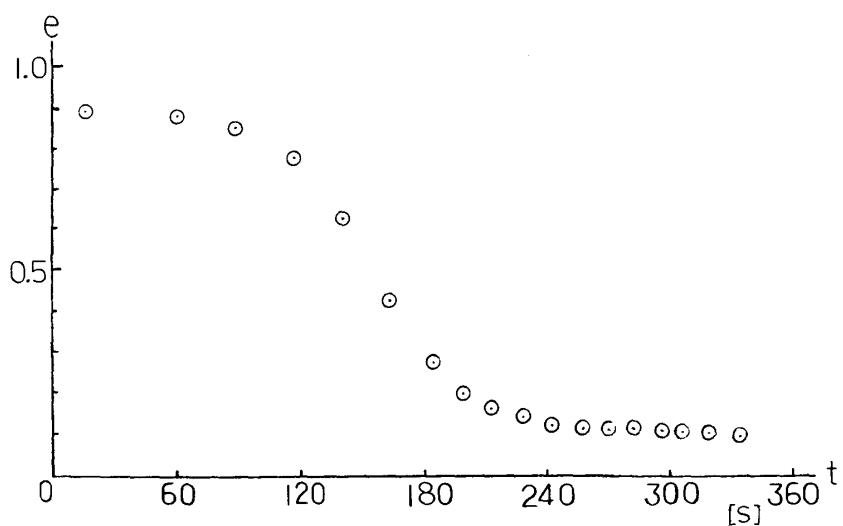


図 7 学習曲線

1入力1出力で(10)式を中間層ニューロンと教師値の数を変えて学習した結果の一例（中間層ニューロン12個、教師値5個）を図8に示す。この場合も関数近似の精度について(10)式の学習の場合と同様のことがいえる。

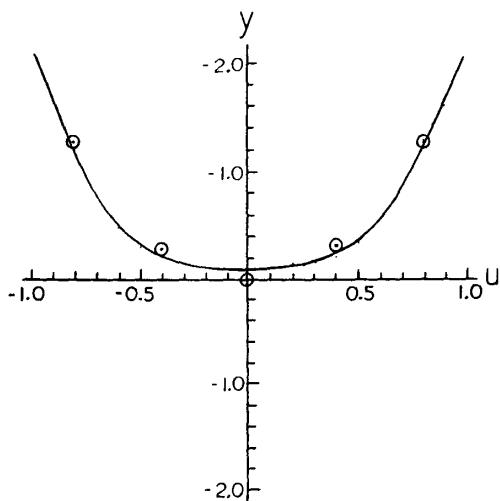


図8 2次関数の学習結果

2入力2出力で(10), (11)式を同時に学習する場合、一組の入出力に(10)式、他の組の入出力に(11)式の教師値を対応させる。この場合の学習結果の一例（中間層ニューロン16個、教師値11個）を図9に示す。図中の教師値は、○が(10)式、×が(11)式を表す。2個の関数を同時に学習させても別々に1個ずつ学習させても関数近似の精度は、ほぼ同じであることが分かる。

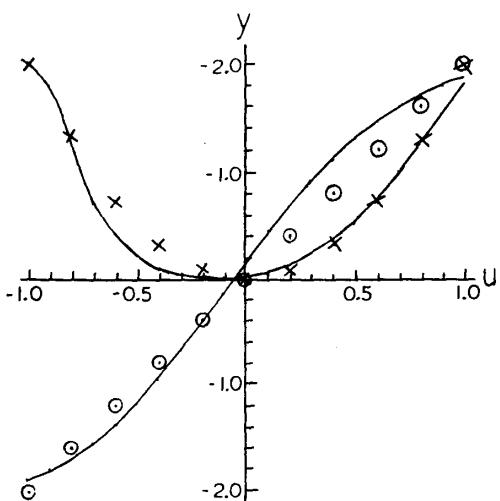


図9 1次、2次関数の同時学習結果

4. おわりに

ニューラルネットワークを制御系のコントローラとして用いる場合の機能を主として教師付き学習に注目して考察し、その結果を3層ニューラルネットワークでの数値シミュレーションにより検討した。得られた結果は、つぎのようにまとめられる。

- (1)ニューラルネットワークは、コントローラの入、出力間の関数発生機能を有する。
- (2)ニューラルネットワークの学習曲線は、飽和特性をもつ。
- (3)中間層のニューロンの数は、発生する関数に大きな差異を与えない。
- (4)教師値の数は、発生関数の近似精度にあまり影響しない。
- (5)2個の関数を組にして同時に学習しても、1個ずつ学習するのと変わらない近似精度を得る。

終わりに、日頃ご指導いただいている大阪府立大学の小野敏郎教授に感謝します。

参考文献

- 1) 甘利俊一：神経回路網の数理，産業図書，(1978)
- 2) 例え、日本ロボット学会：日本ロボット学会誌－（特集）脳神経系情報処理とロボット，vol.6, no.3, (1988).
- 3) 大森隆司，中野馨：自己組織化細胞を含む視覚系のモデル，計測自動制御学会論文集，vol.20, no.1, (1984).
- 4) M.Kawato, Y.Uno, M.Isope, R.Suzuki : A hierarchical neural network model for voluntary movement with application to robotics, IEEE Control Systems Magazine, vol.8, no.8, (1988).
- 5) 瀬戸山徹，川人光男，鈴木良次：多層神経回路網内に学習される逆ダイナミクスモデルによるマニピュレータの制御，信学技報，MBE87, (1988).
- 6) センチュリリサーチセンタ株式会社：ニューロコンピューティングソフト「RHINE」，ver.1.20, (1988).
- 7) D.E.Rumelhart, G.H.Hinton, R.J.Williams : Learning representations by back-propagating errors, Nature, 323, (1986).

A Learning Representation of Neural Network in System Controller

Kazumasa OHSAKA

Department of Mechanical Engineering,

Okayama University of Science,

1-1 Ridaicho, Okayama 700 Japan

(Received September 30, 1989)

In this paper, a learning method for multi-layers neural network in system controller is discussed and the method is simulated for 3-layers neural network.

The results obtained are summarized as follows.

- 1) Neural network in system controller is characterized as a function generator between input and output.
- 2) Learning curve of neural network has a saturation characteristic.
- 3) Generated function does not change largely due to the number of intermediate layer neurons.
- 4) Precision of approximation in generated function does not change largely due to the number of teaching value.
- 5) Precision of approximation in parallel learning of two functions is nearly equal to that in learning of each function.