

誤差収束型ニューロンネットワークシステムの収束能力に関する基礎的実験
 Fundamental Experiment for Convergent Capability
 of Error Convergence-type Neuron Network System

小早川 俊祐[†] 横井 博一[†]
 Shunsuke Kobayakawa Hirokazu Yokoi

1. はじめに

ニューロンネットワーク (NN) は、学習能力が低い場合、入力信号と出力信号との間に因果性があっても、その写像を完全に学習することはできない。この問題を解決する手段として、NN の学習能力を向上させることが考えられる。しかし、その問題を解決した NN は、未だ存在しない。今日まで、NN の出力精度を向上させるために、様々な研究が活発に行われてきた。ニューロンの入出力特性や NN の構造を改善することは、その出力精度向上手段として有効である。そのニューロンとしては、高次^[1]、入力遅れ^[2,4]、RBF^[3]、ボルテラ^[4-11,16]などがある。また、ネットワークとしては、GMDH^[12]、IIR^[13]、ピラミッド型^[14]、2次元拡散連想型^[15]、並列型^[16-21]、介在素子付加型^[22]などがある。本研究室でも、人工ニューロンボルテラフィルタを内蔵したボルテラニューロンや介在素子付加型 NN を用いてその向上を試みた。しかし、学習回数を多くしても、いずれの NN の出力誤差もゼロに収束させることはできていない。従って、NN は、許容範囲内の出力誤差を含んだ状態で使用されている。しかし、より小さな出力誤差が必要な予測符号化^[10,11]や航空宇宙機の飛行制御^[16,17]などへ適用する場合、その状態では不十分である。そこで、小早川が、学習能力が低い NN でも、それを複数用いることで、前記の問題を解決できる可能性のある NN システムの誤差収束法とそれを応用した誤差収束型 NN システム (ECNNS) ^[23,24]を考案した。

単出力である ECNNS は、単出力 NN を多段に接続し、それらが学習時にローカルミニマムへ陥っても、ECNNS の出力の誤差は収束するように設計されている。また、これらの NN の段数を無限にすれば、理論的に ECNNS の出力誤差はゼロとなる。さらに、この ECNNS を複出力 NN システムに適用する場合、対象の NN システムを並列型ニューロンネットワークとし、その並列ユニットを ECNNS とする。これにより、出力間の学習の干渉問題を含んでいる従来の BP ネットワーク^[25]より高精度な誤差収束並列型 NN システムへと発展させることができる。

ECNNS は、教師信号値の有効数字の桁数に従って ECNNS の NN の段数を適切に設定すれば、ECNNS へ与えた 1 個の教師データをわずか 1 回の学習で習得できるという特性を備えている。しかし、この特性は、実験で検証されていない。そこで、本研究の目的は、この特性を 1 入力 1 出力の人工ニューロン 1 個の繰り返し学習と ECNNS の NN を 1 入力 1 出力の人工ニューロン 1 個とした最も簡単な構造の 1 入力 1 出力の ECNNS の 1 回の学習を比較する実験で検証し、ECNNS の収束能力を確認することにある。この検証により、教師信号値の有効数字の桁数に従

って、ECNNS の NN の段数を適切に設定すれば、誤差のない非線形信号の出力を実現できる可能性があることを示すことができる。実験を行った結果、良好なその検証が得られたのでここに報告する。

2. 誤差収束型ニューロンネットワークシステム

2.1 原理

ここで、すべての入力信号に対して学習が収束するまで行われた結果、教師信号に対する出力誤差が学習以前よりも小さくなるがゼロに収束しない単出力のニューロンネットワーク (NN) について考える。はじめに、学習が、第 1 段目の NN によって行われる。次に、この NN の教師信号と出力信号から得られた誤差信号を次の段の NN の教師信号として使用し、その学習を行う。ゆえに、次々と前段の NN の学習から得られた誤差信号を教師信号として次段の NN で学習し続けても、この教師信号に対する出力信号の誤差は、ゼロに収束させることはできないと考えられる。すなわち、第 1 段目の NN に与えられた教師信号とすべての NN の出力信号の総和から得られる誤差は、ゼロに収束しない。このことを式(1)~(4)に示す。

$$y_i = z_i + \varepsilon_i \quad (i=1,2,\dots,n) \quad (1)$$

$$\varepsilon_i = y_{i+1} \quad (i=1,2,\dots,n) \quad (2)$$

$$y_1 = \sum_{i=1}^n z_i + \varepsilon_n \quad (3)$$

$$\lim_{n \rightarrow \infty} \varepsilon_n \neq 0 \quad (4)$$

ここで、 y は教師信号、 z は出力信号、 ε は出力誤差、各記号の添え字は NN の段番号を示す。

また、第 2 段目以降の NN で教師信号として使用される誤差信号が、NN の段数の増加に伴って小さくなるため、段数の高い NN ほど学習が困難となる。この問題を解決するために、増幅された誤差信号を第 2 段目以降の NN の教師信号として使用する。結果として、それらの NN の学習は、容易となる。学習後の NN の出力誤差は、教師信号として使用する誤差信号の増幅率が 1 より大きい場合、増幅前の信号レベルに復元される時縮小される。さらに、その増幅率が非常に大きい場合、復元時の出力誤差は、ゼロに近づく。

ここで、第 n 段目の NN の教師信号である誤差信号の増幅率を A_n として学習した結果得られた誤差信号が、 ε になると仮定する。このとき、NN システム全体に与えられる教師信号に対する出力誤差 e_n は、式(5)で示され、式(6)に示す関係があるとする。さらに、NN の段数が無限大の場合

[†]九州工業大学大学院生命体工学研究科

Graduate School of Life Science and Systems Engineering,
 Kyushu Institute of Technology

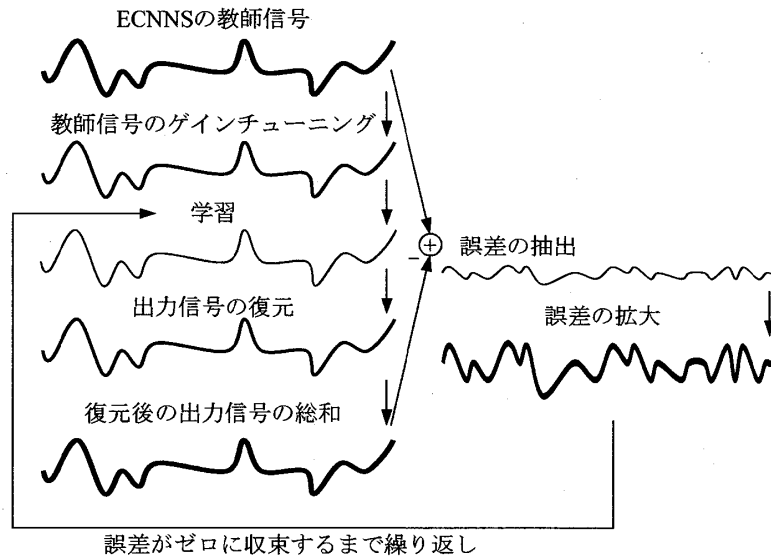


図1 誤差収束型ニューロンネットワークシステムの処理概念

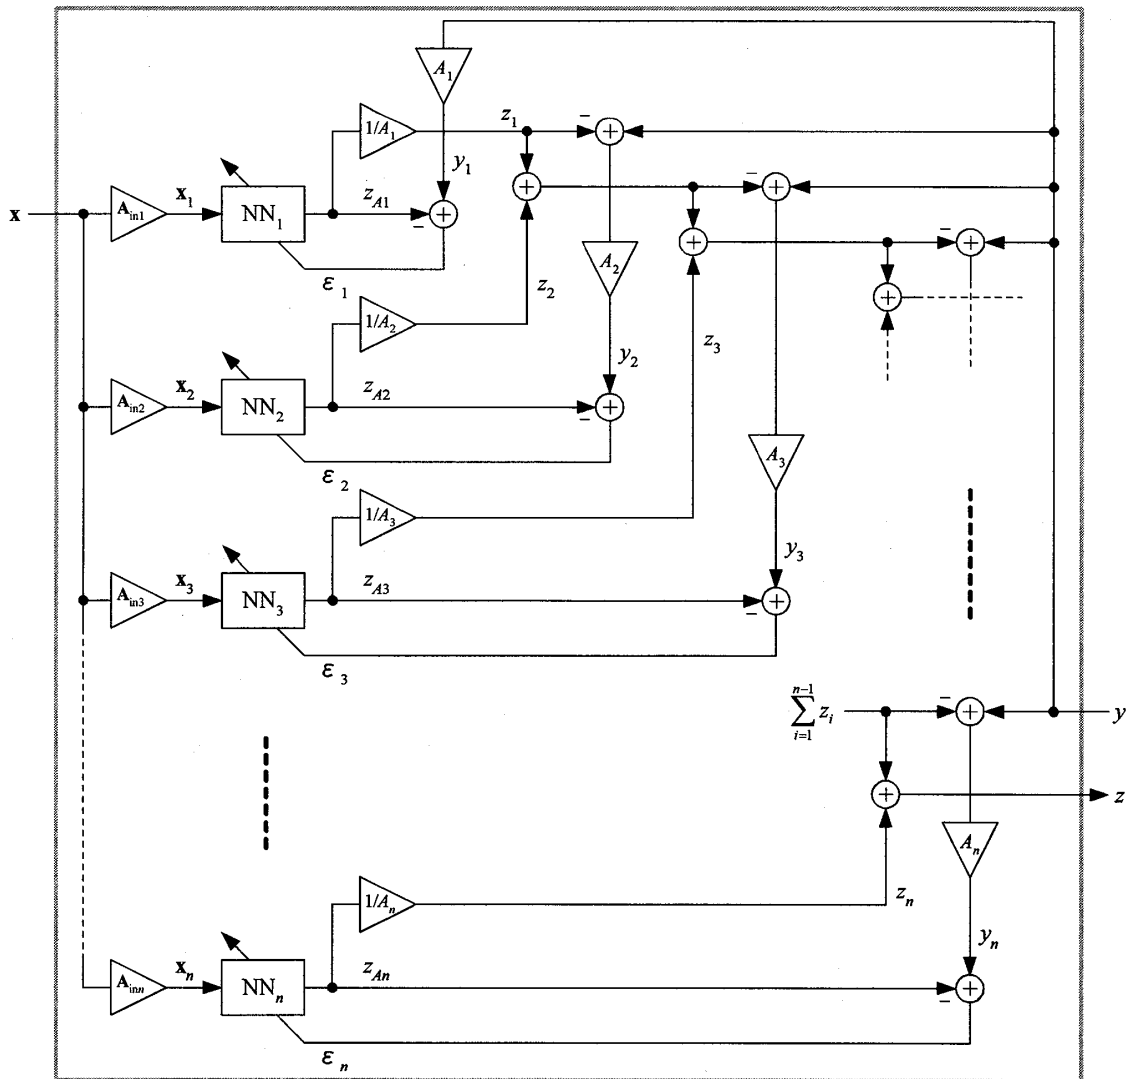


図2 誤差収束型ニューロンネットワークシステム

合、式(7)、(8)より、 ε_n がゼロに収束することが示される。従って、このとき式(3)、(8)より NN システム全体に与えられた教師信号とすべての NN の復元後の出力信号の総和から得られた誤差が、ゼロに収束することが示される。すなわち、NN システム全体に与えられた教師信号とすべての NN の復元後の出力信号の総和は等しくなる。これを式(9)に示す。以上より、前記問題を改善するためのこの手段は、高精度出力を得るために効果的かつ有用であることが示された。これをニューロンネットワークシステムの誤差収束法と呼び、この方法を応用した NN システムを誤差収束型ニューロンネットワークシステム (ECNNS) と呼ぶ。

$$\varepsilon_n = \frac{\varepsilon}{A_n} \quad (5)$$

$$|\varepsilon_n| < |\varepsilon| \quad (6)$$

$$\lim_{n \rightarrow \infty} A_n = \infty \quad (7)$$

$$\varepsilon_n = \lim_{n \rightarrow \infty} \frac{\varepsilon}{A_n} = 0 \quad (8)$$

$$y = \lim_{n \rightarrow \infty} \sum_{i=1}^n z_i \quad (9)$$

ここで、 y は ECNNS の教師信号、 z_i は第 i 段目の NN の復元後の出力信号を示す。

2.2 単出力のニューロンネットワークシステム

図 1 に ECNNS の処理概念を示す。さらに、この概念を基に設計した ECNNS を図 2 に示す。この図中の記号 NN は、1 個のニューロンからニューロンネットワークの状態までを示す。この ECNNS は、内部の NN の入出力関係に応じた最適な処理ができる NN の型と学習則を自由に選択して構成することができる。ここでは、ECNNS の一般的な入出力特性を具体的に ECNNS へ適用した NN の入出力特性に触れずに述べる。

ECNNS は、各段の NN で適切な学習を行うために、それらの入力信号と教師信号の振幅を調整するための増幅器を備えている。さらに、ECNNS は、各段の NN の出力信号を ECNNS の出力信号レベルへ復元するため、それらの出力部に教師信号の増幅率の逆数を増幅率とする増幅器を備えている。ECNNS の入出力特性を式(10)~(15)に示す。さらに、教師信号の関係を式(16)~(18)に示す。ここで、式(15)~(17)で用いられる増幅率の条件を式(19)、(20)に示す。

$$\mathbf{x} = (x_1, x_2, \dots, x_{n_n}) \quad (10)$$

$$\mathbf{A}_{mi} = (a_{i1}, a_{i2}, \dots, a_{im_i}) \quad (i=1, 2, \dots, n) \quad (11)$$

$$\mathbf{x}_i = (a_{i1}x_1, a_{i2}x_2, \dots, a_{im_i}x_{n_n}) \quad (i=1, 2, \dots, n) \quad (12)$$

$$z_{Ai} = f_i(\mathbf{x}_i) \quad (i=1, 2, \dots, n) \quad (13)$$

$$z = \sum_{i=1}^n z_i \quad (14)$$

$$z_i = \frac{z_{Ai}}{A_i} \quad (i=1, 2, \dots, n) \quad (15)$$

$$y_1 = A_1 y \quad (16)$$

$$y_i = A_i \left(y - \sum_{j=1}^{i-1} z_j \right) \quad (i=2, 3, \dots, n) \quad (17)$$

$$\varepsilon_i = y_i - z_{Ai} \quad (i=1, 2, \dots, n) \quad (18)$$

$$A_i \neq 0 \quad (i=1, 2, \dots, n) \quad (19)$$

$$\lim_{n \rightarrow \infty} A_n = \infty \quad (20)$$

ここで、 \mathbf{x} は入力信号ベクトル、 x は入力信号、 \mathbf{x}_i は第 i 段目の増幅後の入力信号ベクトル、 \mathbf{A}_{mi} は第 i 段目の入力信号増幅率ベクトル、 a_i は第 i 段目の信号増幅率、 x と a_i の添え字は信号番号、 z_{Ai} は第 i 段目の NN の出力信号、 f_i は第 i 段目の NN の入出力関係を示す n_{mi} 変数関数、 y は ECNNS の教師信号、 z は ECNNS の出力信号、 y_1 と y_i はそれぞれ第 1 番目と第 i 段目の NN の増幅後の教師信号、 z_i は第 i 段目の NN の復元後の出力信号、 A_i は第 i 段目の NN の教師信号増幅率、 ε_i は第 i 段目の NN の出力誤差を示す。

2.3 複出力のニューロンネットワークシステム

複出力のニューロンネットワークとして、一般的な BP ネットワークを用いると、複出力が共有している中間層で、各出力に対応した学習が原因で生じる学習の干渉が問題となり、高精度な出力を得ることが困難となる。このため、ECNNS を複出力の NN へ適用する場合、ECNNS を並列型ニューロンネットワークの並列ユニットに適用することで、この問題を回避した上、さらに高精度な出力を得ることができる。この NN システムを誤差収束並列型ニューロンネットワークシステム (ECPNNS) と呼び、ECNNS の一般型ともいうことができる。図 3 に ECPNNS を示す。この ECPNNS は、出力と同じ数の ECNNS を適用した並列ユニットから構成されている。

ECPNNS の入出力特性を式(21)~(25)に示す。さらに、教師信号の関係を式(26)~(28)に示す。ここで、式




図 3 誤差収束並列型ニューロンネットワーク

(25)~(27)で用いられる増幅率の条件は、式(29), (30)となる。

$$A_{ij} = (a_{ij1}, a_{ij2}, \dots, a_{ijn_n}) \quad (i=1,2,\dots,m; j=1,2,\dots,n_i) \quad (21)$$

$$x_{ij} = (a_{ij1}x_1, a_{ij2}x_2, \dots, a_{ijn_n}x_{n_n}) \quad (i=1,2,\dots,m; j=1,2,\dots,n_i) \quad (22)$$

$$z_{Aij} = f_{ij}(x_{ij}) \quad (i=1,2,\dots,m; j=1,2,\dots,n_i) \quad (23)$$

$$z_i = \sum_{j=1}^{n_i} z_{ij} \quad (i=1,2,\dots,m) \quad (24)$$

$$z_{ij} = \frac{z_{Aij}}{A_j} \quad (i=1,2,\dots,m; j=1,2,\dots,n_i) \quad (25)$$

$$y_{i1} = A_{i1}y_i \quad (i=1,2,\dots,m) \quad (26)$$

$$y_{ij} = A_{ij} \left(y_i - \sum_{k=1}^{j-1} z_{ik} \right) \quad (i=1,2,\dots,m; j=2,3,\dots,n_i) \quad (27)$$

$$\varepsilon_{ij} = y_{ij} - z_{Aij} \quad (i=1,2,\dots,m; j=1,2,\dots,n_i) \quad (28)$$

$$A_j \neq 0 \quad (i=1,2,\dots,m; j=1,2,\dots,n_i) \quad (29)$$

$$\lim_{n \rightarrow \infty} A_m = \infty \quad (i=1,2,\dots,m) \quad (30)$$

ここで、2つの数字の組合せで表記されている添え字の1番目の数字は並列ユニットの番号、2番目の数字はECNNSのNNの段番号、 y_i は第*i*番目の並列ユニットの教師信号、 z_i は第*i*番目の並列ユニットの出力信号を示す。

2.4 利点

2.4.1 出力の高精度化と学習の高速化

ECNNSの出力誤差は、複数のニューロンネットワークによって収束するため、少ない学習回数で高精度出力が得られる。ここで、ECNNSのNNの段数を無限に設定した場合、最終段のNNが学習で使用する前段のNNの誤差信号は、非常に小さくなる。すなわち、最終段のNNの教師信号の増幅率は非常に大きくなり、ECNNSの出力信号レベルへ復元したときの出力誤差が、ECNNSに与えられた教師信号と比較して皆無に等しくなるため、全NNの出力信号の総和は、非常に高精度な出力信号となる。ECNNSの学習サイクルは、この条件下で1個の教師データだけを学習するならば、理論的に1回となる。例えば、学習則に確率的降下法を用いる場合、前記に示したように高精度な学習が1データ毎実行されるため、安定した出力が数回の学習サイクルで得られると期待される。さらに、ECNNSの出力信号に対する各段のNNの出力信号の成分比率は、学習サイクルの増加とともに、より前段が大きくなると考えられる。ECNNSの学習能力は、NNの段数の増加とともに顕著となり、出力精度や学習速度を向上させると考えられる。

2.4.2 離散時間型ニューロンネットワークの学習能力改善

離散時間型ニューロンネットワーク(DTNN)で使用する信号の標本時間を短くすれば、その能力は向上する。し

かし、デジタル回路の動作周波数、メモリ容量、データ処理時間の制約から、標本周波数の限界が生じる。さらに、データ処理が効率的に行われるための標本周波数は、標本化定理によって、その最低周波数が決定される。しかし、そのデータを用いてDTNNの良好な学習が得られない場合、標本周波数を高くすることで、データ数を増やした状態での学習を行わなければならない。これにより、データ処理が不効率となる。ECNNSは、標本時間の短縮を行わずに、この問題を解決できると考えられる。

3. 実験

3.1 方法

誤差収束型ニューロンネットワーク(ECNNS)の収束能力の検証実験は、1入力1出力の人工ニューロン1個と図2に示すECNNSのNNを1入力1出力の人工ニューロン1個とした最も簡単な構造の1入力1出力のECNNSを用いて行う。ここで用いる人工ニューロンを図4に示す。また、この人工ニューロンの入出力特性を式(31)~(33)に示す。




図4 1入力1出力の人工ニューロン

$$u = wx \quad (31)$$

$$s = u - h \quad (32)$$

$$z = f(s) = A \tan^{-1}(s) \quad (33)$$

ここで、 x は入力信号、 w は結合荷重、 u は入力荷重、 h はしきい値、 s は入力の総和、 z は出力信号、 f は出力関数、 A は出力係数である。また、 w と h は、学習により変更される。

はじめに、人工ニューロンの繰り返し学習が、最も効率的に行われるように、また、ECNNSの人工ニューロンが、1回の学習で最も効率的に行われるように、それぞれの学習強化係数を選定する実験を行う。表1にこの実験条件を示す。両者の人工ニューロンの入力信号値と教師信号値には、入力信号と教師信号をそれぞれの絶対値で除するゲインチューニングを行ったときの値を想定した(-1, -1), (-1, 1), (1, -1), (1, 1)の4組の信号対を用いる。各人工ニューロンの結合荷重としきい値を設定した後、学習強化係数を変化させながら、4組の信号対の学習を1回行う。以上の手順を実験1回とし、これを3回試行する。その結果得られた学習強化係数に対する試行3回の平均2乗平均平方根誤差(RMSE)を比較し、最良な学習強化係数を選定する。人工ニューロンの最良な結果は、次の実験でECNNSの収束能力に対する比較データとして用いられる。

次に、選定した学習強化係数を用いて、ECNNSの収束能力の検証実験を行う。入力信号値と教師信号値には、28桁の正負の整数の擬似乱数値を設定する。そして、これら

表1 学習強化係数選定実験条件

		人工ニューロン	ECNNSの 人工ニューロン
学習則		勾配法	
初期値	結合荷重	-0.3~0.3の疑似乱数値	
	しきい値	-0.3~0.3の疑似乱数値	
学習強化係数	探索範囲	0.1~10	
	探索間隔	0.1~1は0.1, 1~10は1	
出力係数		1	
学習サイクル		3,000	1
実験回数		3	




図5 人工ニューロンの学習強化係数選定実験結果




図6 ECNNSの人工ニューロンの学習強化係数選定実験結果

の信号に対して、前記と同様なゲインチューニングを施す。各段の人工ニューロンの結合荷重としきい値を表1の条件で設定した後、勾配法を用いて学習を開始する。学習は、出力信号値が教師信号値と等しくなるまで、人工ニューロンの段数を増やす。以上の手順を実験1回とし、これを12回試行する。

3.2 結果

図5に人工ニューロンの学習強化係数選定実験で得られた学習強化係数に対する平均RMSEとその標準偏差を示す。この図より、学習強化係数が7のとき平均RMSEが最小となることが示される。さらに、この学習が最良となる条件で試行された12回の実験で得られた人工ニューロンの出力は、教師信号値に必ずしも収束していないことが示されている。




図7 ECNNSの人工ニューロンの段数と正規化誤差




図8 ECNNSの人工ニューロンの段数と平均正規化誤差

図6にECNNSの人工ニューロンの学習強化係数選定実験で得られた学習強化係数に対する平均RMSEとその標準偏差を示す。この図より、学習強化係数が0.8のとき平均RMSEが最小値 1.98×10^{-2} となり、1回の学習が最も効率的に行われることが示されている。

図7に選定した学習強化係数0.8を設定し、収束能力の検証実験を行った結果得られたECNNSの人工ニューロンの段数と出力誤差を正規化した正規化誤差との関係を示す。ここで、正規化誤差とは、ECNNSの教師信号値に対する出力誤差の割合である。ECNNSの出力が教師信号値に収束しても、図7の正規化誤差がゼロになっていない理由は、ECNNSの出力に教師信号値の下1桁より下の位の小さな誤差が残っている状態で、ECNNSの出力値の端数処理が行われ、その値が教師信号値へ丸められているからである。12回の実験すべてにおいて、ECNNSの出力は、教

師信号値に収束した。このとき、人工ニューロンの段数は15~19段で、平均18段であった。図8に図7から得られるECNNSの人工ニューロンの段数と平均正規化誤差とその標準偏差の関係を示す。また、段数当りの正規化誤差は、 3.4×10^{-2} である。これらの図は、正規化誤差が、指数関数的に減少することを示している。

以上の結果より、1入力1出力の人工ニューロンは、1個の教師信号値を繰り返し学習しても、出力が教師信号値に収束しないが、それを用いたECNNSでは、わずか1回の学習で、必ず出力が教師信号値に収束することが示された。さらに、教師信号値の有効数字の桁数に従って、ECNNSのNNの段数を適切に設定すれば、誤差のない非線形信号の出力を実現できる可能性があることも示された。

4. 考察

はじめに、有限段数の人工ニューロンを用いた誤差収束型ニューロンネットワーク(ECNNS)が1個の教師データをわずか1回の学習で習得可能であった理由について考察する。式(7), (8)より、ECNNSの出力誤差は、内部の人工ニューロンの段数を無限大にしなければならないことが示されている。しかし、今回の学習では、ECNNSへ与えられた教師信号値の有効数字の桁数より多い桁数で、ECNNSの学習演算を行うと、ECNNSの出力は、教師信号値が正の場合、教師信号値より小さな値で、教師信号値が負の場合、教師信号値より大きな値で教師信号値に漸近している。この出力を有効数字の桁数に変換する際、コンピュータの端数処理、すなわち、教師信号の有効数字の下1桁より1桁下の数値の4捨5入、または、5捨6入によって教師信号値に丸められ、学習が完成している。さらに、ECNNSの出力が前記のような漸近の仕方をする場合での学習完成時の一般的な処理について述べる。 N 進数の教師信号の有効数字の下1桁より1桁下の数値に対して、教師信号値への収束が最も速やかに得られる切り上げ処理を行った場合、式(34)、または、式(35)の条件を満たした時点で学習を完成させることができる。但し、負数の切り上げは、負の向きに行く。

$$\begin{cases} y \geq 0 \\ y - (N-1)N^r \leq z \leq y \end{cases} \quad (34)$$

$$\begin{cases} y < 0 \\ y \leq z \leq y + (N-1)N^r \end{cases} \quad (35)$$

ここで、 N^r は有効数字の下1桁より1桁下の位を示す。

次にECNNSへ与えた教師信号の有効数字の桁数とそれを学習するために必要な人工ニューロンの段数の関係について考察する。式(34), (35)へ式(14), (15)を代入すると式(36), (37)が導かれる。また、 z_{Ai} を式(38)の段数当りの正規化誤差 ϵ_{normal} と式(18)を用いて表わすと式(39)となる。第*i*段目の教師信号増幅率 A_i を ϵ_{normal} を用いて表わすと式(40)となる。従って、式(36), (37)へ式(39), (40)を代入すると、学習完成時の一般条件の式(41), (42)が導かれる。さらに、これらの式を用いて、1個の教師データを1回の学習で学習完成とするために必要な人工ニューロンの最低段数を求める。実験条件より、教師信号値 y に最大値 10^{28} 、

$1, N = 10, r = -1, \epsilon_{normal} = 0.034$ とすると、段数は20段となる。この値は、今回の実験結果より得られたすべての段数より高い。従って、1個の教師データを1回の学習で学習完成とするために必要な人工ニューロンの最低段数を予測するために、これらの一般条件式は有効であるといえる。また、これらの式は、 ϵ_{normal} が小さいほどその最低段数が少なくなり、 $\epsilon_{normal} = 0$, すなわち、1回の学習で学習完成可能なニューロンやニューロンネットワーク(NN)を用いれば、当然、1段で学習が完成することを示している。その最低段数を減らすためには、学習能力の高いニューロンやNNを用いなければならないことも示している。

$$\begin{cases} y \geq 0 \\ y - (N-1)N^r \leq \sum_{i=1}^n \frac{z_{Ai}}{A_i} \leq y \end{cases} \quad (36)$$

$$\begin{cases} y < 0 \\ y \leq \sum_{i=1}^n \frac{z_{Ai}}{A_i} \leq y + (N-1)N^r \end{cases} \quad (37)$$

$$0 < \epsilon_{normal} < 1 \quad (38)$$

$$z_{Ai} = 1 - \epsilon_{normal} \quad (i = 1, 2, \dots, n) \quad (39)$$

$$A_i = \frac{1}{\epsilon_{normal}^{i-1}} \quad (i = 1, 2, \dots, n) \quad (40)$$

$$\begin{cases} y \geq 0 \\ y - (N-1)N^r \leq (1 - \epsilon_{normal}) \left(1 + \sum_{i=2}^n \epsilon_{normal}^{i-1} \right) y \leq y \end{cases} \quad (41)$$

$$\begin{cases} y < 0 \\ y \leq (1 - \epsilon_{normal}) \left(1 + \sum_{i=2}^n \epsilon_{normal}^{i-1} \right) y \leq y + (N-1)N^r \end{cases} \quad (42)$$

最後に、学習能力と学習で消費されるエネルギーの関係について考える。学習能力が等しい人工ニューロンを用いた場合、1回だけの学習の完成度が高いECNNSほど、用いた人工ニューロンの段数が多い。従って、学習の完成度が高いほど、学習に費やされる計算エネルギーも増大する。これを生物の脳の学習能力と学習で消費されるエネルギーの関係に適用すると、全く習熟されていない事象について、1回だけの学習の完成度が高い脳は、消費エネルギーも多いと推測される。さらに、この相関関係を用いて、一方の物理量を測定することで、他方の物理量を推定できる手法を開発できる可能性もある。その応用としては、脳の能力や障害の簡易評価への適用とその評価を用いた学習の制御や改善等が考えられる。

5. むすび

誤差収束型ニューロンネットワーク(ECNNS)は、教師信号値の有効数字の桁数に従って、ECNNSのニューロン

ネットワーク (NN) の段数を適切に設定すれば, ECNNS に与えた 1 個の教師データをわずか 1 回の学習で習得できるという特性を備えている. 本実験では, この特性を 1 入力 1 出力の人工ニューロン 1 個の繰り返し学習と ECNNS の NN を 1 入力 1 出力の人工ニューロン 1 個とした最も簡単な構造の 1 入力 1 出力の ECNNS の 1 回の学習との比較で検証し, ECNNS の収束能力を確認した. その結果, すべての学習実験において, 人工ニューロン 1 個の出力が, 教師信号値に収束するという保障は示されなかった. しかし, ECNNS の出力は, 学習能力が低い同様の人工ニューロンを用いても, 必ず教師信号値に収束した. このとき, ECNNS に用いた人工ニューロンの段数は平均 18 段であった. さらに, 実験結果より, 1 個の教師データを 1 回の学習で完成させるための一般条件式を求めた. その式から求められる学習を完成させるために必要な人工ニューロンの最低段数の予測値と実験から得られた段数を比較した結果, その予測値は実験から得られたすべての段数より高く, その一般条件式の有効性が示された.

以上の検証により, ECNNS は教師信号値の有効数字の桁数に従って ECNNS の人工ニューロンの段数を適切に設定すれば, ECNNS へ与えた 1 個の教師データをわずか 1 回の学習で習得できるという ECNNS の収束能力の特性が示された. これは, ECNNS が学習により誤差のない非線形信号を出力できる可能性を持っていることをも示している. 今後の課題は, 今回と同様な検証を人工ニューロン 1 個より学習能力の高い NN を用いた ECNNS で行い, その学習能力を確認することである.

謝辞

常日頃から活発に学究活動を推し進め, 自由闊達な研究環境をご提供していただきました皆様に感謝いたします.

参考文献

- [1] C. L. Giles and T. Maxwell, "Learning, Invariance and Generalization in High Order Neural Networks", *Applied Optics*, Vol.26, No.23, pp.4972-4978 (1987).
- [2] K. J. Lang and G. E. Hinton, "A Time-Delay Neural Network Architecture for Speech Recognition", Carnegie Mellon University Computer Science technical report, CMU-CS-88-152, pp.1-37 (1988).
- [3] T. Poggio and F. Girosi, "Networks for approximation and learning", *Proc. of the IEEE*, Vol.78, No.9, pp.1481-1497 (1990).
- [4] 岩本敏, 吉田達徳, 横井博一, "二足歩行ロボットのニューラル制御に関する基礎的検討", *信学技報*, MBE93-106, pp.23-30 (1994).
- [5] 藤末義和, 猪平栄一, 横井博一, "ボルトラネットワークを用いたロボットの制御", *信学技報*, NC2003-78, pp.39-43 (2003).
- [6] 魚田紫織, 横井博一, "階層型運動スキーマによるロボットハンドの運動多様性の実現", *信学技法*, NC2003-75, pp.25-28 (2003).
- [7] 三好純, 横井博一, "四輪操舵車の横滑り角学習用ニューラルネットワークの改善", *信学技報*, NC2004-107, pp.87-90 (2004).
- [8] 重村宗作, 西村敏博, 横井博一, "Volterra filter 組み込み Neural Network による瞬目アーチファクト除去の一手法", *信学技報*, MBE2004-87, pp.57-60 (2005).
- [9] S. Suematsu and H. Yokoi, "A Motion Generating System for Multi-Fingered Myoelectric Hand", *International Congress Series* 1291, pp.257-260 (2006).
- [10] 小早川俊祐, 藤井崇文, 横井博一, "心電図に対するニューロンネットワークの非線形予測能力の評価", *BMFSA 第 20 回年次大会講演論文集*, pp.9-12 (2007).
- [11] S. Kobayakawa, T. Fujii and H. Yokoi, "Evaluation of Prediction Capabilities of Neuron Networks Used for Electrocardiogram", *Proc. of the 5th International Symp. on Management Engineering*, Kitakyushu, Japan, pp.156-161 (2008).
- [12] A. G. Ivakhnenko, "The Group Method of Data Handling-A Rival of the Method of Stochastic Approximation", *Soviet Automatic Control*, Vol.13 c/c of *Avtomatika*, 1, 3, pp.43-55 (1968).
- [13] A. D. Back and A. C. Tsoi, "FIR and IIR Synapses, A New Neural Network Architecture for Time Series Modeling", *Neural Computations*, Vol.3, pp.375-385 (1991).
- [14] 星野美保, 北村佐久, 増田健, 鈴木正樹, 趙晋輝, "RBF ネットワークの多層化とピラミッド型ネットワークの提案", *情報・システムソサイエティ大会講演論文集*, p.28 (2000).
- [15] 木下智樹, 中村清実, "二次元呈示位置自由度を持つ物体の形状と位置を同時認識する二次元拡散連想型ニューラルネット", *信学技報*, NC97-166, Vol.97, No.623-624, pp.209-216 (1998).
- [16] 小早川俊祐, 横井博一, "航空機ピッチ姿勢制御のためのボルトラフィルタ内蔵型ニューラルネットワーク", 平成 17 年度電気関係学会九州支部連合大会講演論文集, p.429 (2005).
- [17] 小早川俊祐, 横井博一, "並列化ニューロンネットワークの航空機における予測問題への適用", *信学技報*, Vol.106, No.471, SANE2006-119-133, pp.43-45 (2007).
- [18] 小早川俊祐, 横井博一, "並列化ニューロンネットワークの予測能力評価", 第 8 回日本知能情報ファジィ学会九州支部学術講演会予稿集, PP.3-6 (2006).
- [19] S. Kobayakawa and H. Yokoi, "Evaluation of the Learning Capability of a Parallel-type Neuron Network", *Proc. of the First International Symposium on Information and Computer Elements* 2007, Kitakyushu, Japan, pp.43-47 (2007).
- [20] 小早川俊祐, 横井博一, "並列型ニューロンネットワークの予測出力精度優位性の実験的検討", *信学技報*, NC2008-1-10, Vol.108, No.54, pp.29-34 (2008).
- [21] S. Kobayakawa and H. Yokoi, "Evaluation for Prediction Accuracies of Parallel-type Neuron Network", *International MultiConference of Engineers and Computer Scientists* 2009 Proc., Hong Kong, China, Vol.1, pp.156-161 (2009).
- [22] 横井博一, 木本智幸, "介在素子を付加した階層型ニューラルネットワーク", *バイオメディカル・ファジィ・システム学会誌*, Vol.1, No.1, pp.87-97 (1999).
- [23] S. Kobayakawa and H. Yokoi, "Proposal of Error Convergence-type Neuron Network System", *Extended Abstracts of 2008 International Symp. on Intelligent Informatics*, Kumamoto, Japan, p.19 (2008).
- [24] S. Kobayakawa and H. Yokoi, "Proposal of Error Convergence-type Neuron Network System", *International Journal of Innovative Computing, Information and Control*, 印刷中, pp.1-10 (2008).
- [25] D.E. Rumelhart, G.E. Hinton and R.J. Williams, "Learning Representations by Back-propagating Errors", *Nature*, Vol.323, No.6088, pp.533-536 (1986).