

卒業研究報告題目

多層化カオスニューラルネットワークにおける  
逐次学習に関する基礎的研究

A Fundamental Study on Incremental Learning in  
Multi-layered Chaostic Neural Networks

指導教員 主査 出口 利憲 教授  
副査 山田 博文 准教授

岐阜工業高等専門学校 先端融合開発専攻

2019Y17 小寺 智仁

---

令和 3 年 ( 2 0 2 1 年 ) 2 月 8 日 提出

## Abstract

In this study, the internal states of multi-layered chaotic neural networks are investigated to improve the learning rate, increase the number of learning patterns, etc., by incremental learning. Chaotic neural networks consisting of chaotic neuron models with refractoriness and spatiotemporal sums were used in this study. The incremental learning method, which is one of the learning methods for associative memory used in chaotic neural networks, was used. Incremental learning was performed on the chaotic neural network with the middle layer added.

The results showed that the input from the middle layer was delayed by several times compared to the input from the input layer. In addition, the delay in input became longer as the learning progressed. Because of the delay, the behavior of the term on the external input of the output layer changed, and the time to meet the learning condition was shifted. In conclusion, on the multi-layered chaotic neural networks, the delay from the middle layer was found out, and it was increased as the learning progresses.

# 目次

## Abstract

<b>第1章 序論</b>	<b>1</b>
<b>第2章 ニューラルネットワーク</b>	<b>3</b>
2.1 ニューロン	3
2.2 ニューロンモデル	3
2.3 ニューラルネットワーク	5
2.4 ホップフィールドネットワーク	6
<b>第3章 カオスニューラルネットワーク</b>	<b>9</b>
3.1 カオス	9
3.2 カオスニューロン	9
3.3 カオスニューラルネットワーク	10
3.4 多層化カオスニューラルネットワーク	11
3.5 動的想起	13
<b>第4章 学習</b>	<b>14</b>
4.1 学習法の分類	14
4.2 ヘップ則	14
4.3 連想記憶 (動的想起)	15
4.4 逐次学習	16
<b>第5章 実験</b>	<b>19</b>
5.1 実験目的	19
5.2 実験モデル・方法	19
5.3 実験結果	19
5.3.1 実験結果 1:遅延の発生	19
5.3.2 実験結果 2:遅延数の増加	21
5.3.3 実験結果 3:遅延時の外部入力に関する項の振る舞い	23
<b>第6章 結論</b>	<b>25</b>
謝辞	26
参考文献	27

## 第1章 序論

人間の脳には、1000億を超えるニューロンが存在することが知られており、これらニューロンがシナプス結合することで大規模かつ複雑なネットワークを構成している。ニューロン単体で行う行動は単純なものであるが、これらが集まることによって優れた記憶能力や処理能力、思考能力といったものを再現している。<sup>1)</sup>

このニューロンによる活動を模倣し、計算機に取り入れたものがニューラルネットワークである。ニューラルネットワークは1943年にアメリカの神経学者であるMcCullochと数学者のPittsがニューロンを単純化し考案したニューロンモデルから始まったとされている。<sup>2)</sup>

彼らはニューロンが興奮状態になると、出力側の軸索に対して1に量子化された電気パルス列の信号を出力し、非興奮状態にあるときは0に量子化された信号を出力すると考えた。ニューロンには樹状突起があり、そこに他のニューロンからの軸索が結合している。この樹状突起から先ほどの信号を受け取る。受け取った信号の総和がニューロンごとに決められたしきい値を超えるとニューロンが興奮状態になり、しきい値を超えないならば非興奮状態になると考え、ニューロンのモデル化を行った。

1949年にカナダの神経心理学者であるヘップ(D.O.Hebb)は、ニューロンが興奮状態となり、刺激を出力すると、その刺激を伝えたシナプス結合の強さは大きくなると考え、より刺激を伝えやすくするという仮説を立てた。この仮説によりニューロンが可塑性を持ち、認識や記憶のもとになっていると主張した。

1982年にアメリカの物理学者であるホップフィールド(J.J.Hopfield)によってニューロン同士が相互結合しているネットワークモデルが提案された。彼は、ニューロンの発火のアルゴリズムと結合係数の組み合わせが決められた神経回路網に適当に与えられた興奮パターンが安定には存在しえず変化していくとき、それにつれて必ず減少していくエネルギー関数が定義できることを示した。さらに、その関数の極小値に達するときパターンは安定になるという神経回路網のダイナミクスを示した。この極小値に対応するパターンを記憶パターンとすれば、ネットワークは適当な刺激パターンから記憶パターンを想起する連想記憶装置となる。

一方、生体としてのニューロンの研究も行われた。ヤリイカの巨大軸索の実験などによってニューロンにはカオス的な反応が確認された。<sup>3)</sup> それらを受けて1990年に合原ら

によってカオスニューロンモデルが発表された。生体にはごく自然に存在するとされるカオスの要素を導入することで、ネットワークがより実際の脳の動作に近くなると期待された。

本来、相互結合型のネットワークは一層で構成されることが大半であるが、深層学習の発展によりネットワークを多層化することによって目的を達成するネットワークが年々増加してきている。そのため本研究では、カオスニューロンモデルで構成されたカオスニューラルネットワークを多層化し、本研究室で用いられている逐次学習法によって学習過程での内部状態の変化を確認することが目的である。カオスニューロンでは、学習する上で外部信号に関する項と他のニューロンからの信号に関する項、不応性に関する項の三項の総和をシグモイド関数に通すことによって値を決定している。その為、内部状態を調査することはカオスニューラルネットワークの学習率の向上や新たな可能性の模索に繋がると考え本研究を行った次第である。

## 第2章 ニューラルネットワーク

### 2.1 ニューロン

動物の脳にはニューロンと呼ばれる情報処理を行う神経細胞が存在する。ニューロンは Figure 2.1 に示す構造をしており、外部から一定以上の電気信号を受け取り、それらがある一定値を超えると興奮し、自らも電気信号を他のニューロンへと出力する。これらのニューロンが互いに結合しあい、ネットワークを形成することで動物の脳は情報を処理している。また、一度興奮した細胞はその後絶対不応期と呼ばれる状態になり、一定の期間は興奮しにくくなる。その後は相対不応期と呼ばれる状態になり、興奮状態になるまでの閾値が高くなるため興奮しにくくなる。

ニューロンには細胞体 (cell body)、軸索 (axon)、樹状突起 (dendrite)、シナプス (synapse) と呼ばれる部位がある。細胞体は細胞核を含むニューロンの中核で、タンパク合成などでニューロンに必要な物質を供給する。軸索は細胞体から伸びた突起で、他のニューロンの樹状突起へと繋がり、電気信号の出力を行う。樹状突起は細胞体から文字通り木の枝状に広がる複数の突起で、接続した他のニューロンの軸索から発せられた電気信号を受け取る。シナプスは、軸索と樹状突起の接合面に存在する部位である。

シナプスは興奮性と抑制性の2種類に分けられ、興奮性のシナプスで接続されたニューロンは片方が興奮するともう一方も興奮しやすくなる (強調作用)。逆に、抑制性のシナプスで接続されたニューロンは、一方が興奮するともう一方のニューロンが興奮しにくくなる (競合作用)。<sup>4)</sup>

### 2.2 ニューロンモデル

ネットワークを構成する要素としてのニューロンの機能を単純化、モデル化したものをニューロンモデルと呼ぶ。以下に示すモデルは、1943年に McCulloch と Pitts により考案されたモデルであり、Figure 2.2 のように表される。このニューロンの動作は以下の式で表すことができる。

$$u = \sum_{i=1}^n x_i w_i - \theta \quad (2.1)$$

$$y = f(u) \quad (2.2)$$

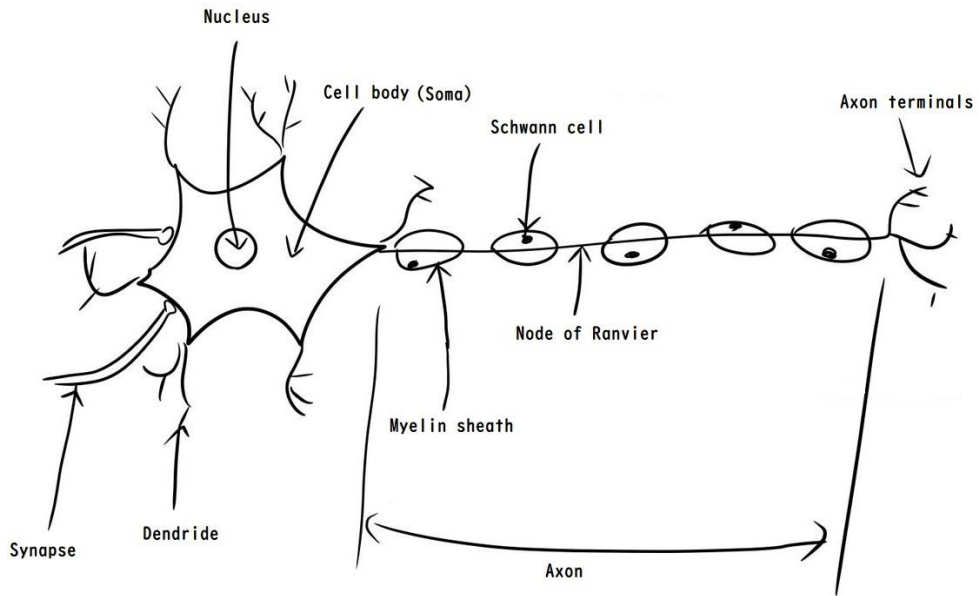


Figure 2.1 Neuron.




Figure 2.2 Neuron Model.

$x_i$  は  $i$  番目の入力を示しており、0 または 1 のパルス入力である。  $w_i$  は結合荷重と呼ばれ、シナプスの結合の強さを示す。  $\theta$  はニューロンの閾値であり、ニューロンの電位がこれを超えるとニューロンは興奮する。  $y$  は出力であり、式 (2.1) での  $u$  は膜電位又は内部ポテンシャルと呼ぶ。この式は、ニューロンが  $i$  番目の入力を受けて  $x_i = 1$  になると、ニューロンの膜電位  $w_i$  が高くなることを表す。この時、  $w_i > 0$  ならばそのシナプス結合は興奮性、  $w_i < 0$  ならば抑制性となる。また、  $w_i = 0$  とならば、シナプス結合がされていないことになる。McCulloch と Pitts のモデルは離散的な入力であるためステップ関数を出力関数とすることが多いが、連続的な入力を考える場合はシグモイ




Figure 2.3 Sigmoid function.

ド関数を出力関数とすることが多い。シグモイド関数は式 (2.3) で表され、Figure 2.3 となる。

$$f(u) = \frac{1}{1 + \exp(-u)} \quad (2.3)$$

## 2.3 ニューラルネットワーク

ニューロンモデルを繋ぎ合わせて構成されたネットワークがニューラルネットワークである。ニューロンモデルの出力を他のニューロンモデルの外部入力に伝達することでネットワークを構成し状態を変化させ出力する。

ニューラルネットワークは、順伝搬型ネットワークと相互結合型ネットワークの二種類に大きく分けられる。Figure 2.4 で表せられる順伝搬型ネットワークでは、入力層、中間層、出力層の階層で構成されており、同じ階層のニューロンは相互に結合していない。そのため、ニューロンの出力は次の階層への一方通行となり、信号を受け取った層は順番に隣接する層のニューロンへと伝搬していく。Figure 2.5 で表せられる相互結合型ネットワークでは、外部から入力を受け取り、ニューロン同士が出力を双方向に伝搬するネットワークである。



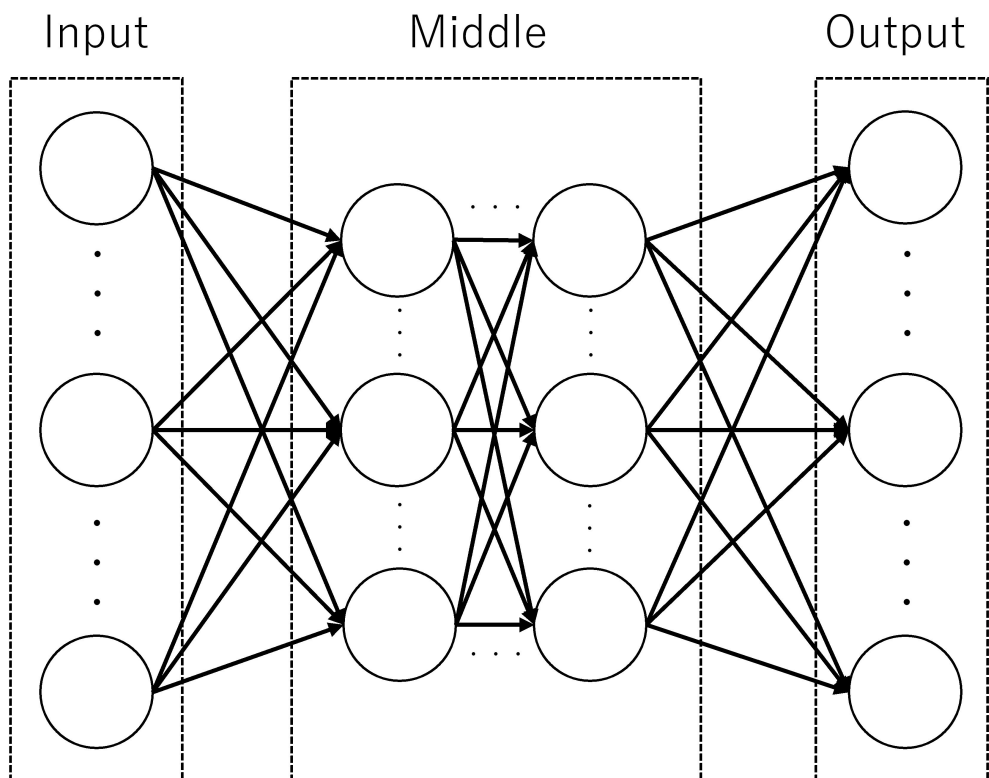


Figure 2.4 Feed forward neural network.

## 2.4 ホップフィールドネットワーク

ホップフィールドネットワークとは、リカレント型の構造のニューラルネットワークである。ホップフィールドネットワークは入力層、出力層がなくすべてのユニットは自分自身を除く他の全てのユニットと結合しており、式(2.4)の等式を満たしている。ホップフィールドネットワークに入力するパターンは二値であり、入力パターン  $\boldsymbol{x}^s$  は  $(x_1^s, x_2^s, \dots, x_n^s)^T$  (但し、 $s = 1, 2, \dots, k$ ) と与えられる。ホップフィールドネットワークに  $k$  個のパターンを記憶させる場合に設定される各ニューロンの結合荷重は式(2.5)で表される。

$$w_{ij} = w_{ji} \quad (2.4)$$

$w_{ij}$ :  $i$  番目のニューロンから  $j$  番目のニューロンへの結合荷重

$$w_{ij} = \sum_{s=0}^{k-1} x_i^s x_j^s \quad (2.5)$$

ホップフィールドネットワークのエネルギーは式(2.6)で計算できる。各ニューロンに初期状態が与えられた後、式(2.6)で与えられたネットワークのエネルギーが最小となる




Figure 2.5 Recurrent neural network.

ように状態変化を収束するまで繰り返す。<sup>5)</sup> この動きは Figure 2.6 での点の動きで例えられる。このエネルギー関数は一般に極小値を複数持つ関数であり、ホップフィールドネットワークが収束する点、つまり記憶してられる情報数も同様に複数である。一般的にホップフィールドネットワークが記憶できるパターン数は、素子数の約 0.15 倍であるとされている。

$$E = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n w_{ij} x_i x_j + \sum_{i=1}^n \theta_i x_i \quad (2.6)$$

$\theta_i$  :  $i$  番目のニューロンの閾値

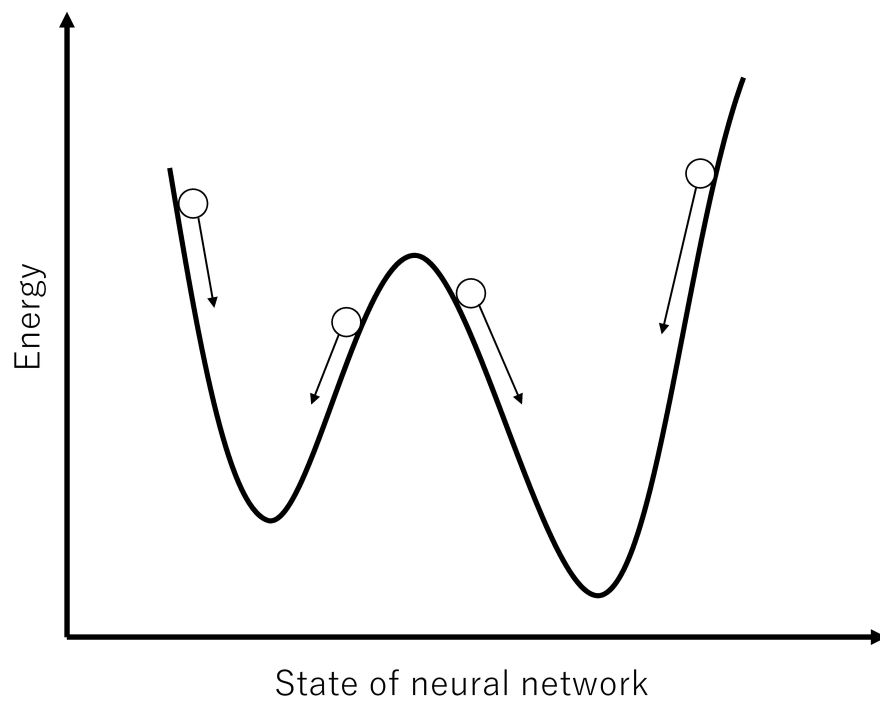


Figure 2.6 Energy of neural network.

## 第3章 カオスニューラルネットワーク

### 3.1 カオス

19世紀末から20世紀末にかけてポアンカレの研究以来、カオスの概念が表舞台に登場してきた。<sup>2)</sup> カオスの定義は研究者によって異なり、統一的な見解は得られておらず、この定義する事自体が大きな問題として取り上げられている。本研究ではカオスを「決定論的力学系において生じる非周期的振動」とする。<sup>6)</sup> カオスを和訳すると「混沌」「無秩序」といった意味となる。基本単位を別個に観察すれば、特定の力学的関係や法則に則っている為、「無作為」とは区別される。

カオス現象の例をあげると炎の揺らめきや海岸に打ち寄せる波、風によって靡く旗などがあり日常生活の中にも様々なカオスを観察することができる。理工学から生物学にはじまり、社会学や経済学の分野にいたるまで、カオスの現象が確認できる。

カオスの特徴として、初期値のごくわずかな差が、将来の結果に多大な影響を生み出すことがあげられる。このようなカオス現象は、人工物、自然物を問わず非線形システムではごく自然に確認できるものである。

具体的なカオスの例としてロジスティック写像がある。これは、式(3.1)で表される方程式で、与えられた $\alpha$ の値によってきわめて複雑な振る舞いをする。初期値がわずかに違うだけでその後の挙動が大きく変化する初期値鋭敏性がある。

$$X_{n+1} = \alpha X_n(1 - X_n) \quad (3.1)$$

### 3.2 カオスニューロン

従来のニューロンモデルは、多数の入力の結合荷重と閾値作用をニューロンの特徴的な機能としモデル化を行っていた。合原らのヤリイカの巨大軸索を用いた実験より、ニューロンに電気刺激を与えた時の応答がカオス的になることが分かった。つまり、ニューロン内にもカオス現象が存在することが確認された。そこで合原らはニューロンに見られるカオス的な振る舞いをニューロンモデルで再現したモデルをカオスニューロンと提唱した。<sup>3)</sup> このモデルはMcCullochとPittsのニューロンモデルでは考慮されなかった一度興奮した後、一定期間興奮しなくなる、あるいは興奮しにくくなるといった性質や、時間とともに電気信号が減衰していく性質を再現している。カオスニューロンモデルの式

は以下のように示される。

$$x(t+1) = f[A(t) - \alpha \sum_{d=0}^t k_r^d g\{x(t-d)\} - \theta] \quad (3.2)$$

$x(t)$ :時刻  $t$  におけるニューロンの出力

$A(t)$ :時刻  $t$  における外部入力の大きさ

$\alpha$ :不応性の時間減数定数

$k_r$ :不応性の時間減衰定数

$g$ :不応性によるフィードバックの大きさを求める関数

$\theta$ :ニューロンの閾値

不応性は、一度興奮したニューロンは興奮後、興奮しにくくなる現象を再現するために設定された性質である。関数  $f$  は出力を一定範囲に制限する関数で、以下のシグモイド関数(式(3.3))を用いる。この式においての  $y$  は入力値であり、 $\epsilon$  は急峻さをきめるパラメータである。

$$f(y) = \frac{1}{1 + \exp(-\frac{y}{\epsilon})} \quad (3.3)$$

### 3.3 カオスニューラルネットワーク

カオスニューラルネットワークとは、カオスニューロンによって構成されたニューラルネットワークのことである。カオスニューラルネットワークは、相互に結合したりカレント型の構造を持ち、式(3.4)で表される。

$$\begin{aligned} x_i(t+1) = & f\left[\sum_{j=1}^M v_{ij} \sum_{d=0}^t k_s^d A_j(t-d) \right. \\ & + \sum_{j=1}^N \omega_{ij} \sum_{d=0}^t k_m^d h\{x_j(t-d)\} \\ & \left. - \alpha \sum_{d=0}^t k_r^d g\{x_i(t-d)\} - \theta_i\right] \end{aligned} \quad (3.4)$$

$M$ :外部入力数

$N$ :ニューロン数

$A_j$ :外部入力の  $j$  番目の値

$x_i(t)$  :時刻  $t$  における  $i$  番目のニューロンの出力

$v_{ij}$  :外部入力からの  $i$  番目のニューロンに対する結合荷重

$\omega_{ij}$  : $j$  番目のニューロンから  $i$  番目のニューロンへの結合荷重

$h$  :出力と不応性との関係を与える関数

$k_s$  :外部入力の時間減衰定数

$k_m$  :他ニューロンからの入力の時間減衰定数

$\theta_i$  : $i$  番目のニューロンの閾値

式 (3.4) において、外部入力を表す第一項を  $\xi_i$ 、ニューロン結合を表す第二項を  $\eta_i$ 、不応性を表す第三項を  $\zeta_i$  とすると、それぞれの項は式 (3.5)、式 (3.6)、式 (3.7) と表される。この三式を踏まえると、式 (3.4) は式 (3.8) のように簡略化できる。

$$\xi_i(t+1) = \sum_{j=1}^M v_{ij} \sum_{d=0}^t k_s^d A_j(t-d) = k_s \xi_i(t) + \sum_{j=1}^M v_{ij} A_j(t) \quad (3.5)$$

$$\eta_i(t+1) = \sum_{j=1}^N \omega_{ij} \sum_{d=0}^t k_m^d h\{x_j(t-d)\} = k_m \eta_i(t) + \sum_{j=1}^N \omega_{ij} x_j(t) \quad (3.6)$$

$$\zeta_i(t+1) = -\alpha \sum_{d=0}^t k_r^d g\{x_i(t-d)\} - \theta_i = k_r \zeta(t) - \alpha x_i(t) - \theta_i(1 - k_r) \quad (3.7)$$

$$x_i(t+1) = f[\xi_i(t+1) + \eta_i(t+1) + \zeta_i(t+1)] \quad (3.8)$$

### 3.4 多層化カオスニューラルネットワーク

本研究室の江本らによってカオスニューラルネットワークを多層化する手法が提案された。江本らは Figure 3.1 で示されるような、入力層、中間層、出力層の三層からなるモデルである。中間層と出力層は自ニューロン以外と相互結合をしており、ニューロンの値を矢印によって接続されている層に出力することによって値を伝えている。このモデルでのニューロンの状態は次の式で与えられる。

$$\begin{aligned} x_i^{ca}(t+1) &= f\left[\sum_{d=0}^t k_s^d A_j^{ca}(t-d)\right. \\ &\quad + \sum_{d=0}^t k_f^d \sum_{j=1}^N \omega_{ij}^{ca} x_j^{ca}(t-d) \\ &\quad \left. - \alpha \sum_{d=0}^t k_r^d x_i^{ca}(t-d) - \theta\right] \end{aligned} \quad (3.9)$$

$$A_i^{ca}(t) = s[x_i^{ip}(t)] \quad (3.10)$$

$$s(u^{ip}) = \begin{cases} 8.75 & \text{if } u > 0.5 \\ 1.25 & \text{else} \end{cases} \quad (3.11)$$

また、このモデルの出力層のニューロン状態は次の式で与えられる。

$$\begin{aligned} x_i^{cx}(t+1) = & f\left[\sum_{d=0}^t k_s^d A_j^{cx}(t-d)\right. \\ & + \sum_{d=0}^t k_f^d \sum_{j=1}^N \omega_{ij}^{cx} x_j^{cx}(t-d) \\ & \left. - \alpha \sum_{d=0}^t k_r^d x_i^{cx}(t-d) - \theta\right] \end{aligned} \quad (3.12)$$

$$A_i^{cx}(t) = s[x_i^{ip}(t), x_i^{cx}] \quad (3.13)$$

$$s(u^{ip}, u^{cx}) = \begin{cases} 8.75 & \text{if } u^{ip} > 0.5 \text{ or } u^{cx} > 0.5 \\ 1.25 & \text{else} \end{cases}$$

$ip$ 、 $ca$ 、 $cx$  はそれぞれ、入力層、中間層、出力層を示す行列である。このモデルは式 (3.14)、式 (3.15) の条件を満たすとき、式 (3.16) に基づいて学習を行う。

$$\text{similarity}(t-2) \neq N \quad (3.14)$$

$$\text{similarity}(t-1) = \text{similarity}(t) = N \quad (3.15)$$

$$\Delta\omega_{ij} = \beta(2x_i(t) - 1)(2x_j(t-1) - 1) \quad (3.16)$$




Figure 3.1 Multilayer chaotic neural network modeled by Emoto et al.<sup>7)</sup>

### 3.5 動的想起

カオスニューラルネットワークの使用例の一つに、動的想起がある。想起とは、一度ネットワークに記憶させた入力データを出力する現象のことをいい、動的想起とは、出力が収束せず、記憶したパターンを様々なパターンを出力する現象である。いくらかのパターンを学習させたカオスニューラルネットワークを外部から入力を与えずに動作させ続けると、ネットワークは学習したパターンの中からいくつかのパターンを動的に想起する。カオスニューラルに含まれる不応性の性質によって、カオスニューラルネットワークで動的想起が発生しやすくなっていると考えられている。



## 第4章 学習

### 4.1 学習法の分類

生物の神経系において脳は過去の経験を記憶として蓄え、これを活用して処理を行う。さらに、自己の動作をより適切なものへと変化させていく。このように自身の構造をより適切な状態に変化させる事を学習と呼ぶ。

脳は多数のニューロンからなるネットワークによって構成されているため、脳の特性的変化とはニューロン間の相互結合の強さを変換させる事で実現する。

このような脳の仕組みをプログラムとして実現させる。ニューラルネットワークでの学習は、特定のアルゴリズムに基づきニューロン間の伝達係数である結合荷重を変化させる事を指す。意味のある学習をするためには、それに応じた何らかの機構が必要である。

学習の指針として、ある入力に対して回路網が出力すべき望ましい出力が外部から与えられる場合、これを教師信号と呼ぶ。その教師信号の入力によって、問題に最適化されていく教師あり学習と、教師信号を必要としない教師なし学習の2つに分けられる。明確な解答が用意される場合には教師あり学習が、データ・クラスタリングなど明確な区別がない場合には教師なし学習が用いられる。結果としていずれも次元削減されるため、画像や統計など多次元量のデータでかつ線形分離不可能な問題に対して、比較的小さい計算量で良好な解を得られることが多い。<sup>1)</sup>

このことから、データ予測やパターン認識をはじめ、様々な分野において応用されている。

### 4.2 ヘップ則

ヘップ則は、アメリカの心理学者 Donald Hebb が提唱したニューロン間の結合荷重に関する仮説である。ヘブ則とも呼ばれる。Hebb はニューロンとニューロンが繋がる接合部のシナプスに長期的な変化が起こって信号の伝達効率が変わることが学習の仕組みであると唱えた。<sup>2)</sup> このヘップ則に基づき、本研究ではニューロンとニューロンが同時に興奮した時にその間の結合荷重を増大させる。それに加えて、片方のニューロンのみが興奮し、もう一方が興奮しない場合には結合荷重を減少させることで記憶の定着を再現した。

### 4.3 連想記憶 (動的想起)

ニューラルネットワークにおける連想記憶とは、次のようなものである。  $N$  個のニューロンに  $M$  本の入力信号が加えられている Figure 4.1 のようなモデルを考える。

このようなモデルで、入力パターン  $\mathbf{x} = (x_1, x_2, \dots, x_M)^T$  ( $x_j$ :ニューロン  $j$  の入力信号がとる値) と出力パターン  $\mathbf{y} = (y_1, y_2, \dots, y_N)^T$  ( $y_i$ :ニューロン  $i$  の出力信号がとる値) の組が複数個 ( $(\mathbf{x}^{(1)}, \mathbf{y}^{(1)}), \dots, (\mathbf{x}^{(P)}, \mathbf{y}^{(P)})$ ) あって、上記の  $P$  個の入力パターンのうちの1つをニューラルネットに入力した時に、対応する出力パターンを出力するように、入出力パターンを記憶させることを連想記憶という。このことは、対称結合のネットワークでいえば、エネルギー関数の極小点が出力パターンになるような結合荷重を作るということになる。この時、ニューラルネットワークが連想記憶を学習する過程を記録過程とよぶ。また、ニューラルネットが入力パターンを与えられることにより、なんらかの出力をすることを想起過程とよぶ。

ニューラルネットにおける連想記憶の特徴として、以下の点が挙げられる。

(1) 分散性記憶である。1つの入出力パターンの組の情報は結合荷重全体に分散して記憶される。また、複数の入出力パターンの組については、分散した情報を重ね合わせて記憶する。

(2) 記憶の取り出し方が並列的である。コンピュータのメモリなどに、直列的に入出力の組を記憶させておくと、取り出すのにかかる時間は記憶させたパターンの組の数、取り出そうとしているパターンの組が記憶されている順番などにより異なる。また、もし取り出そうとしているパターンの組が記憶されていない場合、全てのパターンを探索し終えるまで、記憶されていないことを知ることはできない。しかし、ニューラルネットによる連想記憶の場合、記憶させたパターンの組の数、取り出すパターンの組、取り出そうとしているパターンの組が記憶されているかによらず、かかる時間はほぼ同じである。

(3) 誤り訂正能力を持つ。あいまいな入力パターンから、正しい出力パターンを得ることができる。例えば、 $(\mathbf{x}^{(r)}, \mathbf{y}^{(r)})$  というパターンの組を記憶しているニューラルネットに対し、 $\mathbf{x}^{(r)}$  と若干異なるパターン  $\mathbf{x}^{(r')}$  を入力した場合でも、ニューラルネットは正しい出力パターン  $\mathbf{y}^{(r)}$  を出力する。これは、ニューロンモデルの持つ非線形性が、多少の誤りの影響なら吸収してくれるためである。

連想記憶のうち、記録する入力パターンと出力パターンが一致している連想記憶のことを自己相関記憶、異なっている記憶のことを相互相関記憶という。自己相関記憶を行

なうとき、ネットワークの出力をそのまま入力としてフィードバックする (相互結合型) ことで、情報が何度もネットワークで処理され、誤り訂正能力を強めることができる。このときの誤り訂正能力は、Figure 2.6 のエネルギー関数の谷の幅であるということもできる。入力パターンの状態が記憶したパターンの位置からずれていても、目的のパターンを極小点とする谷に含まれていれば、そのパターンを出力することができる。ただし、ニューラルネットワークのエネルギー関数は、記憶させたパターン以外にも極小点を多数持つため、目的のパターンと入力パターンが離れ過ぎていると、誤ったパターンを出力してしまう。

自己相関記憶において、誤り訂正機能を持つということは次のような意味がある。複数のパターンを記憶したニューラルネットにおいて、記憶しているパターン  $\mathbf{x}^{(r)}$  に非常に良く似たパターン  $\mathbf{x}^{(r')}$  を入力した時、正しいパターン  $\mathbf{x}^{(r)}$  を出力すれば、 $\mathbf{x}^{(r')}$  から  $\mathbf{x}^{(r)}$  を連想したことになる。人間の脳で例えば、複数の記号を記憶している状態で、形の崩れた記号を見せられたとき、記憶している記号の中で最も形の似たものを答えることに当たる。

ニューラルネットワークで自己相関記憶を実現する簡単な方法に、自己相関行列を加算したものを結合行列とするものがある。これを相関学習法といい、式 (2.5) のような結合荷重設定法は、まさに相関学習法である。

#### 4.4 逐次学習

逐次学習法とは、本研究室の浅川氏によって提案されたカオスニューロンモデルに対する学習方法であり、個々のニューロンが自身の内部状態により結合荷重を変化させるかどうかの判定をし、追加学習を行う学習方法である。<sup>8)</sup> 逐次学習は式 (3.7) から式 (3.5) で示したカオスニューロンの内部状態を表す三つの項において式 (4.1) が満たされた時に学習を行う。

$$\xi_i \times (\eta_i + \zeta_i) < 0 \quad (4.1)$$

この条件式により、相互結合の項と不応性の項の和と外部入力の項との積が負の時に、積が正になるまで結合荷重を変化することで学習することを表している。

ニューラルネットワークにおける学習とは、一度入力されたパターンが次に入力されたときに素早く想起できるように結合荷重を変化させることである。結合荷重は相互結




Figure 4.1 Associative memory.

合しているニューロンからの情報の重みであり、相互結合の項のみに影響を与える。相互結合の項が外部入力の項と同じ符号になるように結合荷重を変化させることにより、相互結合の項によりネットワークのエネルギーが極小値に向かおうとする作用と、外部入力によって入力されたパターンに近付こうとする作用が同じように働き、次に同じパターンが入力された時素早く想起できるようになる。また、式 (4.1) が成立し、結合荷重が変化しなくても、しばらく時間が経つと相互結合の項と反対の符号を持つ不応性の項が大きくなってくる。それにより、不応性の項が相互結合の項より大きくなると、学習の条件式が成立し、相互結合の項が不応性の項の大きさを越えるように再び学習が始まる。これを繰り返すことによりネットワークは学習を進めていく。式 (4.1) が成り立つとヘップの原理に従って結合荷重を変化させる。 $i$  番目のニューロンの  $j$  番目のニューロンからの出力に掛かる結合荷重  $w_{ij}$  の変化は式 (4.2) で表される。

$$w_{ij}^{new} = \begin{cases} w_{ij}^{old} + \Delta w & [\xi_i(t) \times x_j(t-1) > 0] \\ w_{ij}^{old} - \Delta w & [\xi_i(t) \times x_j(t-1) \leq 0] \end{cases} \quad (4.2)$$

式(4.2)を繰り返し、ネットワークの結合荷重を少しずつ変化させることで、入力パターンを少しずつ学習していく。この学習法では、個々のニューロンが独自に学習を行うので相関学習に見られた結合荷重の対称性は見られなくなる。また、学習条件が成立した時の結合荷重の変化量がホップフィールドネットワークにおける結合荷重の変化量に比べ少ないという特徴がある。この特徴により、結合荷重は相関学習での結合荷重に比べ取り得る値の数が多くなる。

## 第5章 実験

### 5.1 実験目的

本研究室では、カオスニューラルネットワークを用いた逐次学習についての研究が行われてきた。研究が進むにつれ、カオスニューラルネットワークの性質が少しずつ解明されてきた。一方、計算機の発達により中間層を多く含むニューラルネットワークは画像処理や音声認識、自然言語処理などといった用途で輝かしい成果をあげている。その為、従来一層で構成されているカオスニューラルネットワークに対しても、多層化を行うことが検討された。そこで、本研究では多層化されたカオスニューラルネットワークを用いて逐次学習を行った際の学習に与える影響や学習途中に生じる挙動を確認することで、カオスニューラルネットワークの学習率の向上や学習時間の短縮、学習可能パターン数の増加、使用範囲の拡大等の方法を模索すること目的としている。

### 5.2 実験モデル・方法

今回、実験で使用したモデルとパラメータを Figure 5.1 と Table 5.1 に示す。Figure 3.1 で示した江本らのモデルと同じように、入力層と出力層に加え、中間層をいれた三層のネットワークからできている。各層のニューロンは入力層から中間層、入力層から出力層、中間層から出力層の三方向にのみ出力を伝搬している。各層のニューロン数は100とし、ネットワーク間の結合係数及び学習率等のパラメータは先行研究を基に設定した値である。1と-1の比率が49:51で構成される二値の入力を5パターン用意し、逐次学習法によって学習させた。<sup>9)</sup> 今回の逐次学習法では、各入力パターンを入力層に100回ずつ入力することを1セットと定め、100セット繰り返すことによって学習を行った。

### 5.3 実験結果

#### 5.3.1 実験結果 1:遅延の発生

実験を行い、入力回数が進んでいくと学習過程で出力層に入力される入力層からのデータと中間層からのデータが異なることが確認された。比較しやすいよう出力層からニューロンを一つ選び、1セット分の外部入力の値をグラフ化したものを Figure 5.2 に示す。中間層のニューロンの値は、入力層からのニューロンの値より数回分遅れて入力されているのが確認できる。入力層では、入力データに対応する要素数のデータがそのまま入力




Figure 5.1 Two layer chaotic neural network model used in the experiment.

されているため、入力データが切り替わるたびに1と-1のどちらかが出力層に入力されているため遅れずに入力ができる。一方、中間層ではニューロンの値を計算してから出力層に出力しているため、ニューロンの値が入力データの切り替わりを考慮するまでに数回分の遅れが生じている。中間層のニューロンの値を決定する式(3.8)では、一つ前のニューロンの値を使用して計算しており、入力が切り替わった後も一つ前の外部入力の項の計算結果に代入しながら値を変化させているため、反映されるまでに数回分の入力が必要であった。

Table 5.1 Parameters.

Gradient const. of sigmoid function $\epsilon$	0.015
Attenuate const. of mutual connection $k_m$	0.1
Attenuate const. of refractoriness $k_r$	0.95
Attenuate const. of input $k_s$	0.95
Refractoriness coefficient $\alpha$	0.5
Variation of connection weight in Middle	0.00005
Variation of connection weight in Output	0.00005
Connection weight of Input-Middle	0.6
Connection weight of Middle-Output	0.6
Connection weight of Input-Output	0.6

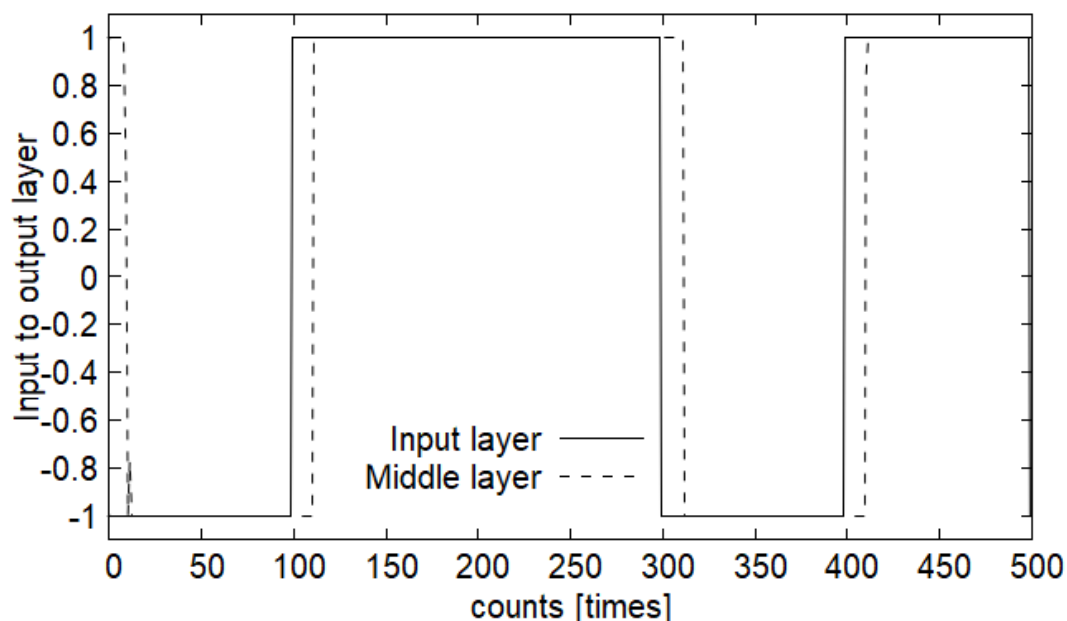


Figure 5.2 Input data to the output layer.

### 5.3.2 実験結果 2: 遅延数の増加

実験結果 1 で中間層からの入力が遅れていることが確認でき、その遅れている数が学習過程で変化することも確認できた。出力層のニューロンを三個用意し、それぞれのセット毎での遅延数を Figure 5.3 に示す。ニューロン毎の遅延数は異なっているが、どれも学習が進むにつれて遅延数が増加していることが確認できる。35 セットを超えると遅延数が 13 ステップで頭打ちとなっていた。この現象は本研究で用いた実験モデルにおいて



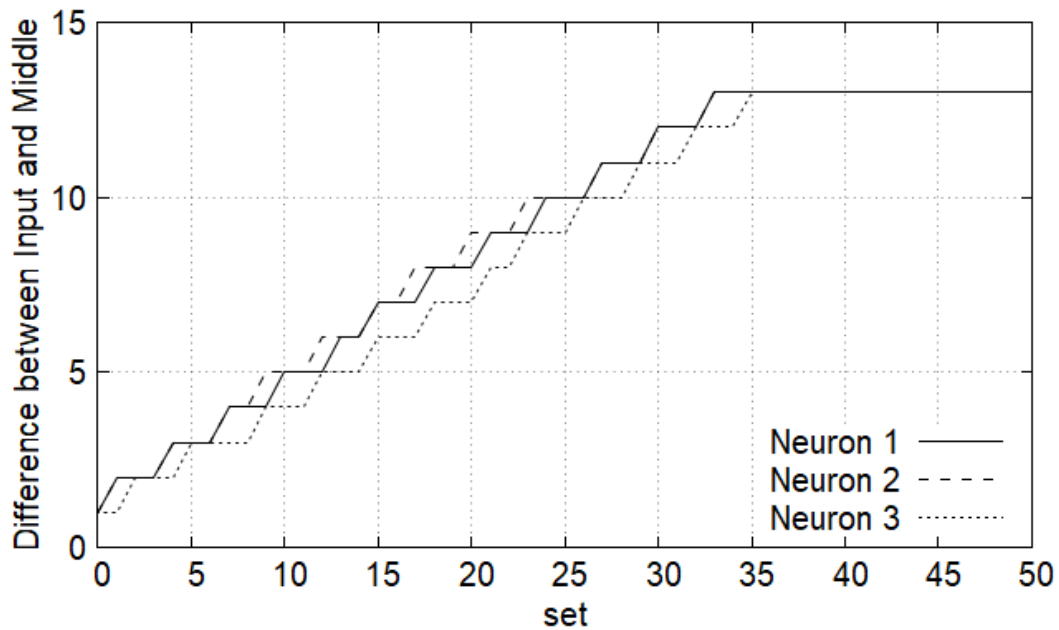


Figure 5.3 Increase in the number of delays.




Figure 5.4 Transition of input patterns from the middle layer to the output layer.

は35セットの時点でニューロン間の結合荷重が殆ど決定したため、学習条件を殆ど満たさなくなり発生していたと考えられる。

ニューロン毎の遅延数にずれが生じているとカオスニューラルネットワークに入力するパターンが異なる。20セット時の中間層からの入力パターンの一部を Figure 5.4 に示す。入力が-1である際は白い四角、1である際は黒い四角で表現した。尚、上部に記載されている数字は出力層への入力数である。10016回目や10019回目の入力本来入力している5つのパターンの1つであるが、10017回目や10018回目の入力では前後の入力パターンが組み合わされた新たなパターンが入力されていた。これは入力が切り替わるたびに発生しており、遅延数が増加するほど後者の新たなパターンが入力される回数が多くなっていた。

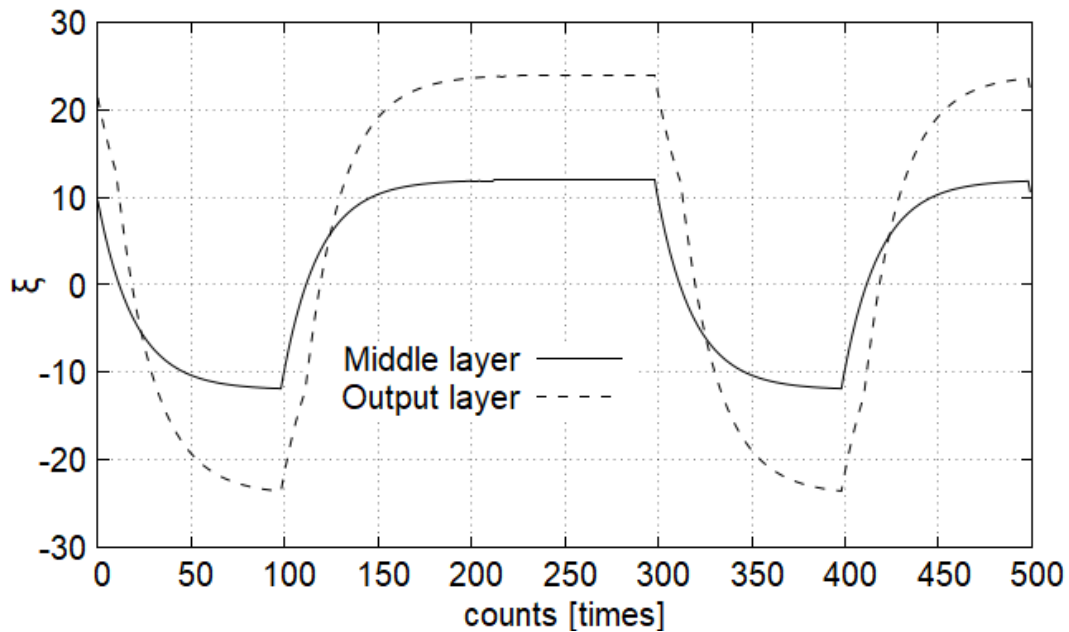


Figure 5.5 Comparison of terms related to external inputs.

### 5.3.3 実験結果 3:遅延時の外部入力に関する項の振る舞い

カオスニューラルネットワークを多層化することで、出力層に与えられる入力に遅れが生じるため、中間層と出力層の外部入力に関する項の増減の仕方にも影響が出ていた。中間層と出力層でニューロンの値を決定する外部入力に関する項(3.5)を同入力回数で比較すると Figure 5.5 のような結果が得られた。出力層では、入力層と中間層の二つの層から入力を受け取るため、絶対値が大きくなっているが、学習に与える影響として重要なのは絶対値ではなく正負の向きである。中間層では値が切り替わると対数関数のような増減を繰り返すが、出力層では入力層と中間層の入力パターンの遅延が発生している場所では緩やかな傾きで増減している。通常増減に緩やかな傾きが加わることで、本来正負が切り替わるタイミングを少し遅らせている。中間層と出力層の学習条件を満たしているタイミングを Figure 5.6 に示した。学習条件を満たしたときは1とし、満たしていない時は0としている。出力層の学習条件を満たす期間は中間層に比べて遅れている。この遅れは先ほど示した傾きによる遅れの分だけずれていた。




Figure 5.6 Comparison of conditions for learning.

## 第6章 結論

本研究では、多層化されたカオスニューラルネットワークに対して、逐次学習を行うことで生じる学習過程でのニューロンの値の振る舞いを調査した。学習を行う際には、ニューロンの値を決定する式に含まれる、外部入力に関する項、ニューロン結合に関する項、不応性に関する項の三項が重要となっている。その為、この三項の振る舞いを重点的に調査した。

学習モデルは入力層と出力層に中間層を加えたモデルであり、入力層から出力層、入力層から中間層、中間層から出力層の三方向にニューロンの値を同じ要素数のニューロンに入力するモデルを使用した。中間層を加えた結果、中間層から出力層へ入力する値が入力層から出力層へ入力する値よりも数ステップ遅れて入力していることを確認した。この遅れて入力される状態は入力回数が多くなればなるほど、遅れるステップ数が増加していく傾向がある。しかし、カオスニューラルネットワークの結合荷重が収束し、殆ど学習条件を満たすことがなくなると、遅れるステップ数は変わらなくなることも確認された。但し、遅れる数は要素ごとによって異なるため、前後の入力パターンを組み合わせさせた結果を入力していた。前後の入力パターンを組み合わせさせた入力パターンを入力していたことによって、動的想起させる際に滑らかな想起が可能となるネットワークが作成できる可能性が考えられる。

また、この遅れて入力される現象は、出力層の外部入力に関する項の計算に影響を与えていた。中間層からの入力データと入力層からの入力データが異なる状態が発生する間、出力層の外部入力に関する項が本来の増減に比べて緩やかな増減をしている状態が発生した。その為、外部入力に関する項の正負が反転するのが遅れ、一層のネットワークに比べ学習条件を満たす時間がずれていた。

今回の研究では、多層化されたカオスニューラルネットワークに対して、逐次学習を行うことで生じる学習過程でのニューロンの値の振る舞いを調査した。学習率の向上や新たな可能性の模索への直接的な繋がりについては、今後の課題としていきたい。

## 謝辞

本研究を進めるにあたり、御多忙中にも関わらず多大なご指導を賜りました出口利憲先生に深く感謝すると共に、同研究室において共に勉学に励んだ遠藤大介氏に厚く御礼を申し上げます。

## 参考文献

- 1) 吉原康成: ニューラルネットワーク, 朝倉書店 (2002)
- 2) 中野馨: ニューロコンピュータの基礎, コロナ社 (1990)
- 3) 合原一幸: ニューラルネットワークにおけるカオス, 東京電機大学出版局 (1993)
- 4) 甘利俊一: 神経回路網モデルとコネクショニズム. 東京大学出版会 (1989)
- 5) 合原一幸: カオス カオス理論の基礎と応用. サイエンス社 (1988)
- 6) 金子邦彦: 複雑系のカオスのシナリオ. 朝倉書店 (1996)
- 7) 江本伸悟, 浅間一, 大武美保子: 逐次学習可能な多層カオスニューラルネットワークを用いた長期記憶形成, 電子情報通信学会技術研究報告, NC2007-113 (2008)
- 8) 浅川新也: カオスニューラルネットによる未知パターンの学習, 岐阜工業高等専門学校専攻科電子システム工学専攻特別研究報告 (2000)
- 9) 酒井菜月: カオスニューラルネットワークにおける逐次学習のパラメータに関する研究 (2014)