

卒業研究報告題目

カオスニューラルネットワークによる  
逐次学習に関する研究

A Study of Incremental Learning  
in Chaotic Neural Network

指導教員 出口利憲 教授

岐阜工業高等専門学校 電気情報工学科

2013E15 久保田 勘太郎

---

平成30年(2018年) 2月16日提出

# Abstract

The human brain consists of a large number of neurons connected to each other and constituting a network. The action each cell performs is relatively simple. Simple things get together and realize things such as superior memory ability, learning ability, thinking ability by simply becoming a system.

A neural network is a model of a network of human neurons. In 1943 American neurologist McCulloch and mathematician Pitts made a simplified neuron model from a biological neuron. In 1949, the foundation of a neural network based on the proposal of the Hebb rule was created. In 1958, the boom of the neural network started from the development of Perceptron.

In this study, a recurrent type chaotic neural network model was used. According to a certain rule, the coupling constant between neurons was changed, and the change in learning result was investigated. Furthermore, the relation between the learning pattern ratio confirmed in past research and the learning result was examined.

# 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>2</b>
2.1 ニューロン	2
2.2 ニューロンモデル	3
2.3 ニューラルネットワーク	4
2.4 ホップフィールドネットワーク	5
<b>第3章 カオスニューラルネットワーク</b>	<b>6</b>
3.1 カオス	6
3.2 カオスニューロン	7
3.3 カオスニューラルネットワーク	8
3.4 動的想起	9
<b>第4章 学習</b>	<b>11</b>
4.1 学習法の分類	11
4.2 誤差逆伝播法	11
4.3 ヘップ則	12
4.4 連想記憶	12
4.5 逐次学習	13
<b>第5章 中期記憶</b>	<b>14</b>
5.1 記憶の種類	14
5.2 大脳皮質	14
5.3 H.M. の臨床例	14
5.4 中期記憶	15
<b>第6章 カオスニューラルネットワークの多層化</b>	<b>16</b>
<b>第7章 実験</b>	<b>18</b>
7.1 実験目的	18
7.2 実験モデル	18
7.3 実験1 パターン素子の比率 1:1 における結合定数を変化させた学習	19

7.3.1	実験方法 . . . . .	19
7.3.2	実験結果 . . . . .	20
7.4	実験 2 パターン素子の比率 1:1 以外における結合定数を変化させた学習 1	21
7.4.1	実験方法 . . . . .	21
7.4.2	実験結果 . . . . .	21
7.5	実験 3 パターン素子の比率 1:1 以外における結合定数を変化させた学習 2	24
7.5.1	実験方法 . . . . .	24
7.5.2	実験結果 . . . . .	25
<b>第 8 章</b>	<b>結論</b>	<b>28</b>
<b>第 9 章</b>	<b>謝辞</b>	<b>30</b>
	<b>参考文献</b>	<b>31</b>

## 第1章 序論

人間の脳は多数のニューロンが互いに接続し、ネットワークを構成することで成り立っている。一つ一つの細胞が行う作用は比較的単純なものでありながら、それが集まり、システムとなるだけで優れた記憶能力や学習能力、思考能力といったものを実現している。<sup>9)</sup> このニューロンによるネットワークを模倣し、モデル化し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て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>1)</sup> 1949年にはカナダの心理学者 Hebb がヘッブ則を提唱し、ニューラルネットワークにおける学習の基礎を築き、<sup>1)</sup> 1958年にはアメリカの心理学者 Rosenblatt がニューロンモデルとヘッブ則を基にパーセプトロンを開発してニューラルネットワークのブームが始まった。それ以降、ニューラルネットワークの研究は活発に行われ、ホップフィールド型ニューラルネットワークや誤差逆伝播法、そしてカオスニューラルネットワークといった技術が開発されてきた。

本研究で用いるカオスニューラルネットワークは、リカレント型ニューラルネットワークにカオス要素を取り入れたモデルである。これは、実際の脳神経系が「カオスダイナミクスを有したカオスデバイス」で構成されたシステムとしてとらえられるという考えに基づいて作成された。<sup>2)</sup>

本研究での目的は、過去の研究で使用されたカオスニューラルネットワークについて、構成するパラメータを変化させ構築を変えることで、過去のニューラルネットワークモデルとの振る舞いの違いを調べることである。今回の研究では、梅田堯英氏の研究で用いられた多層型ニューラルネットワークモデル<sup>3)</sup> について、各モジュール間の結合定数パラメータを変化させ、その時の学習結果の変化を調べた。

今回使用したニューラルネットワークモデルは、人間の脳の入力・海馬・連合野に見立てた三つのモジュールによって構成されるカオスニューラルネットワークモデルであり、その中で入力-連合野間でのやりとりを失くすことにより、古い記憶より新しい入力の方を重要視する特性を持つモデルが作成できると予想される。

今回の研究では、パラメータの一定の規則に基づいた組み合わせに対する学習結果の変化の調査を第一とし、多層型カオスニューラルネットワークモデルについて実験と考察を行なった。

## 第2章 ニューラルネットワーク

### 2.1 ニューロン

ニューロンとは脳にのみ存在する情報処理を行う神経細胞のことである。(図2.1) ニューロンは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。その後も相対不応期と呼ばれる状態になり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)。

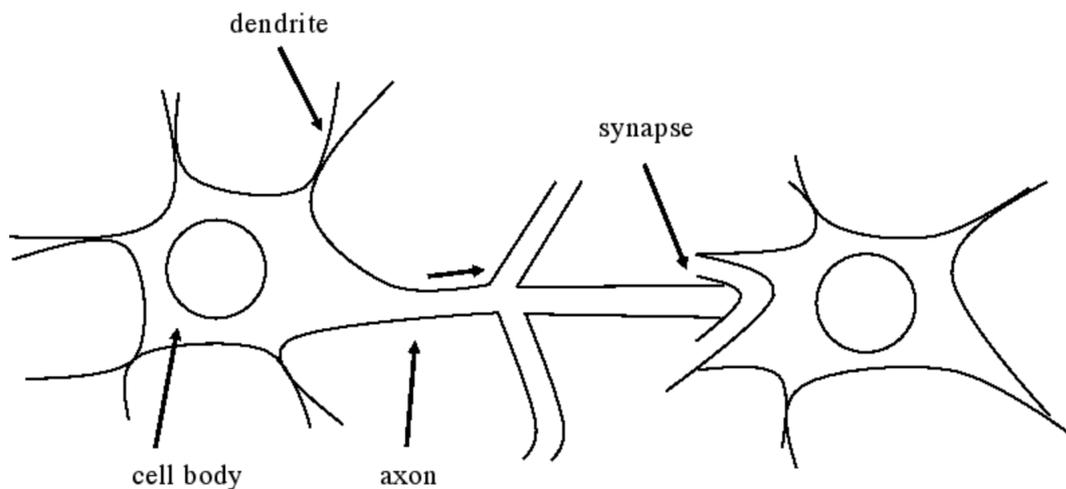


Figure 2.1 Neuron

## 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。ここで使うモデルは、1943年に McCulloch と Pitts により考案されたモデルであり、図 2.2 のように示される。このニューロンモデルの出力  $y$  は以下のように計算される。

$$u = \sum_{i=0}^n x_i w_i \quad (2.1)$$

$$y = \begin{cases} 1 & (u > T) \\ 0 & (u \leq T) \end{cases} \quad (2.2)$$

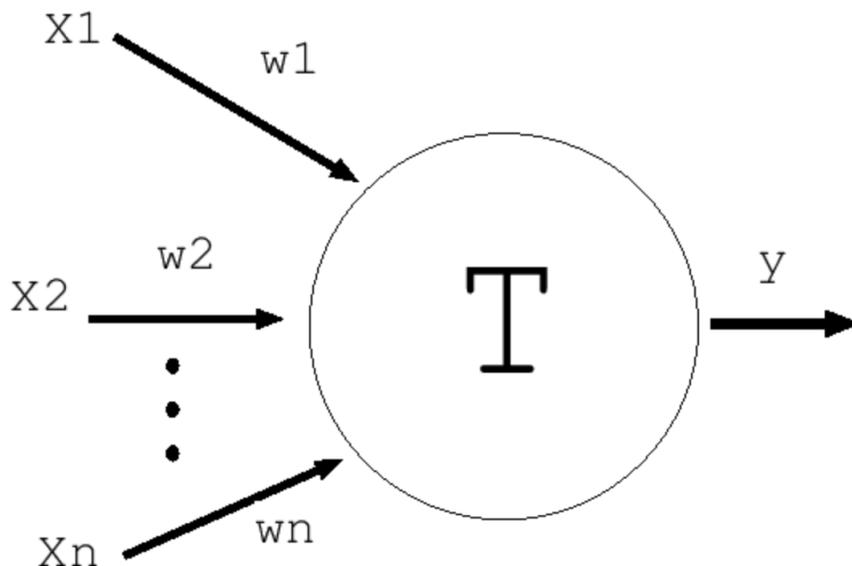


Figure 2.2 Neuron model

$x_0, \dots, x_n$  外部入力

$w_0, \dots, w_n$  結合荷重

$T$  閾値

$y$  出力

## 2.3 ニューラルネットワーク

ニューラルネットワークとは、ニューロンモデルによって構成されたネットワークの総称である。ニューロンが脳内で行うように、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、出力する。

ニューラルネットワークにはフィードフォワード型やリカレント型など様々な構成パターンがある。図2.3のフィードフォワード型はニューロンモデルの信号が一方向にのみ流れる。逆に、図2.4のリカレント型ではニューロンモデルが相互に結合しており、信号は双方向に伝播する。

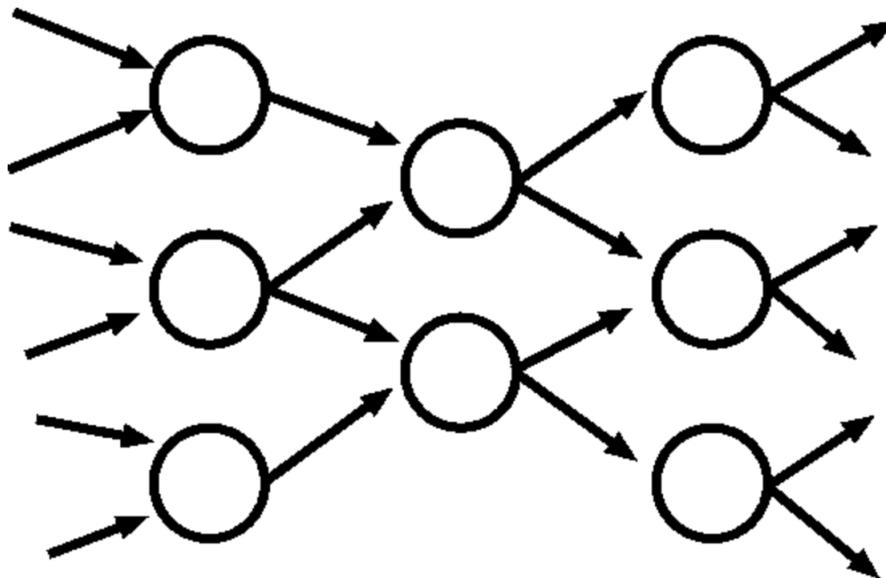


Figure 2.3 Feed forward type

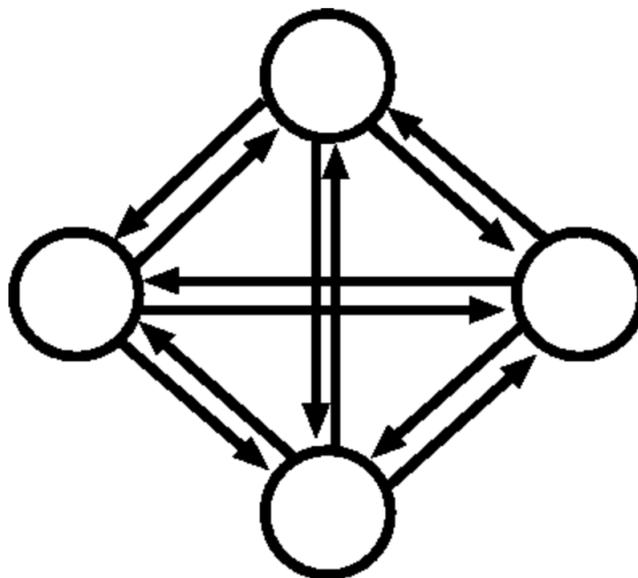


Figure 2.4 Recurrent type

## 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以下の等式を満たし、各ニューロンが非同期定期的に動作するもののである。

$$w_{ij} = w_{ji} \quad (2.3)$$

$w_{ij}$  :  $i$  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

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以下の式で表される。

$$w_{ij} = \sum_{s=0}^{k-1} x_i^{(s)} x_j^{(s)} \quad (2.4)$$

$x_i^s$  パターン  $s$  の  $i$  番目のニューロンの状態

また、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。

ホップフィールドネットワークにはエネルギー関数が存在する。ホップフィールドネットワークは初期状態が与えられた後、エネルギー関数を小さくする方向へと動作し収束する。この動きは図 2.5 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、つまり記憶されている情報数も同様に複数ある。

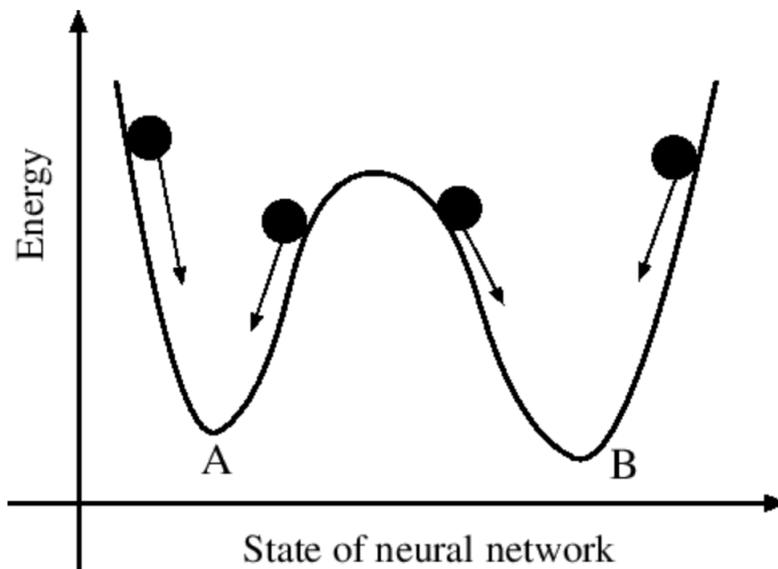


Figure 2.5 Energy function of neural network

## 第3章 カオスニューラルネットワーク

### 3.1 カオス

カオスとは「決定論的システムにおいて起こる確率論的な振る舞い」のことである。<sup>4)</sup>つまり、構造自体は理論的に示されているが、条件の変化による振る舞いに規則性を見出しにくい、もしくは見出せない振る舞いのことを指す。カオスは初期条件が決まれば、常に同じ振る舞いをするという点でランダムとは異なるものの、ランダムのように不規則で将来の予測が困難な挙動である。カオスは初期値の僅かな差によってその後の挙動が大きく変化する、初期値鋭敏性を持つ。また非線型性を持ち、非周期的でもある。

カオスの代表的なものに、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 $\alpha$ の値によって極めて複雑な振る舞いをする。ロジスティック写像の振る舞いの一つを図3.1に示す。

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

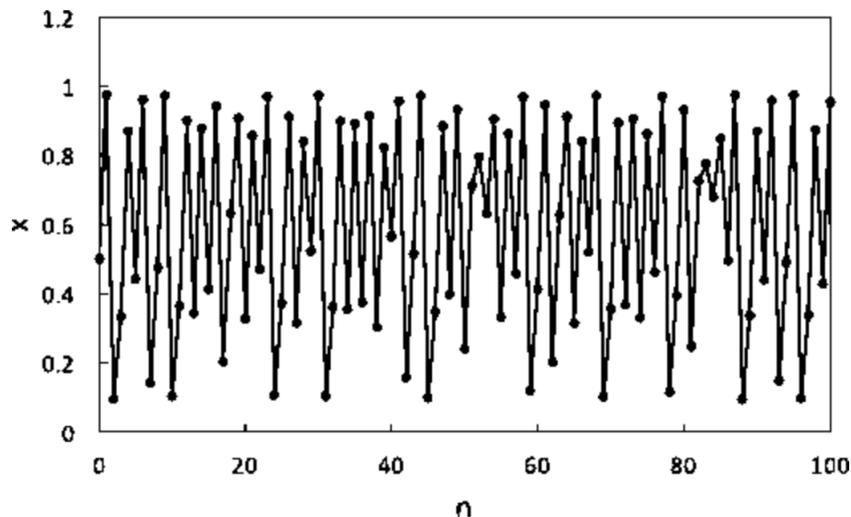


Figure 3.1  $\alpha=3.9$ ,  $X_0=0.5$

### 3.2 カオスニューロン

カオスニューロンは、ニューロンモデルにカオスを導入したモデルである。現実での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で、合原一幸らによって提唱された。<sup>5)</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、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表される。

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

$x(t)$  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さき

$\alpha$  不応性に対する係数

$k$  不応性の時間減衰定数

$g$  軸索の伝達関数

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。

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

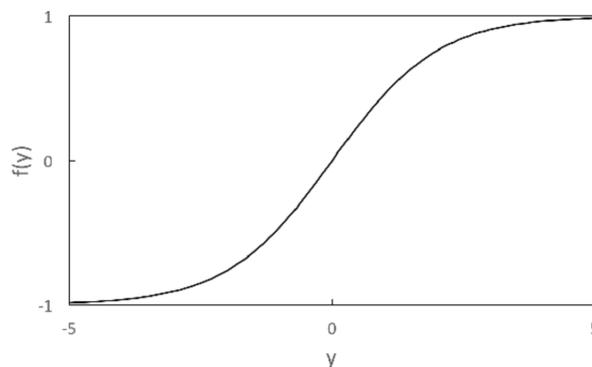


Figure 3.2 Sigmoid function(  $\epsilon = 1$  )

### 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、以下の式で表される。

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

$M$  外部入力数  $N$  ニューロン数

$x_i(t)$  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

$k_r$  不応性の時間減衰定数

$\theta$   $i$  番目のニューロンの閾値

式 (3.5) の関数  $f$  において、外部入力を表す第一項を  $\zeta_i$ 、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  $\xi_i$  とすると、式 (3.5) は以下のように簡略化できる。

$$\begin{aligned}
 \zeta_i(t+1) &= \sum_{j=1}^M v_{ij} \sum_{d=0}^t k_s^d A_j(t-d) = k_s \zeta_i(t) + \sum_{j=1}^M v_{ij} A_j(t) \\
 \eta_i(t+1) &= \sum_{j=1}^N \omega_{ij} \sum_{d=0}^t k_m^d h\{x_j(t-d)\} = k_m \eta_i(t) + \sum_{j=1}^N \omega_{ij} x_j(t) \\
 \xi_i(t+1) &= -\alpha \sum_{d=0}^t k_r^d \{x_i(t-d)\} - \theta_i = k_r \xi_i(t) - \alpha x_i(t) - \theta_i(1 - k_r)
 \end{aligned} \tag{3.5}$$

$$x_i(t+1) = f[\xi_i(t+1) + \eta_i(t+1) + \zeta_i(t+1)] \tag{3.6}$$

### 3.4 動的想起

ネットワークが記憶したパターンを出力する現象を想起するという。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し出力していく。カオスニューラルネットワークの特徴の一つに、動的想起というものがあげられる。動的想起とは、出力が収束せず、記憶したパターンを含む様々なパターンを出力する現象である。ネットワークが動的想起を示す時、ネットワークは動的想起状態にあるという。動的想起の原因には、カオスニューロンに含まれる不応性が挙げられる。

これは記憶検索と呼ばれる、ネットワークに記憶してある検索したいパターンそのものを入力して探し出すのではなく、検索したいパターンの特徴のみを入力することによって、目的とするパターンを見つけ出す手法において非常に重要な現象である。

例として、A,B,Cの形を順に学習させたカオスニューラルネットワークの動的想起の状態を、図3.3に示す。図3.3より、 $t = 36$ までは最後に学習したCを想起し続けているが、次のステップからは形が崩れ始めているのがわかる。また、 $t = 43$ から、学習したパターンであるBを想起していることがわかる。このように、学習したパターンを入力を与えられずに動的に想起する現象が、動的想起である。<sup>6)</sup>

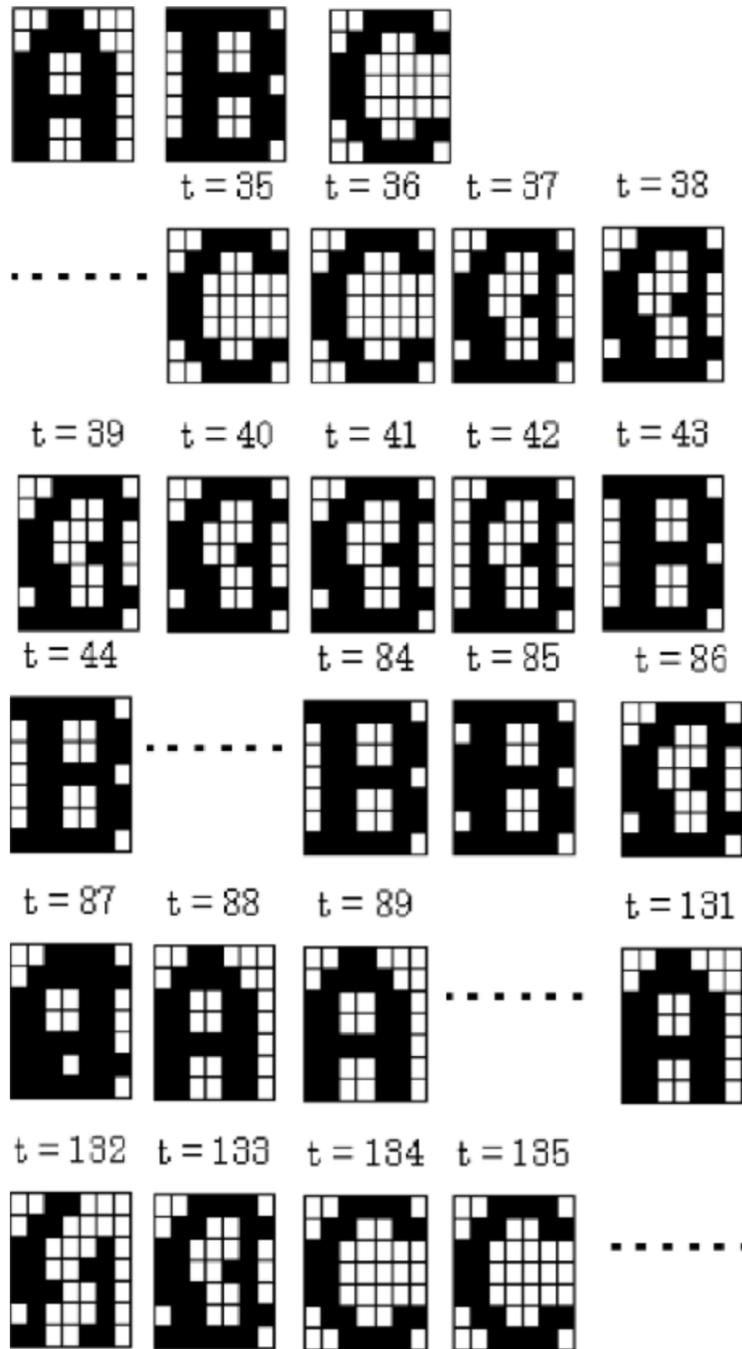


Figure 3.3 Dynamical Recollection

## 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なう。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。結合の強さの変換というのは具体的には、結合を断ち切ったり、新しい結合を作成したりする事を指す。

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(正解)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>7)</sup>。

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

### 4.2 誤差逆伝播法

誤差逆伝播法(バックプロパゲーション)とは、1986年に米スタンフォード大学のRumelhart教授らが発表した多層階層型ニューラルネットワークの学習方法である。<sup>8)</sup>

方法の要約は次の通りである。

1. ニューラルネットワークに学習のためのサンプルを与える。
2. ネットワークの出力とそのサンプルの最適解を比較する。各出力ニューロンについて誤差を計算する。
3. ここのニューロンの期待される出力値と倍率を、要求された出力と実際の出力の

差を計算する。

4. 各ニューロンの重みを局所誤差が小さくなるよう調整する。
5. より大きな重みで接続された前段のニューロンに対して、局所誤差の責任があると判定する。
6. そのように判定された前段のニューロンのさらに前段のニューロン群について同様の処理を行う。

この方法によって、従来のパーセプトロンでは学習することのできなかった非線形分離問題を解決できるようになった。

### 4.3 ヘップ則

ヘップ則は、Hebbが提唱したニューロン間の結合荷重の変化に関する法則である。ヘップ則では、2つのニューロンが同時に興奮した時、その間の結合荷重を増大させ、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は結合荷重を減少させる。<sup>1)</sup> この法則に基づき、ニューロン間の結合定数を変化させていくと、特定のニューロン間の繋がりが太くなり、その結果特定の細胞への情報伝達経路が形成される(流れやすくなる)。

### 4.4 連想記憶

人間は自分の脳に蓄積された記憶を、連想によって検索すると言われている。ニューラルネットワークにおける連想記憶 (Associate memory) とは、複数個の入力パターンのうち一つをニューラルネットワークに入力したときに、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することである。入力パターンと出力パターンが同じベクトル空間となる連想記憶を自己相関連想記憶 (Autoassociative memory) と呼ぶ。異なるベクトル関数空間となるものを相互相関連想記憶 (Heteroassociative memory) と呼ぶ。自己相関連想記憶とは、例えば、ワープロの文字を記憶しておき、手書きの文字などを入力した場合、記憶しているワープロの文字がどれが一番近いかを答えることに相当する。相互相関連想記憶とは、「りんご」は「赤い」と連想するように、入力と出力の関係を記憶して、与えられた入力に対してそれにあうような出力を出すことに相当している。<sup>9)</sup>

## 4.5 逐次学習

逐次学習とは、カオスニューラルネットワークの学習に用いられる学習方法である。この方法は入力の度にニューロンが結合荷重を入力に合わせて変化させ、逐次的に学習を行う方法である。逐次学習はヘップ則に基づいて行われ、2つのニューロンが同時に興奮した場合は結合荷重を増加させ、片方が興奮してもう片方が興奮しなかった場合は結合荷重を減少させる。ニューロンが学習を行う条件は以下の式で与えられる。<sup>10)</sup>

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

式(4.1)を満たしていないニューロンは、現在の入力を既に学習しているためこれ以上結合荷重を変化させない。一方、条件を満たすニューロンは現在の入力をまだ学習しきっていないため、以下の式(4.2)に基づいて結合荷重を変化させ学習を行う。

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

$\omega_{ij}^{old}$  変化前の結合荷重

$\omega_{ij}^{new}$  変化後の結合荷重

$\Delta\omega$  結合荷重の変化量

## 第5章 中期記憶

### 5.1 記憶の種類

記憶とは、環境との相互作用によって生ずる、経験の記録、これの保持、これの再生をする過程を指す脳内の持続的変化である。この記憶には、一時的な短期記憶と、より永続的な長期記憶がある。また、記憶される情報のタイプで分類すると、認知記憶と手続き記憶と分けられる。前者は、以前見たことがある出来事や風景の記憶を思い出すことによって意識にのぼってくるもの、後者は熟練した技能や条件反射など、意識しなくても行動に現れる記憶とされる。

短期記憶の過程は脳内の特定の神経回路を信号が巡回する動的過程であるとされている。海馬に対して高頻度で連続刺激が行われると、長時間(約1時間～数日にわたる)の伝達効率の上昇が起こる。この現象を長期増強といい、短期記憶の基礎をなすと考えられている。

### 5.2 大脳皮質

大脳皮質は、大脳の機能を制御する部位であり、脳の中心的存在である大脳半球の中でも非常に重要な部分である。大脳皮質はその発生から古い部分と新しい部分に分けられる。

古い部分は古皮質と呼ばれ、すべての脊椎動物に見られる脳の系統の中で最も古い時期に発生した皮質であり、主として嗅覚情報を処理する皮質領域である。高等な哺乳類や人間では退化する傾向にある。

原皮質は両生類以上の生物に見ることができ、哺乳類になっても退化せず複雑な構造を示す。海馬は原皮質の代表的な構造であり、記憶などの高度な神経機能に役立っている。

新皮質は哺乳類が著しく発達しており、両生類や爬虫類は古皮質や原皮質が大脳のほとんどを覆っているが、哺乳類になると新皮質が発達し、それらは内側に押しやられる。特に人のような極度に新皮質が発達した動物では大脳のほとんどが新皮質に覆われている。

### 5.3 H.M. の臨床例

脳内の海馬と呼ばれる部位は、記憶形成において重要な役割を担っていると考えられている。そして、その機能の解明に大きな貢献をした人物として Henry Molaison(以下

「H.M.」と称する)が挙げられる。H.M. はてんかん治療のため海馬とその近傍の摘出手術を受けた後、術前3年間の記憶に対する部分的な逆行性健忘症と、術後の記憶の定着ができなくなる順向性健忘症を発症した。しかし、術前3年以上前の記憶は思い出すことが可能であり、短期記憶も問題がない等、記憶能力が全て失われていたわけではなかった。<sup>14)</sup>

これらの症例から、海馬は非永続的な記憶を保持すると共に、記憶の形成に大きな影響を与えていると推測されている。

## 5.4 中期記憶

中期記憶は海馬が記憶している非永続的な記憶である。伊藤真らはH.M.の臨床例で失われた海馬が保持する非永続的な記憶を、連合野が保持する永続的な長期記憶とは異なるものであるとして、中期記憶と名付けた。<sup>11)</sup>

## 第6章 カオスニューラルネットワークの多層化

カオスニューラルネットワークを多層化したモデルとして、図6.1のように表される江本らによって提唱されたモデルがある。<sup>12)</sup> このモデルは、入力層、海馬モジュール、連合野モジュールの3層からなるモデルであり、以下の現象を発現可能としたものである。

- 逐次記憶
- メタ記憶
- 由想起性
- 中期記憶による長期記憶の形成
- H.M. の臨床例に対応する現象
- エピソード記憶
- 意味記憶

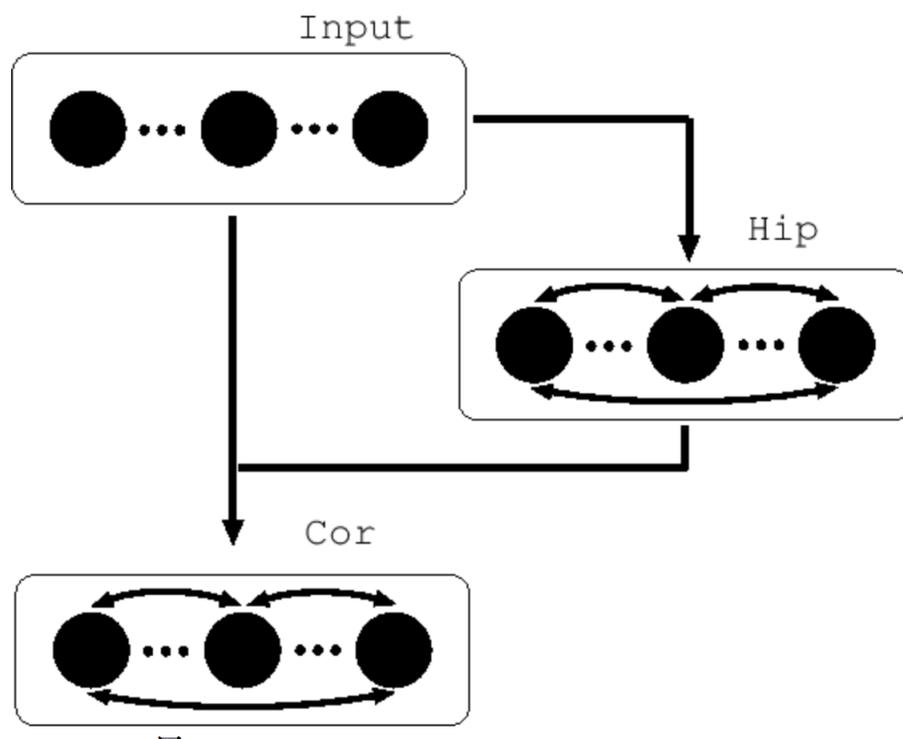


Figure 6.1 Network structure of model modeled by Emoto etc.

このモデルの海馬モジュールのニューロンの状態は次の式で与えられる。

$$x_i^{ca}(t+1) = f\left[\sum_{d=0}^t k_s^d A_j^{ca}(t-d) + \sum_{d=0}^t k_f^d \sum_{j=1}^N \omega_{ij}^{ca} x_j^{ca}(t-d) - \alpha \sum_{d=0}^t k_r^d x_i^{ca}(t-d) - \theta\right] \quad (6.1)$$

$$A_i^{ca}(t) = s[x_i^{ip}(t)] \quad (6.2)$$

$$s(u^{ip}, u^{cx}) = \begin{cases} 8.75 & \text{if } u^{ip} > 0.5 \text{ or } u^{cx} > 0.5 \\ 1.25 & \text{else} \end{cases} \quad (6.3)$$

$ca$ ,  $cx$ ,  $ip$  はそれぞれ、海馬モジュール、連合野モジュール、入力層を示すインデックスである。このモデルでは式 (6.4)、式 (6.5) の条件を共に満たすとき、式 (6.6) の式に基づいて学習を行う。

$$similarity(t-2) \neq N \quad (6.4)$$

$$similarity(t-1) = similarity(t) = N \quad (6.5)$$

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

$$similarity = \sum_{i=1}^N x_i^{\text{index1}} x_i^{\text{index2}} \quad (6.6)$$

$N$  素子数

$\beta$  学習定数

## 第7章 実験

### 7.1 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を行ってきた。前年度までの研究で、この逐次学習に適したパラメータや学習データの比率、海馬による中期記憶、順向性健忘の再現を行った。今回の実験では、過去の研究<sup>3)</sup>における、入力・海馬・連合野の各モジュールの組み合わせによる中期記憶再現を目的としたニューラルネットワークモデルにおいて、入力から連合野への伝達が無くなった場合の特性を調べた。

### 7.2 実験モデル

今回実験に使用したカオスニューラルネットワークモデルを図7.1に示す。これは過去の研究で扱われたネットワークモデルにおいて、入力モジュールから連合野モジュールへの伝達を無くしたものである。実質的には入力層-中間層-出力層のモジュールの繋がりからなり、出力層から中間層へのフィードバックが追加されたモデルと言える。

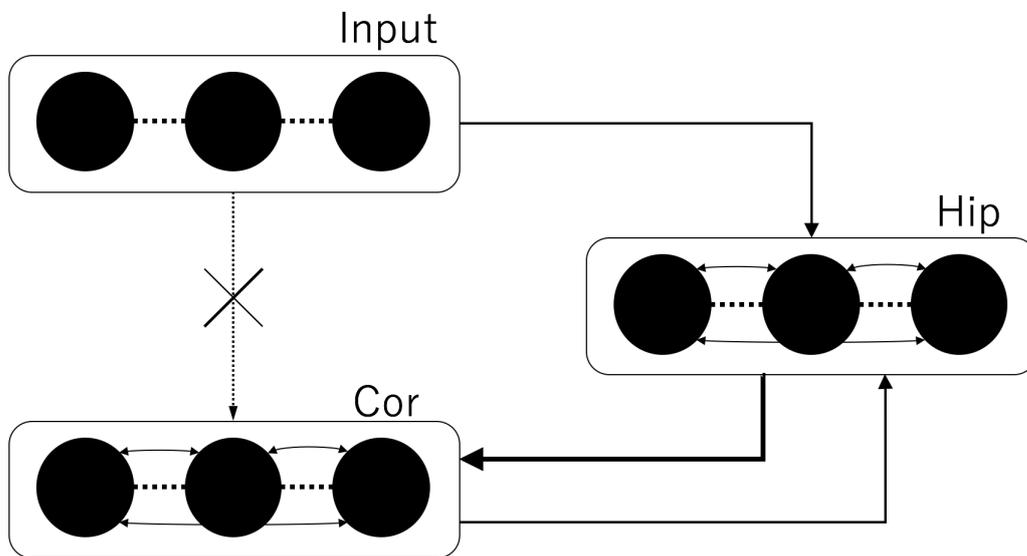


Figure 7.1 Neural network model

今回の研究では、このモデルのうち海馬-連合野の結合定数 ( $v_{-hc}$ ) を 2.0 に固定し、入力-海馬、連合野-海馬の結合定数 (前者は  $v_{-ih}$ 、後者は  $v_{-ch}$ ) の総和を 2.0 となるようにしたうえでその比率が変化する。海馬、連合野モジュールの  $i$  番目のニューロンの状態は

次の式 (7.1) で与えられる。

$$x_i(t+1) = f[\xi_i(t+1) + \eta_i(t+1) + \zeta_i(t+1)] \quad (7.1)$$

式 (7.1) において、外部入力を表す第一項は  $\zeta_i$  , ニューロン結合を表す第二項は  $\eta_i$  , 不応性を表す第三項は  $\xi_i$  で表され、各式は次の式 (7.2)~(7.4) で表される。

$$\zeta_i(t+1) = \sum_{j=1}^M v_{ij} \sum_{d=0}^t k_s^d A_j(t-d) = k_s \zeta_i(t) + \sum_{j=1}^M v_{ij} A_j(t) \quad (7.2)$$

$$\eta_i(t+1) = \sum_{j=1}^N \omega_{ij} \sum_{d=0}^t k_m^d h\{x_j(t-d)\} = k_m \eta_i(t) + \sum_{j=1}^N \omega_{ij} x_j(t) \quad (7.3)$$

$$\xi_i(t+1) = -\alpha \sum_{d=0}^t k_r^d g\{x_i(t-d)\} - \theta_i = k_r \xi(t) - \alpha x_i(t) - \theta_i(1 - k_r) \quad (7.4)$$

また、学習方法については参考文献<sup>3)</sup>と同条件の、ヘップ則に基づいた式に従って逐次学習で行うこととした。本実験で使うモデルの各種パラメータの値を表 7.1 に示す。

Table 7.1 Various parameters

$\varepsilon$	0.015
km	0.1
kr	0.95
ks	0.95
alp	0.0006
dw_c	0.000003
dw-h	0.000003

## 7.3 実験 1 パターン素子の比率 1:1 におけるの結合定数を変化させた学習

### 7.3.1 実験方法

前年度までの研究の中で、逐次学習における学習パターンの素子数の比率が 1:1 の時、学習結果に影響する現象が見られた(参考文献<sup>13)</sup>)。よって素子比率 1:1 の条件下での結合

係数パラメータを変動させ、その時の学習成功数を調べた。今回の研究では一貫して学習パターンは「1」「-1」2種類の素子100個の羅列で表され、この実験では「1:-1=1:1」の比率となる。つまり1パターン100素子で構成され、その内訳は「1」50素子、「-1」50素子がランダムで配列されたものとなる。これを300パターン学習させ、1パターン学習するごとにこの条件のもと、入力-海馬、連合野-海馬の結合定数を変化させ、その時の学習結果を測定した。結合定数以外のパラメータは表7.1に従う。

### 7.3.2 実験結果

「1」と「-1」の比率が1:1の学習パターンにおいて、入力-海馬、連合野-海馬の結合定数パラメータを変動させた時の、学習パターン数と学習成功パターン数の関係のグラフを図7.2に示す。

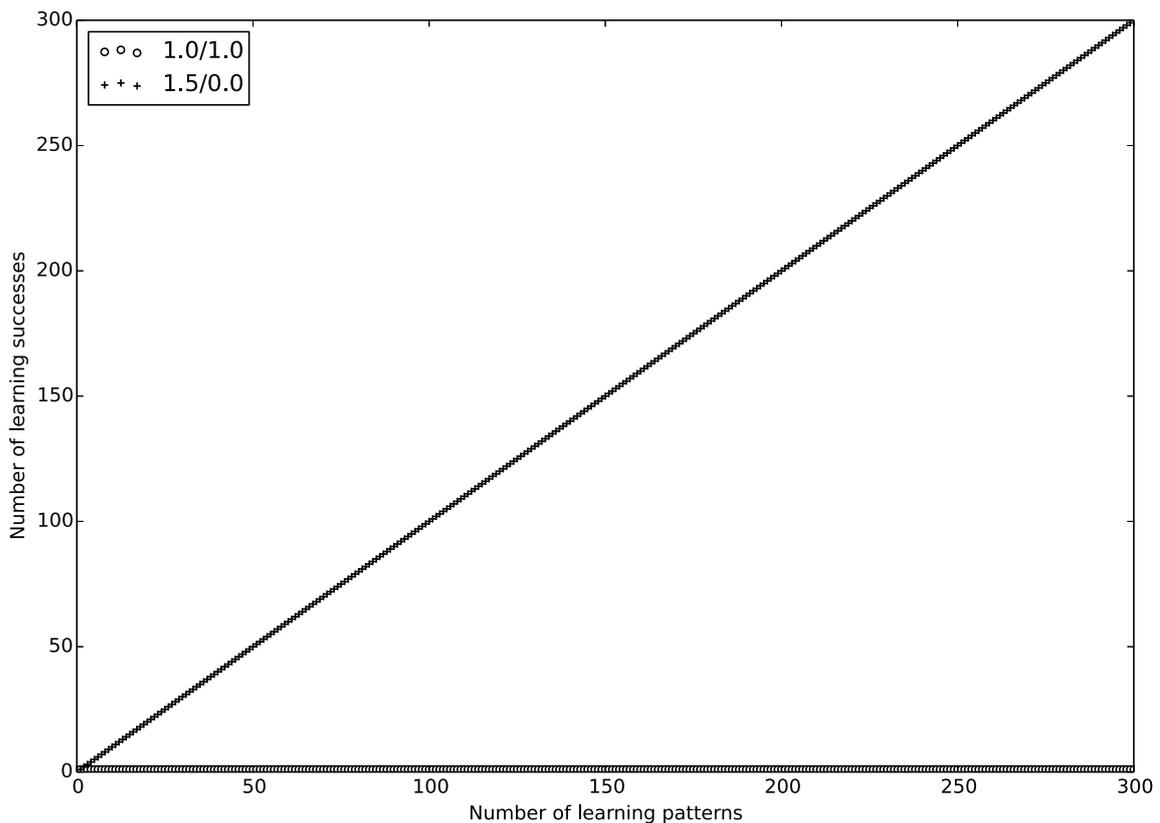


Figure 7.2 Number of learning successes (Pattern ratio 1:1)

x軸が入力された学習パターン数、y軸が学習成功パターン数を表す。

ih1.0、ch1.0の時を除き、学習パターン数と学習成功パターン数が同値となる完全学習となっている。今までの研究の中で、学習パターンの素子数に対して1.5倍程度の学習パ

ターン数が完全学習可能な数であり、今回の素子数は 100 の場合は実際は 150 パターン前後で完全学習は終わるはずであるが、最終的に 300 パターンすべてを完全学習できている。これは参考文献<sup>13)</sup>における実験結果と同様の結果であり、すなわち約 150 パターンを学習する前に 1:1 の比率の性質の学習が完了したために起きた現象であると考えられる。

また、結合定数パラメータを変動させてもほぼ同様な結果が得られたため、学習パターン素子の比率 1:1 により起こる学習結果への影響は今回のカオスニューラルネットワークモデルにおいても同様に発生する可能性があると考えられる。実験の目的である「入力-海馬、連合野-海馬の結合定数の変化による学習結果」を求める上において、学習パターン素子の比率が 1:1 となることは結果を固定してしまう要素であると考えられる。

## 7.4 実験 2 パターン素子の比率 1:1 以外における結合定数を変化させた学習 1

### 7.4.1 実験方法

実験 1 において、学習パターン素子の比率が 1:1 であるとき、参考文献<sup>3)</sup>と同様に今回のカオスニューラルネットワークモデルにおいても、学習結果が全パターン完全学習か逆に一つも学習できないかのどちらかになってしまうことが考えられた。よって、素子比率を変化させ 1:1 の条件から外した状態で、入力-海馬、連合野-海馬の結合定数パラメータを変化させたときの学習成功数を調べた。この実験では「1」、「-1」の比率を「49:51」または「51:49」で順番ランダムに 100 素子 1 パターンとして計 300 パターンを学習させた。結合定数パラメータは、入力-海馬、連合野-海馬の結合定数の和が 2.0 となることを条件に、以下の表に示すパラメータの組み合わせで実験した。それ以外のパラメータについては、表 7.1 に従う。また、学習結果について、各パラメータごとに学習パターン数=学習成功パターン数が続く最大値である完全学習数 (Maximum complete learning) と、学習終了までの間での最多学習成功数 (Maximum number of learning successes) について調べた。(以下、図中にて Mcl(完全学習数)、Mnls(最多学習成功数) と略)

### 7.4.2 実験結果

「1」と「-1」の比率が「49:51」もしくは「51:49」である学習パターンにおいて、入力-海馬 (Input-Hippocampus、以下「i-h」と略)、連合野-海馬 (Cortex-Hippocampus、以

下”c-h”と略)の結合定数パラメータを変動させたときの、学習パターン数と学習成功パターン数の関係のグラフを図(7.3)、図(7.4)、図(7.5)に示す。x軸が学習パターン数、y軸が学習成功パターン数を表す。

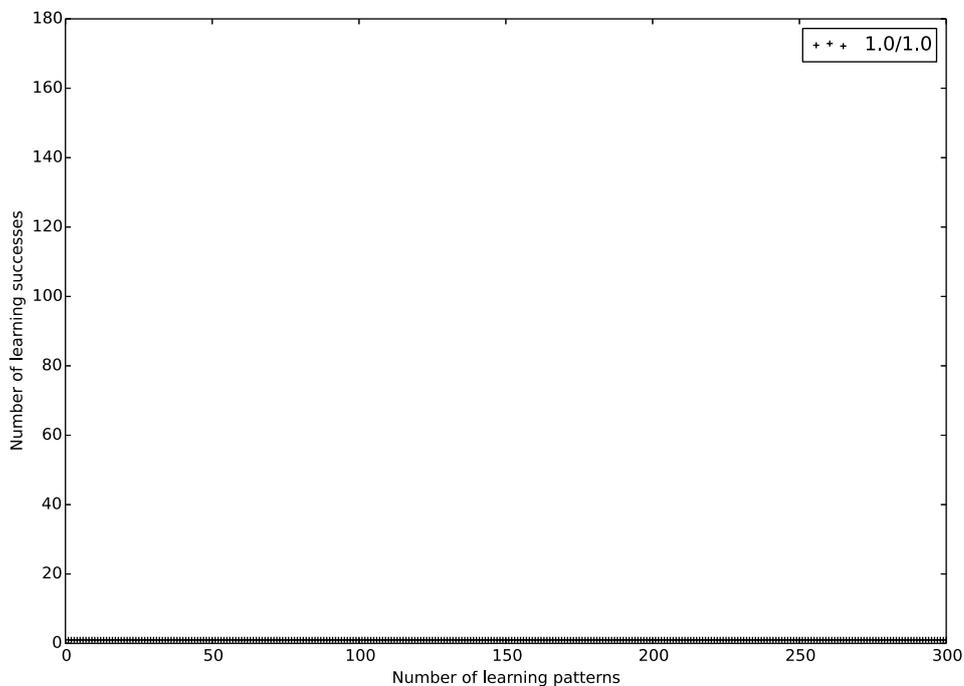


Figure 7.3 Number of learning successes  $i-h=1.0:c-h=1.0$ (Pattern ratio 49:51)

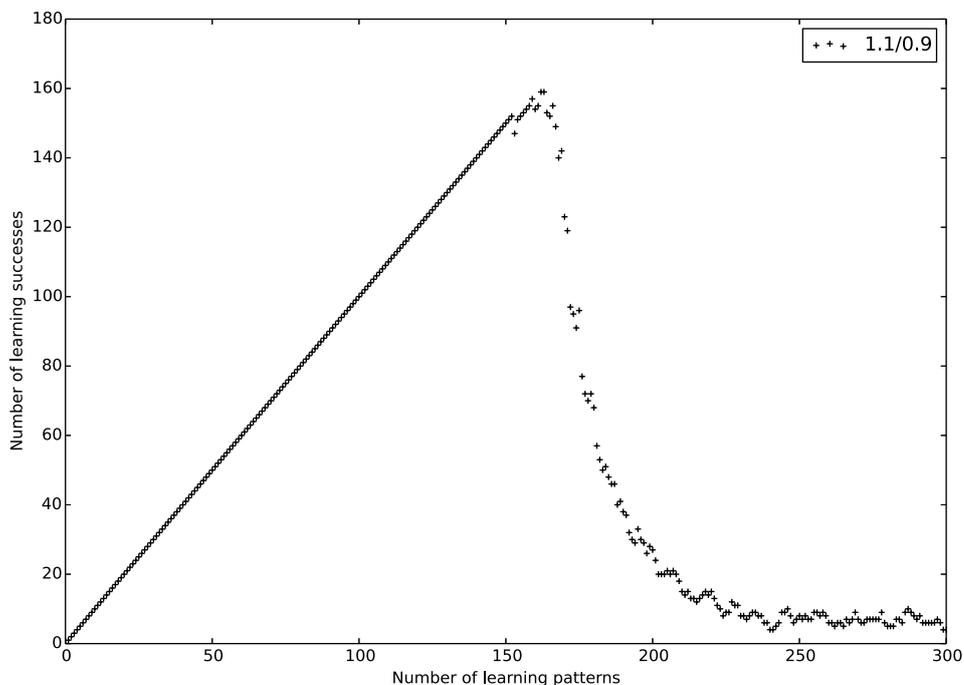


Figure 7.4 Number of learning successes  $i-h=1.1:c-h=0.9$ (Pattern ratio 49:51)

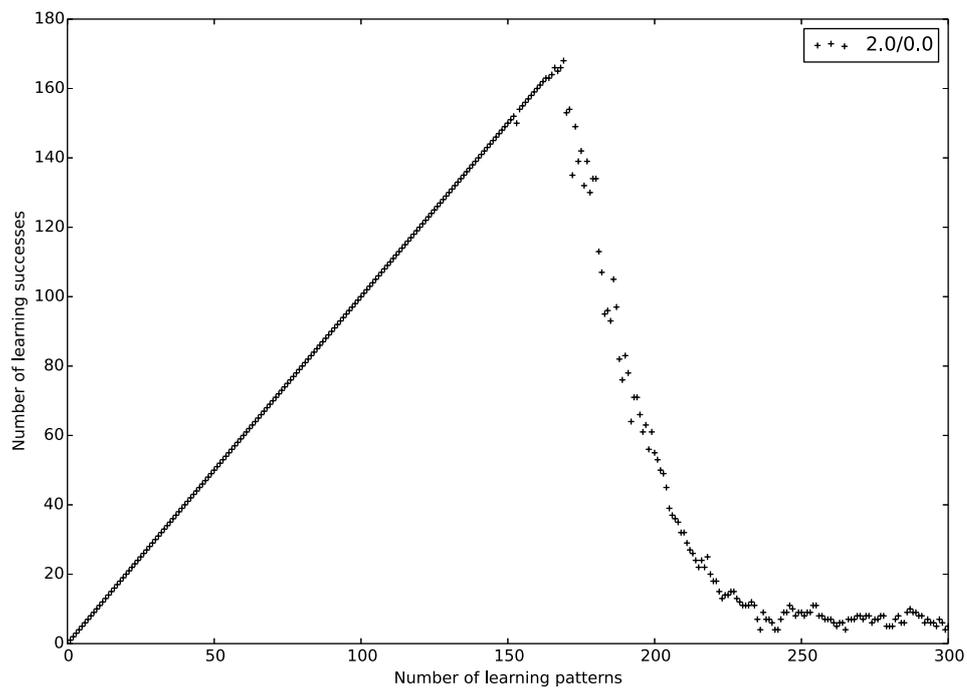


Figure 7.5 Number of learning successes  $i-h=2.0:c-h=0.0$ (Pattern ratio 49:51)

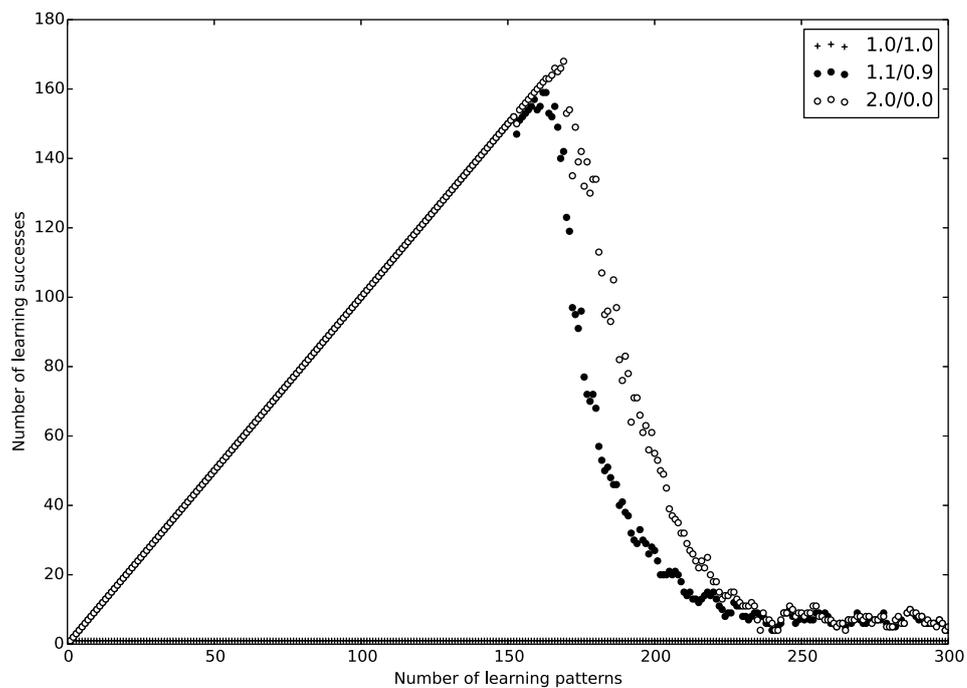


Figure 7.6 Number of learning successes (Pattern ratio 49:51)

i-h=1.0:c-h=1.0の組み合わせでは、学習開始から終了まで想起成功したのは1パターンのみのままであった。(図7.3) ei-h=1.1:c-h=0.9の組み合わせでは、150付近までは完全学習できており、160パターン前付近で学習性能が落ちた。(図7.4) i-h=2.0:c-h=0.0の組み合わせは、全パターンの中で最も学習成功パターン数が多いが、160パターンを超えたあたりから学習性能が落ちた。(図7.5)

これらのグラフを重ねたものを図7.1に示す。これに示した3つの組み合わせ以外のパターンはi-h=1.1とi-h=2.0の間をばらつく程度の違いになった。どの組み合わせにおいても、実験1の時のような200以上のパターンの学習ができたものは無かった。基本的に150パターン前後までの完全学習の後、急激に想起できたパターン数が減少して、10パターン前後で落ち着く。今回変化させた結合定数パラメータの学習結果への影響は、i-hの比率が大きくなるほど学習できているパターンの数が多く、減少が始まるまでのパターン数が多くなり、逆にc-hの比率が大きくなると学習できるパターン数は少なく、より早く減少が始まるようになった。

これらの結果について、各パラメータごとの最大学習数(Mcl)と最多学習成功数(Mnls)を図7.7に示す。x軸はパラメータの組み合わせ、y軸は学習パターン数を表す。「i-h=1.0:c-h=1.0」以外のパラメータについては、横並びで完全学習数に関しては差がなく、最多学習成功数については、わずかだがi-hの比率が大きいものほど高い傾向がみられた。

## 7.5 実験3 パターン素子の比率1:1以外における結合定数を変化させた学習2

### 7.5.1 実験方法

実験2において、各パラメータごとの学習結果を得ることができたが、その結果の中でも「i-h=1.0:c-h=1.0」とそれ以外との結果が非常に大きな差になっていた。そのため追加で「ih=1.0-1.1:ch=1.0-0.9」までの間でさらに細かくパラメータを取り、実験2と同様の条件において以下の表に示すパラメータの組み合わせで実験した。それ以外のパラメータについては、表7.1に従う。また、学習結果についても実験2と同様に完全学習数(Mcl)と最多学習成功数(Mnls)を求めた。

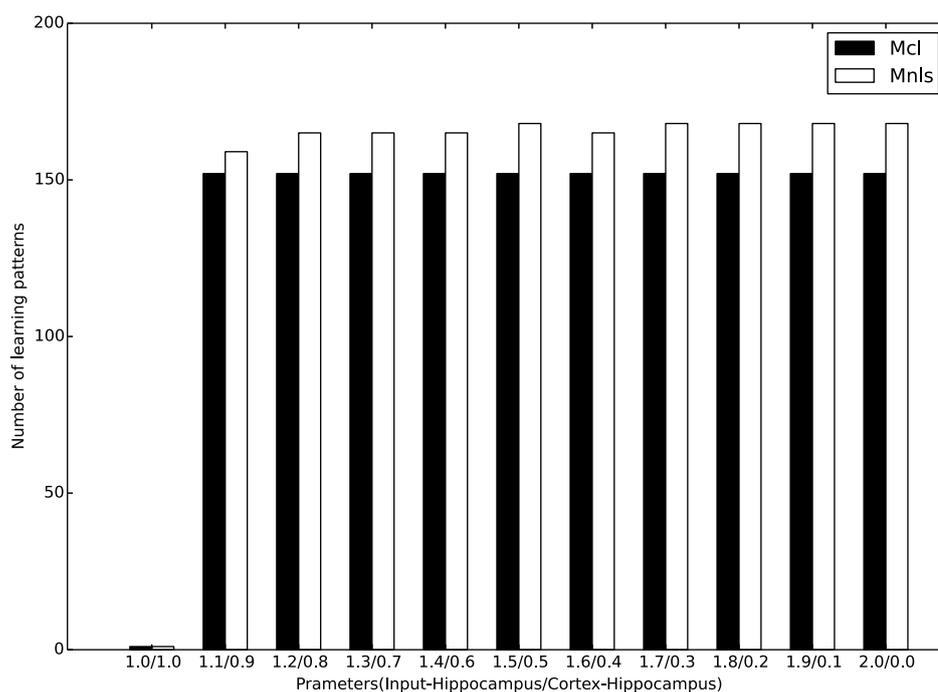


Figure 7.7 Number of learning successes (Pattern ratio 49:51)

## 7.5.2 実験結果

「1」と「-1」の比率が「49:51」もしくは「51:49」である学習パターンにおいて、入力-海馬 (i-h)、連合野-海馬 (c-h) の結合定数パラメータを変動させたときの、学習パターン数と学習成功パターン数の関係のグラフを図 7.8, 図 7.9, 図 7.10 に示す。x 軸が学習パターン数、y 軸が学習成功パターン数を表す。

また、実験 2 と同様にこの結果について各パラメータごとの完全学習数 (Mcl) と最多学習成功数 (Mnl) を図 7.11 に示す。x 軸はパラメータの組み合わせ、y 軸は学習パターン数を表す。ここから、実験 2 に比べてよりパラメータごとの完全学習数の差が大きく、また i-h の比率が大きくなるほど完全学習数が大きくなるという特徴がみられた。また最多学習成功数に関しても同様の特徴がみられ、全体的に実験 2 に比べて差が大きく特徴が顕著に表れた。またそれぞれの変化は i-h の比率が小さい時から大きい時に向かって対数的な上がり方をしていることがわかる。

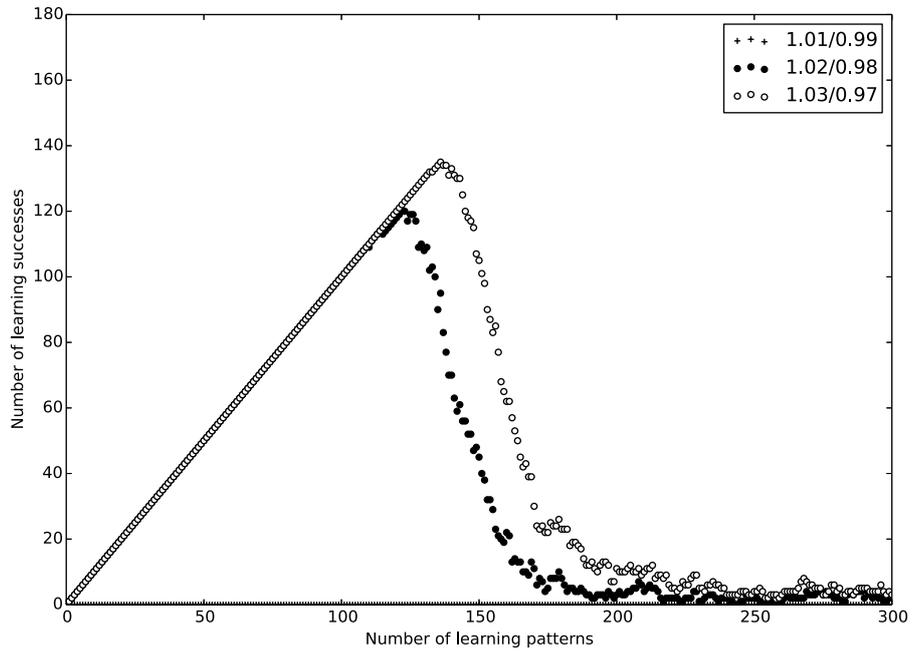


Figure 7.8 Number of additional learning successes 1(Pattern ratio 49:51)

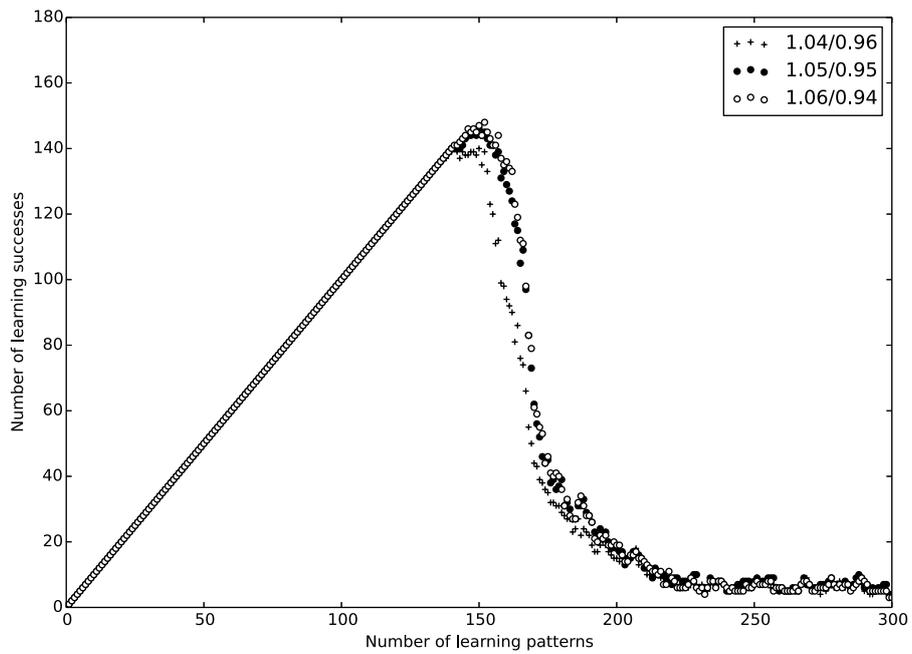


Figure 7.9 Number of additional learning successes 2(Pattern ratio 49:51)

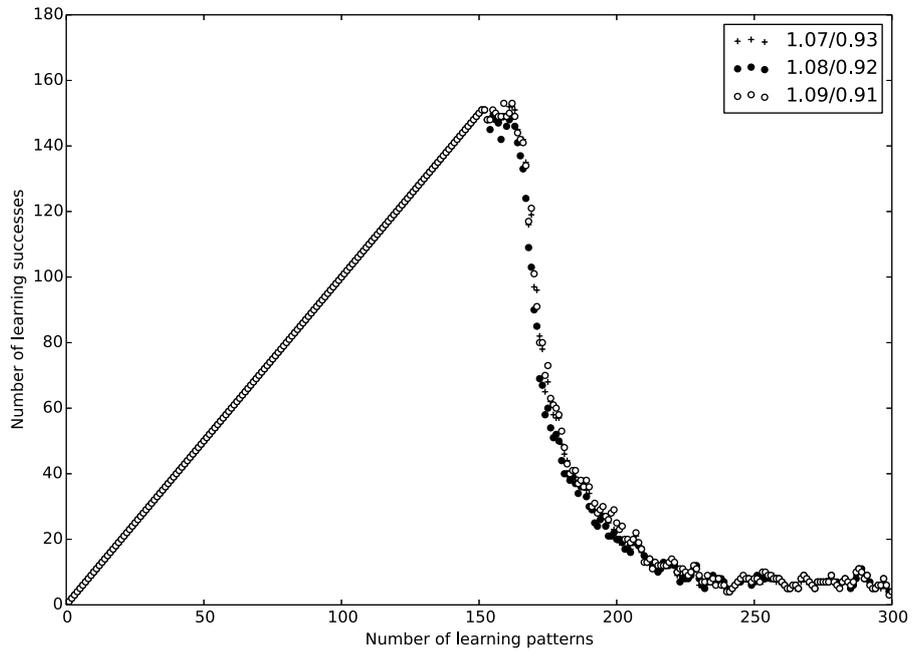


Figure 7.10 Number of additional learning successes 3(Pattern ratio 49:51)

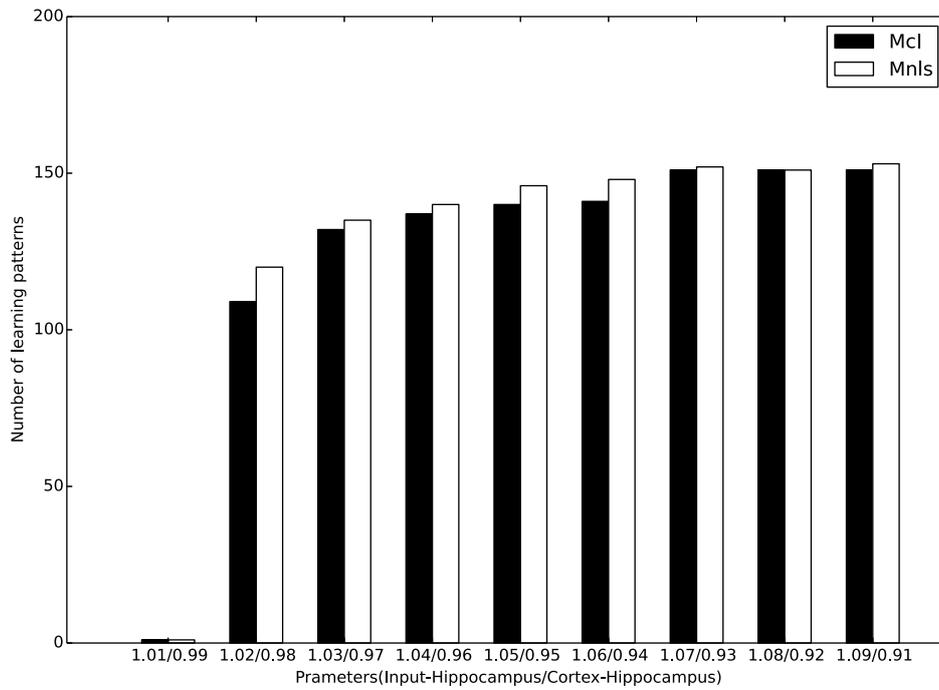


Figure 7.11 Number of additional learning successes 1(Pattern ratio 49:51)

## 第8章 結論

これまでの実験により、過去の研究で用いたカオスニューラルネットワークモデル<sup>3)</sup>において、入力層、海馬モジュール、連合野モジュールのうち、入力-連合野間の結合を無くした場合のニューラルネットワークモデルの学習性能の特性を知ることができた。

過去の研究<sup>13)</sup>に、学習データの素子数とその比率が学習結果に影響してくる性質が述べられたものがあった。「実験1」より、その研究のカオスニューラルネットワークモデルにおいて起こった学習パターンの素子数やその比率が学習結果に影響する、という性質が今回のネットワークモデルにおいても同様の現象が発生することがわかった。この現象については過去の研究論文でも述べられているが、基本的に今までの研究の中で、カオスニューラルネットワークモデルの完全学習数は入力される学習素子の数の約1.5倍程度になるとの結果が出ている。これは「実験2」からもわかる通り、完全学習数は今回の素子数が100の1.5倍、約150パターン前後が最大となっている。しかし、学習パターン素子の比率が1:1となる場合、学習能力が落ちず300パターンの完全学習ができています。これは理論上の完全学習数150に到達する前に1:1の比率の学習が完了していたためであると考えられる。また、今回の結果では過去の研究<sup>13)</sup>とは異なり、素子数100時の学習において、最後まで学習能力が低下することなく300パターンまでの完全学習を終えることができている。今回のようなネットワークモデルの場合、全パターン完全学習における学習性能が向上している可能性が考えられる。

「実験2」は今回の研究の目的である、「入力-海馬(以下、i-hと略)、連合野-海馬(以下、c-hと略)の結合定数を変化させた時の学習性能」についての調査である。「実験1」より、今回使用するカオスニューラルネットワークモデルにおいても学習パターン素子の比率が学習結果に大きな影響を及ぼすと考えられた為、「実験2」では学習パターンの比率を変化させ、「49:51」の比率の条件のもとで、i-hとc-hの和が一定になるようパラメータを変化させ調べた。結果として、「i-h=2.0/c-h=0.0」である時、つまり一方向のみのフィードバックなしである3層型カオスニューラルネットワークモデルであるとき、最大学習数、最多学習成功数共に最大となり、c-hの比率が増えていくに従って最大学習数と最多学習成功数は減少していくことがわかった。またその現象の仕方についても、比例的な変化ではなく対数的な変化であり、「i-h=1.0:c-h=1.0」から「i-h=1.1:c-h=0.9」までの間で特に大きく変化していることがわかった。また、「i-hよりc-hの方が大きい」

パラメータパターンでは全く学習できないこともわかった。

以上のことから、入力層、海馬モジュール、連合野モジュールで構成される本カオスニューラルネットワークモデルにおいて、入力ー連合野間の結合を無くした場合の学習性能は、学習パターンの素子比率が1:1である場合においては学習性能の向上の可能性が見られ、それ以外の比率においては最大でも3層型カオスニューラルネットワークモデルと同等程度、パラメータを変えると学習性能が低下していくことがわかった。

今後の研究では他の比率における学習結果への影響<sup>13)</sup>の再現性、結合定数パラメータ、ニューロンの状態式と学習結果の関係、その他のパラメータの変更による学習性能への影響などについて調べる必要がある。

学習性能評価の指標として今回は、学習パターン数と学習成功パターン数が完全に一致する「完全学習数」と、学習終了までの間での学習成功パターン数の最大値である「最多学習成功数」の二つを使用した。これらを元に性能の評価をしたが、それ以外の評価法による結果の変化も考えられる。

## 第9章 謝辞

最後に、本研究において一年間多大なご指導をしていただいた出口利憲先生に深く感謝いたします。また、同研究室において共に研究を協力してくれた船橋聡太氏、稲垣天斗氏、竹中一生氏に感謝の意を表します。

## 参考文献

- 1) 中野馨: ニューロコンピュータの基礎, コロナ社 (1990)
- 2) 合原一幸: ニューロ・ファジィ・カオス, オーム社 (1993)
- 3) 梅田堯英: カオスニューラルネットワークにおける逐次学習の多層化に関する研究, 岐阜工業高等専門学校電気情報工学科卒業論文 (2016)
- 4) Ian・Stewart: カオス的世界像, 白揚社 (1992)
- 5) 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)
- 6) 家入 悠至: カオスニューラルネットによる逐次学習を用いた動的想起に関する研究, 岐阜工業高等専門学校電気情報工学科卒業論文 (2005)
- 7) 平野廣美: Cでつくるニューラルネットワーク, パーソナルメディア (2003)
- 8) M.A. アービブ: ニューラルネットと脳理論, サイエンス社 (1992)
- 9) 吉富康成: ニューラルネットワーク, 朝倉書店 (2002)
- 10) 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)
- 11) 伊藤真, 三宅章吾, 猪苗代盛, 黒岩丈介, 沢田康次: 海馬-連合野モデルによる時系列パターンの長期記憶形成, 電子情報通信学会技術研究報告, NLP2000-18 / NC2000-12 (2000)
- 12) 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)
- 13) 坂井菜月: 逐次学習における学習パターンの影響に関する研究, 岐阜工業高等専門学校電気情報工学科卒業論文 (2015)
- 14) Brenda Milner, Suzanne Corkin, H. L. Teuber: Further analysis if the hippocampal amnesic syndrome, 14-year follow-up study of h.m. Neuropsychologia, Vol.6, pp-215-234 (1968)