

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よる
逐次学習の基礎的研究

A Fundamental Study on the Incremental Learning
in Multilayered 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

2015E02 浅野 蒼太

令和 2 年 (2 0 2 0 年) 2 月 1 4 日 提出

Abstract

Neural Network is one of the methods for machine learning and a computational model that imitates a brain structure of living things. Chaotic Neural Network used in this study is Neural Network which introduces a concept of refractoriness and spatiotemporal sum. Incremental Learning is one of learning methods related to associative memory using Chaotic Neural Network. In Incremental Learning, terms related to external input, internal connection of neurons, and refractoriness are important.

In this study, we studied variation of connection weights change amount and Refractoriness coefficient in incremental learning. As a result, I found that value of connection of neurons is changed by variation of connection weight change amount of Hippocampus and Cortex, also found that terms except for a term related to external input move differently by changing refractoriness coefficient.

目次

Abstract

第1章 序論	1
第2章 ニューラルネットワーク	2
2.1 ニューロン	2
2.2 ニューロンモデル	2
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
第3章 カオスニューラルネットワーク	8
3.1 カオス	8
3.2 カオスニューロン	8
3.3 カオスニューラルネットワーク	10
3.4 動的想起	11
第4章 カオスニューラルネットワークの多層化	12
第5章 学習	15
5.1 学習法の分類	15
5.2 ヘップ則	15
5.3 連想記憶 (相関学習)	16
5.4 逐次学習	18
第6章 実験	20
6.1 実験目的	20
6.2 実験モデル	20
6.3 実験1: 学習成功パターン時の海馬, 連合野での結合荷重の変化による二項 の挙動	20
6.7 実験2: 海馬層, 連合野層の結合荷重, steps をさらに増やした時の不応性 の挙動	24
6.8 実験3: 不応性係数の変化による三項の挙動	24
第7章 結論	31
7.1 謝辞	32

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、このニューロン同士をシナプス結合することで大規模で複雑なネットワークが構築されている。一つ一つのニューロンが行う活動は単純なものでありながら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。

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。

本研究に用いられるカオスニューラルネットワークは合原らによって提唱された。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認められた。それを受けて1990年に合原らがカオスニューロンモデルを発表し、生体にはごく自然に存在するとされるカオスの要素をニューロンに導入することで、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。カオスニューラルネットワークを構成する項は三つあり、外部入力を表す項、ニューロン結合を表す項、不応性を表す項がある。逐次学習により、重みが更新され、三つの項の値も変わっていく。

本研究の目的は、過去の研究で使用された多層カオスニューラルネットワークの内部の変数に着目し、結合荷重の変化量と不応性係数の変化による内部状態の変化を確認することである。

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、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)。¹⁾

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。

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

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

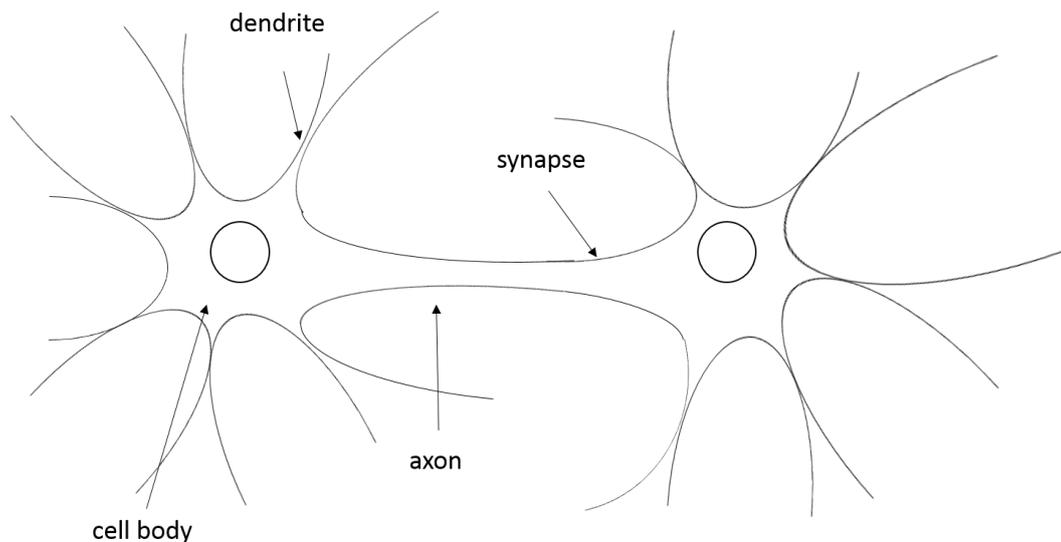


Figure 2.1 Neuron.

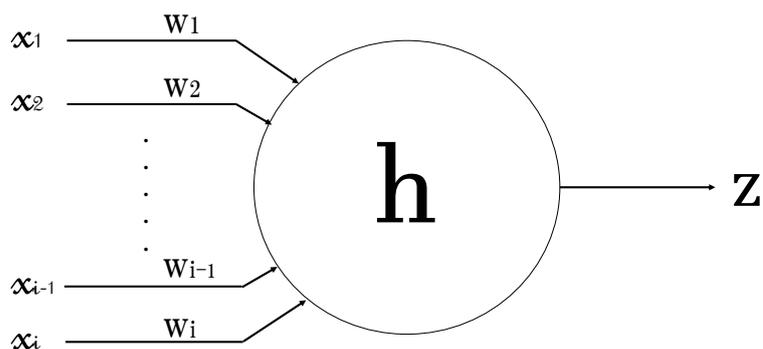


Figure 2.2 Neuron model.

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。 h はニューロンに対する閾値であり、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 (2.3) 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、 $w_i = 0$ 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

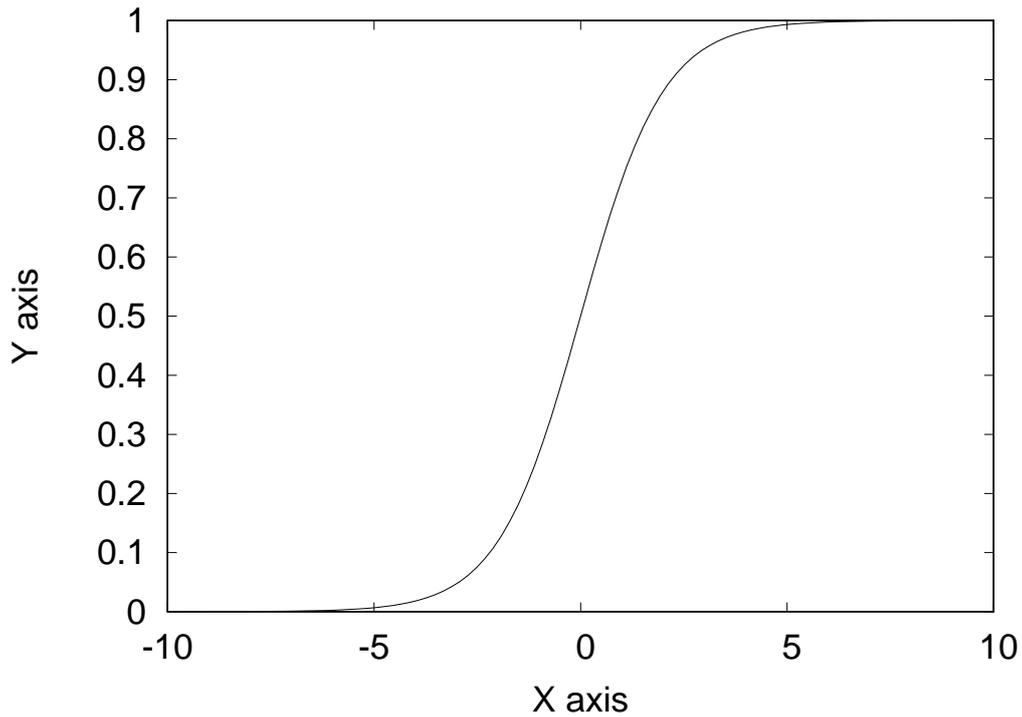


Figure 2.3 Sigmoid function.

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させ出力する。

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。Figure 2.4 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方向にのみ流れる。逆に、Figure 2.5 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。

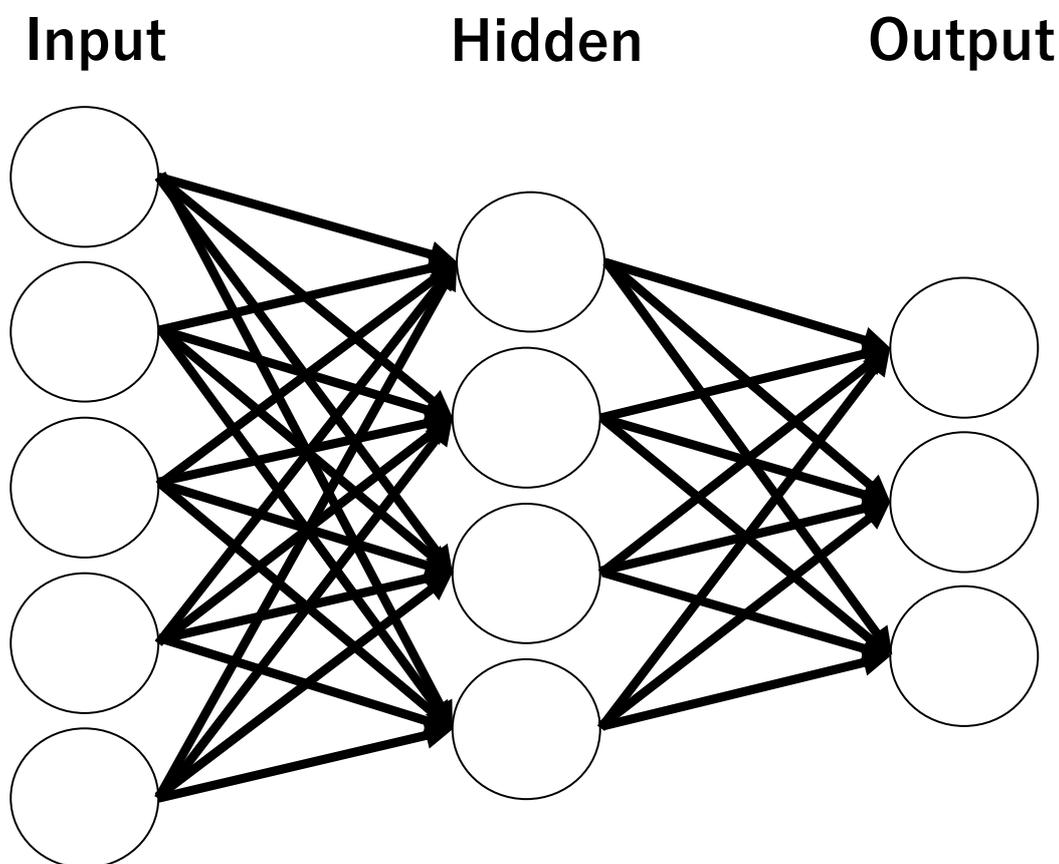


Figure 2.4 Feed forward type.

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 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)で表せられる。

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

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

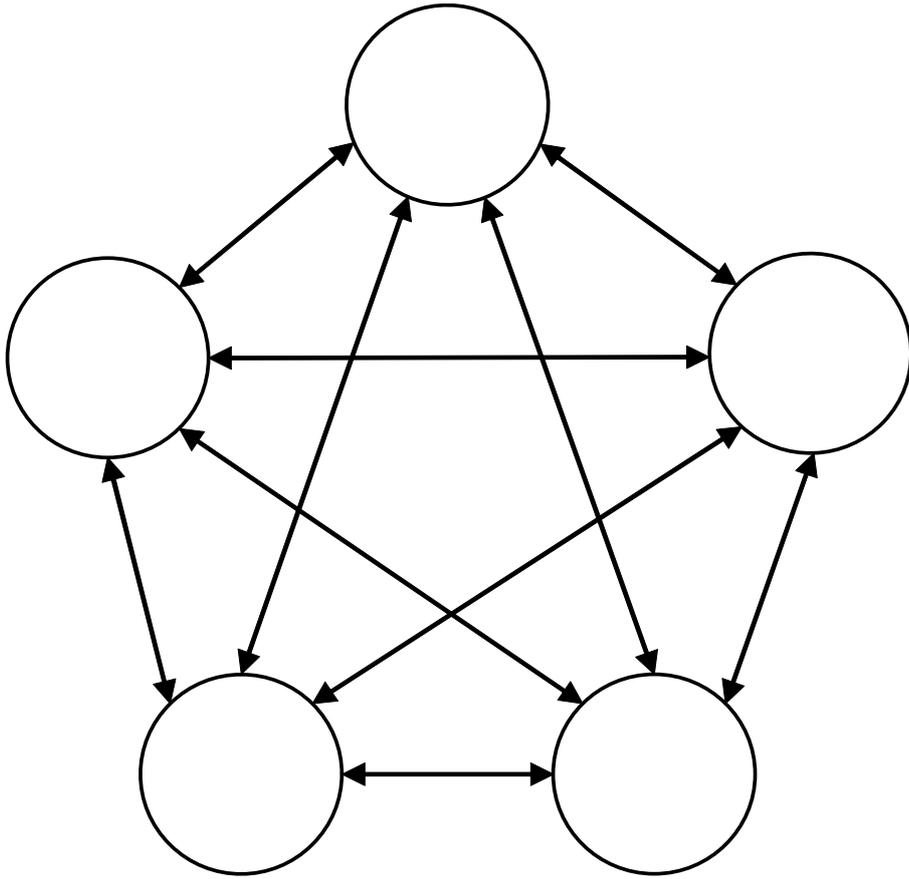


Figure 2.5 Recurrent type.

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

x_i^s : パターン s の i 番目のニューロンの状態

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ように状態変化を収束するまで繰り返す。³⁾ 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。

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

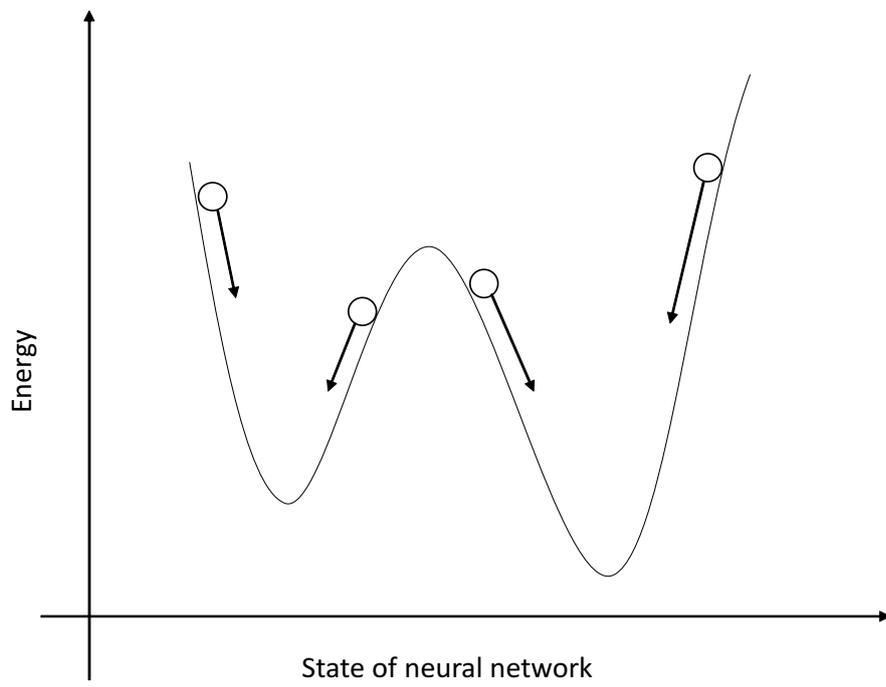


Figure 2.6 Energy of neural network.

第3章 カオスニューラルネットワーク

3.1 カオス

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。⁵⁾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。

カオス現象は、自然物、人工物を問わず非線形システムにごく当たり前に生じるものである。カオス現象の例を挙げると、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。

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 α の値によってきわめて複雑な振る舞いをする。 α の値は4として X_0 を 0.3、 X_0 を 0.3000000001 とした二つの関数を Figure 3.1、Figure 3.2 に示した。初期値が 0.000000001 違うだけだがその後の挙動が大きく変化している。そのため初期値鋭敏性が確認できる。また、非周期的であることも確認できる。

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

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。⁶⁾ 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。

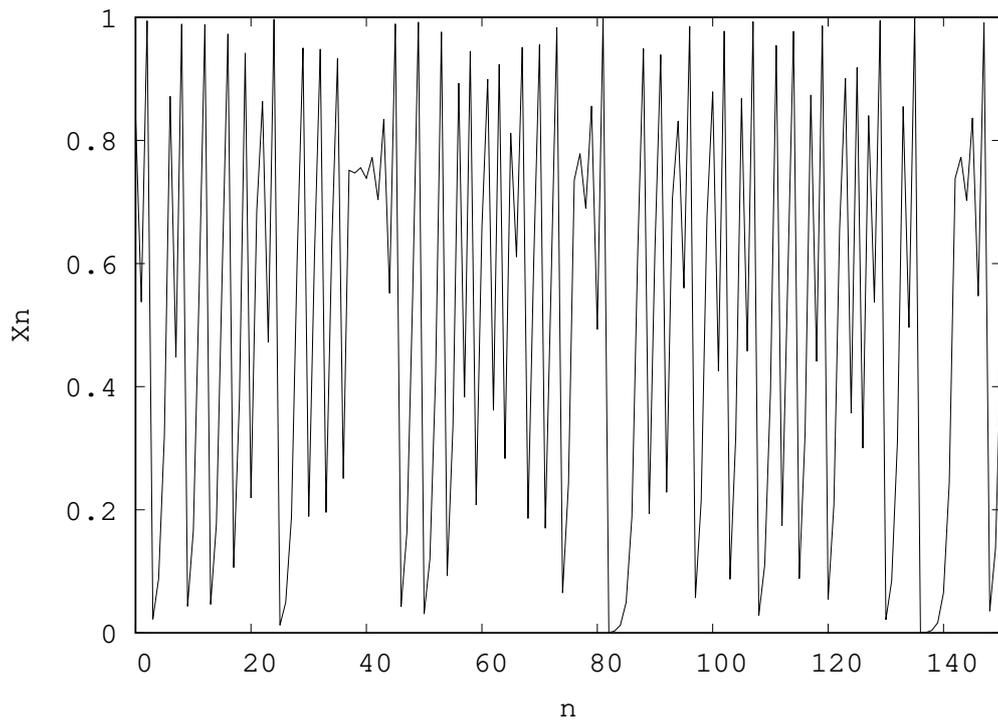


Figure 3.1 Sequences of logistic map with $X_0 = 0.3$

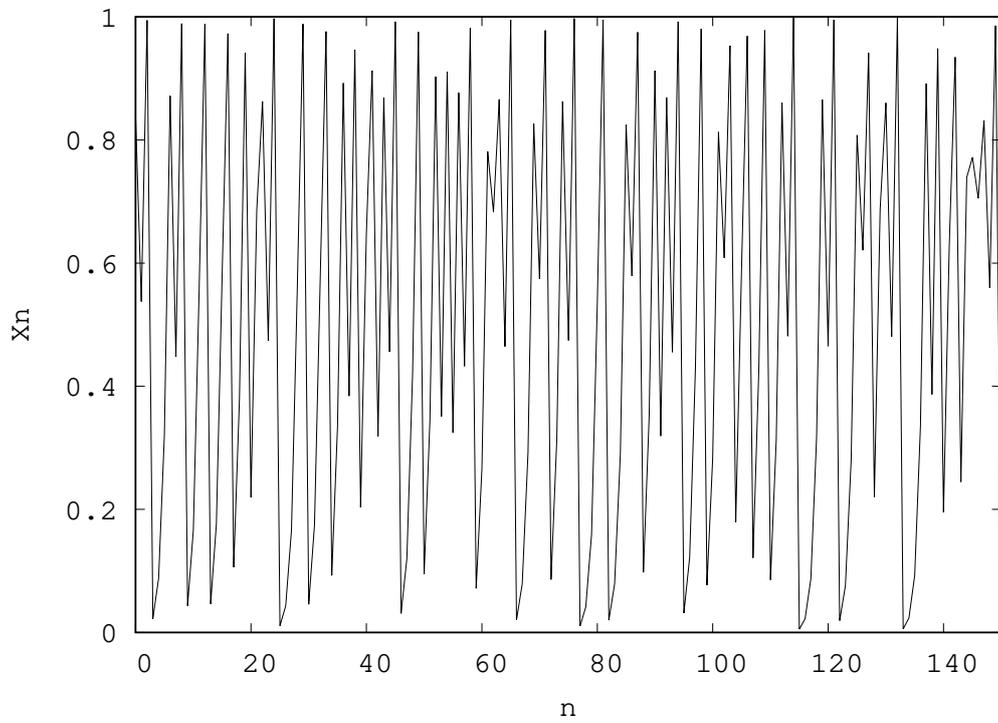


Figure 3.2 Sequences of logistic map with $X_0 = 0.3000000001$

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

$x(t)$: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

α :不応性の時間減数定数

g :不応性によるフィードバックの大きさを求める関数

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、 ϵ 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(3.5)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

$x_i(t)$: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

ω_{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 of 時間減衰定数

k_m :他ニューロンからの入力 of 時間減衰定数

k_r :不応性 of 時間減衰定数

θ_i :i番目のニューロンの閾値

式 (3.7) の関数 f において、外部入力を表す第一項を ξ_i 、ニューロン結合を表す第二項を η_i 、不応性を表す第三項を ζ_i とすると、式 (3.7) は式 (3.8) のように簡略化できる。

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

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

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

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

3.4 動的想起

カオスニューラルネットワークの特徴の一つに、動的想起があげられる。想起とは、ネットワークが記憶したパターンを出力する現象のことを言い、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。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ため動的想起が発生する。カオスニューラルネットワークが動的想起する原因に、カオスニューロンに含まれる不応性が挙げられている。

第4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 Figure 6.1 のようなものがある。このモデルは江本らによって提唱されたモデルであり、入力層、海馬層、連合野層の3層からなるモデルである。このモデルは以下の現象を発現可能としたものである。このモデルのニューロンの状態は次の式で与えられる。⁸⁾

- 逐次記憶
- メタ記憶
- 自由想起性
- 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
- エピソード記憶や意味記憶

$$\begin{aligned} x_i^{ca}(t+1) = & f\left[\sum_{d=0}^t k_s^d A_j^{ca}(t-d)\right. \\ & + \sum_{d=0}^t k_f^d \sum_{j=1}^N \omega_{ij}^{ca} x_j^{ca}(t-d) \\ & \left. - \alpha \sum_{d=0}^t k_r^d x_i^{ca}(t-d) - \theta\right] \end{aligned} \quad (4.1)$$

$$A_i^{ca}(t) = s[x_i^{ip}(t)] \quad (4.2)$$

$$s(u^{ip}) = \begin{cases} 8.75 & \text{if } u > 0.5 \\ 1.25 & \text{else} \end{cases} \quad (4.3)$$

また、このモデルの連合野モジュールのニューロン状態は次の式で与えられる。

$$\begin{aligned}
x_i^{cx}(t+1) &= f\left[\sum_{d=0}^t k_s^d A_j^{cx}(t-d)\right. \\
&\quad \left. + \sum_{d=0}^t k_f^d \sum_{j=1}^N \omega_{ij}^{cx} x_j^{cx}(t-d)\right. \\
&\quad \left. - \alpha \sum_{d=0}^t k_r^d x_i^{cx}(t-d) - \theta\right]
\end{aligned} \tag{4.4}$$

$$A_i^{cx}(t) = s[x_i^{ip}(t), x_i^{cx}] \tag{4.5}$$

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

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。このモデルは式(4.6)、式(4.7)の条件を満たすとき、式(4.8)に基づいて学習を行う。

$$similarity(t-2) \neq N \tag{4.6}$$

$$similarity(t-1) = similarity(t) = N \tag{4.7}$$

$$\Delta\omega_{ij} = \beta(2x_i(t) - 1)(2x_j(t-1) - 1) \tag{4.8}$$

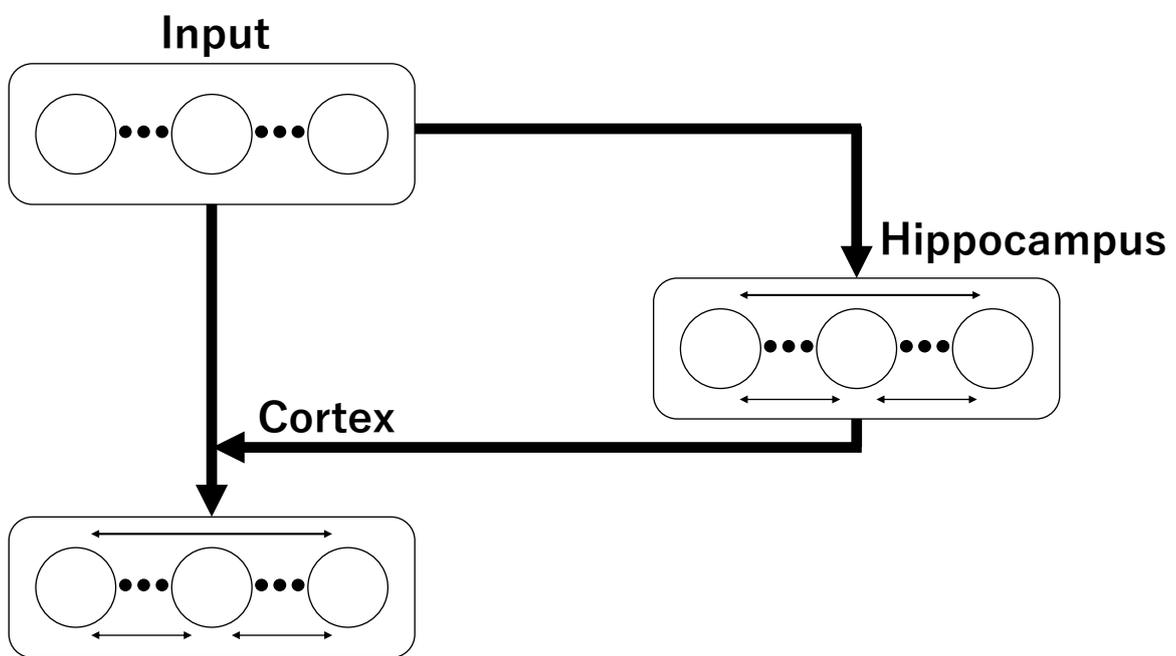


Figure 4.1 Network structure modeled by Emoto et al.⁸⁾

第5章 学習

5.1 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。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。

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。

5.2 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。ニューロンと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する。この仮説を用いて情報処理においてはニューロン同士の結合荷重を変化させることで記憶の定着を再現している。⁴⁾

5.3 連想記憶（相関学習）

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 5.1 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

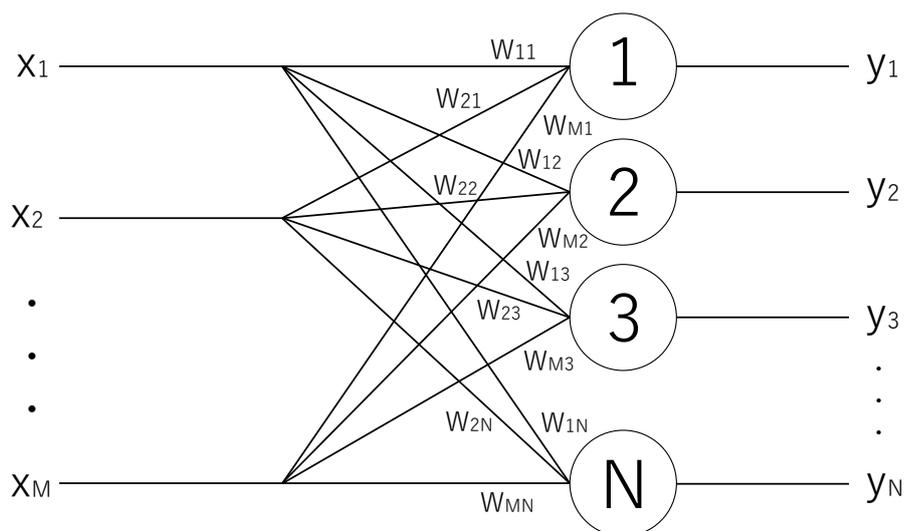


Figure 5.1 Associative memory.

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。人間の脳で例えれば、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。

5.4 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ラ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。⁷⁾ 逐次学習は式 (3.7) 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 (5.1) が満たされた時に学習を行う。

$$\zeta_i \times (\eta_i + \xi_i) < 0 \quad (5.1)$$

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 (5.1) が成立し、結合荷重が変化しなくなっても、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いく。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 (5.1) 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 (5.2) で表される。

$$w_{ij}^{new} = \begin{cases} w_{ij}^{old} + \Delta w & [\xi_i(t) \times x_j(t-1) > 0] \\ w_{ij}^{old} - \Delta w & [\xi_i(t) \times x_j(t-1) \leq 0] \end{cases} \quad (5.2)$$

式 (5.2) 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6章 実験

6.1 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研究を行ってきた。研究が進むにつれ、逐次学習に適したパラメータが少しずつ明らかになってきた。本研究では、1と-1の二値のパターンを用いて学習を行い、入力した学習パターンと想起できたパターンが一致しものを「学習成功パターン」と呼ぶ。学習する際に用いる二値のパターン1:-1の比率が49:51のパターンで学習させると、学習パターンが増えるにつれ、いずれ学習が失敗することが確認されている。カオスニューラルネットワークの二層モデルでは、同じ学習条件で学習を行った場合でも一層目と二層目で学習成功数に違いが出ることを確認されている。

そこで本研究の目的はカオスニューラルネットワークの二層モデルを用いて、逐次学習を行い学習に大きくかかわってくる三つの項の動きを確認することである。学習に関わってくる三つの項とは式(3.7)で述べた外部入力を表す項、ニューロン間の相互結合を表す項、不応性を表す項の三つである。学習成功パターン時の結合荷重の変化量や結合定数の変化による三項の内部状態の変化を確認する

6.2 実験モデル

本研究で用いたカオスニューラルネットワークのモデルを Figure 6.1 に示す。ニューロン間は相互結合型のネットワークであり、入力層に二値のパターンを入力して実験を行う。今回の研究で用いたパラメータは Table 6.1 の通りである。

6.3 実験1: 学習成功パターン時の海馬, 連合野での結合荷重の変化による二項の挙動

カオスニューラルネットワークの多層モデルでの逐次学習を行った。今回の実験で学習させたパターンは1と-1の比率が49:51で構成される100個のパターンである。このパターンを入力とし、逐次学習法を用いてネットワークに学習させた。具体的な学習内容としては、パターン1を100回入力する。その後、パターン2、パターン3と100回ずつ入力する。この一連の入力の流れを1セットと定め、50セットするまで繰り返し合計で15000回の入力を行う。学習時のパターンのうち0番目の要素に着目し、二項の挙動を

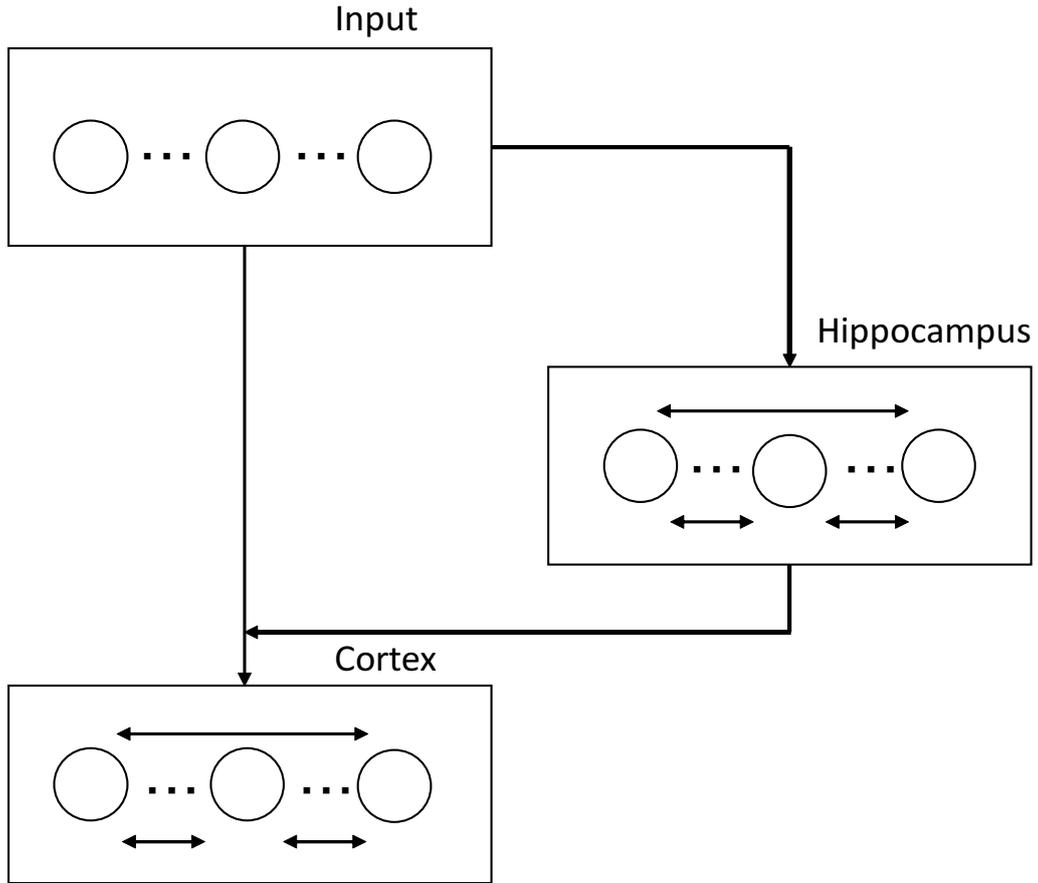


Figure 6.1 Layer model of chaos neural network.

Table 6.1 Parameters

Gradient const. of sigmoid function ϵ	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 α	0.5
Variation of connection weight in Cortex	0.000001
Variation of connection weight in Hippocampus	0.00005
Connection weight of Input-Cortex	0.0006
Connection weight of Hippocampus-Cortex	0.6
Connection weight of Input-Hippocampus	0.6

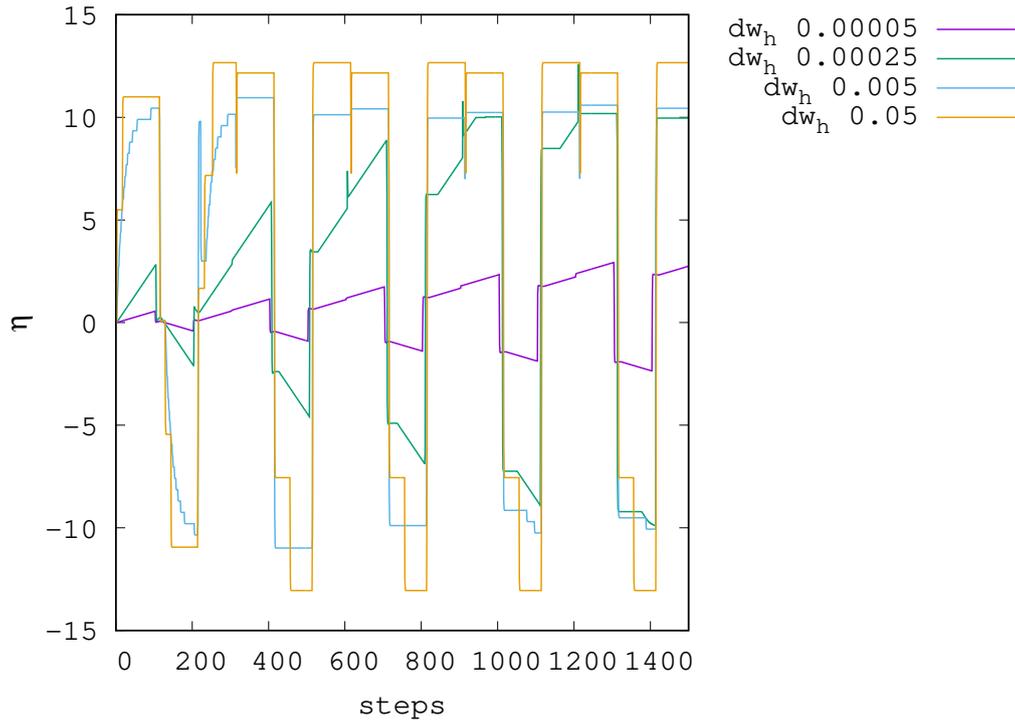


Figure 6.2 η of Hippocampus.

確認した。パターンの0から99番目の要素はどの要素も1か-1である。そのため、どの要素に着目しても同様な結果が得られると仮定し0番目の要素で実験を行った。海馬での結合荷重を変化させたときの1セット目から50セット目までの海馬層の η , ξ の挙動をFigure 6.2、Figure 6.3に示す。同様に連合野層での η , ξ をFigure 6.4、Figure 6.5に示す。まず、海馬層と連合野層の η を比較すると、海馬層、連合野層においてどちらも結合荷重の変化量の初期値とその5倍、10倍、1000倍と増やして実験を行なった。その結果、まずどの結合荷重でもに入力した学習パターンと想起できたパターンが一致した。また海馬層では η の振幅がだんだん大きくなっていくことがわかる。連合野層では海馬層と違い、結合荷重が1000倍になるまで η の値の振幅が大きくならなかった。この理由は式に関係している。 η は式に時刻 t における i 番目のニューロンの出力と 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の積を毎回加算していく(式(3.6)参照)。それが次のパターンの入力があるまで同じ値が入力され続けるため、振幅が大きくなっていることがわかる。連合野層に関してはそもそもの結合荷重の変化量 Δw_c の初期値が小さく設定されていたため、値の倍率を上げてでも始めは振幅があまり変化しなかったのだと思われる。 ξ は海馬、連合野共に連続的な波形を表していた。

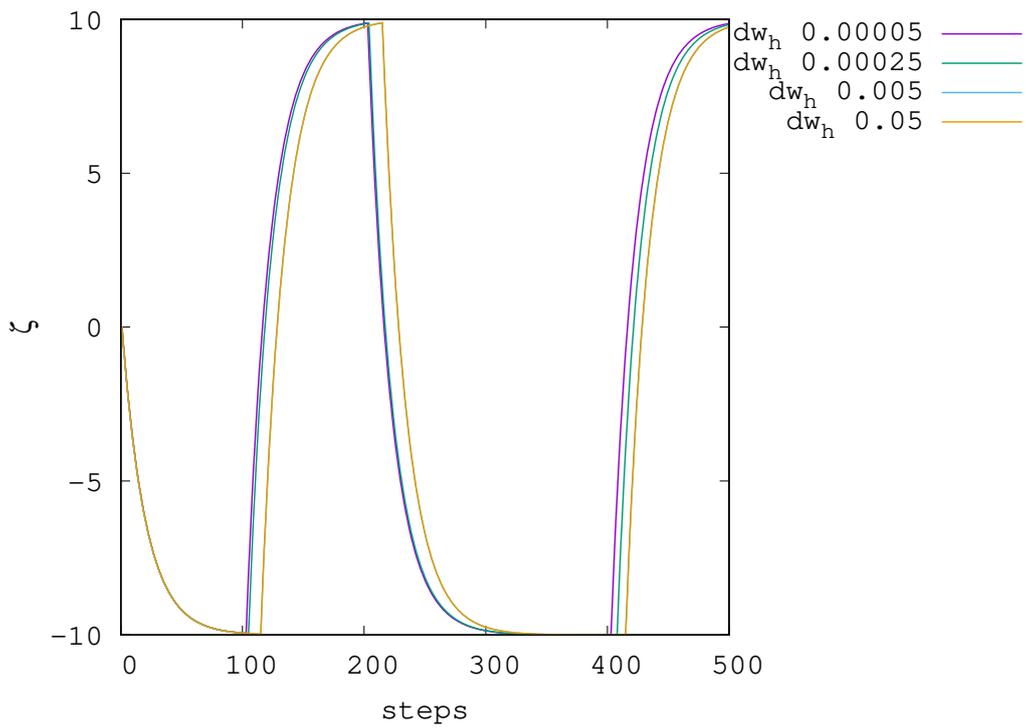


Figure 6.3 ζ of Hippocampus.

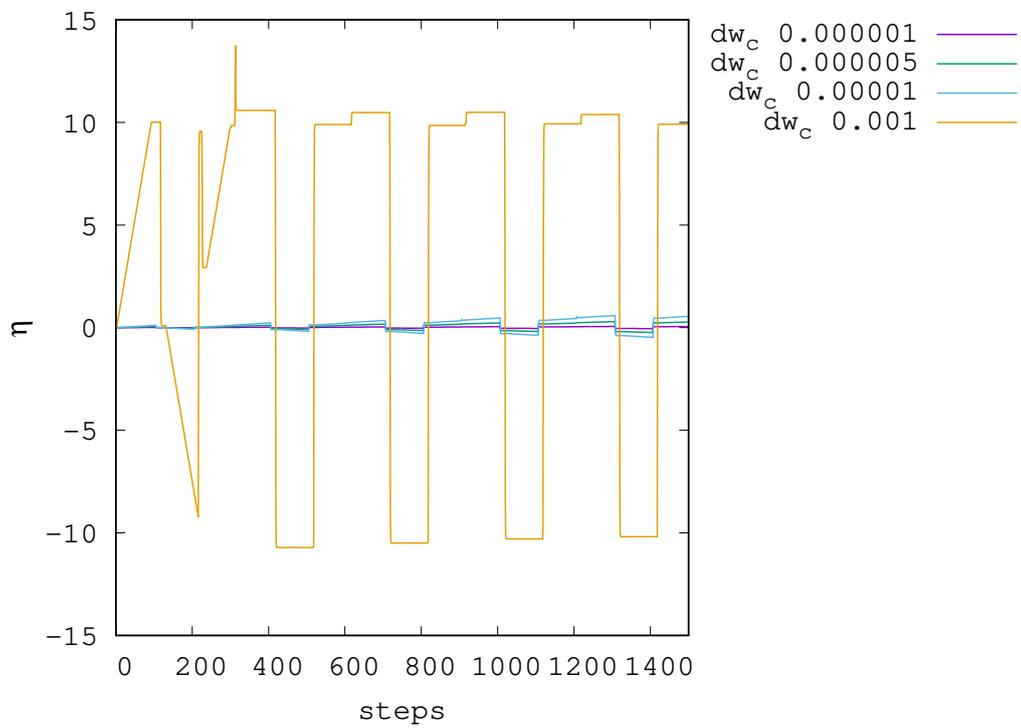


Figure 6.4 η of Cortex.

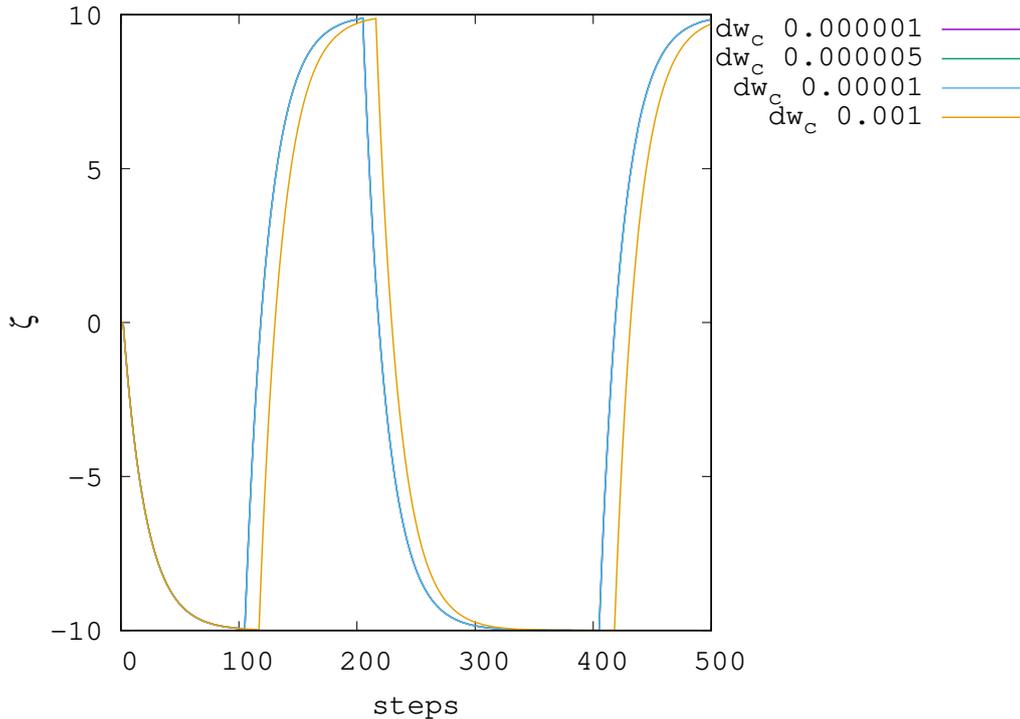


Figure 6.5 ζ of Cortex.

6.7 実験 2: 海馬層、連合野層の結合荷重、steps をさらに増やした時の不応性の挙動

実験 1 では結合荷重の変化量の変化による海馬、連合野層の二項の挙動を確認した。そのとき、各層の不応性の値が結合荷重の変化量の変化に関わらず 500steps まで同じ波形を表すことが確認できた。だがどの時もこのような波形が続くかどうかはわからない。そこで結合荷重をもう少し増やしたり steps を増やしたりして波形を確認することにする。海馬層の ζ の挙動を Figure 6.6 に示し、これまでとは異なる波形の拡大部分の ζ の挙動を Figure 6.7 に示す。また連合野層の ζ の挙動を Figure 6.8 に示し、これまでとは異なる波形の拡大部分の ζ の挙動を Figure 6.9 に示す。海馬層、連合野層においても 1000steps から波形が変化することが分かった。海馬層では結合荷重の変化量 0.9 と 0.93 を比較する。0.9 では 1000steps を超えると右上がりになっていくのに対して、0.93 は右下がりになり、反転する結果となった。連合野層でも同じような状況となった。

6.8 実験 3: 不応性係数の変化による三項の挙動

実験 1 では海馬、連合野層の結合荷重の変化量の変化による二項の挙動を確認した。学習の計算式には不応性係数が影響していることが分かる (式 (3.7) 参照)。不応性係数

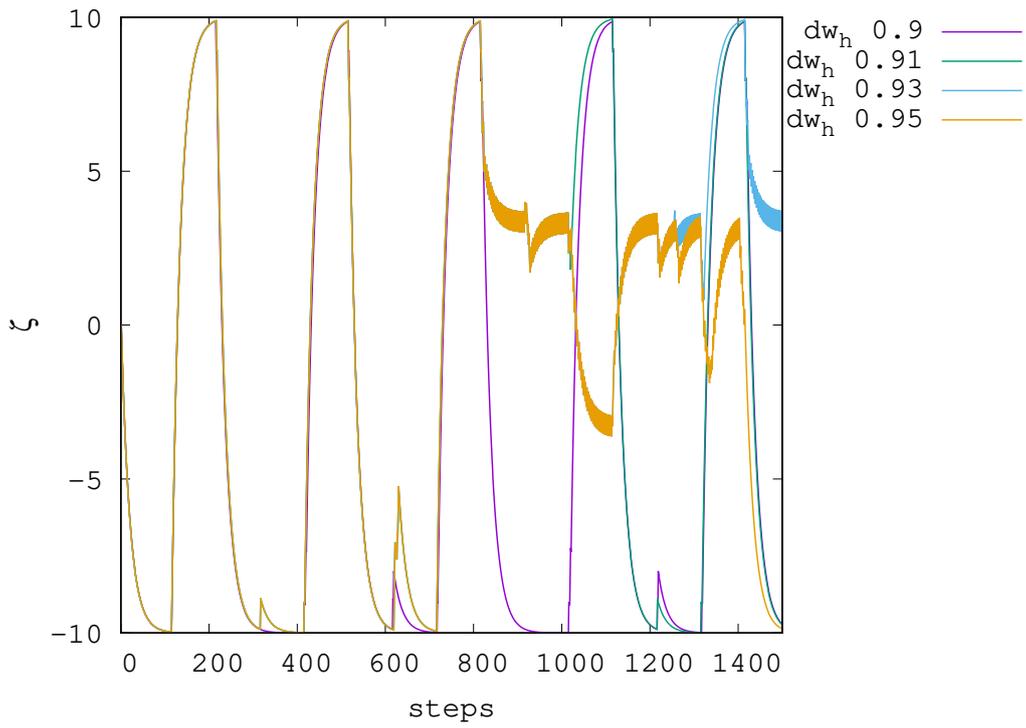


Figure 6.6 ζ of high variation of connection weight change amount in Hippocampus.

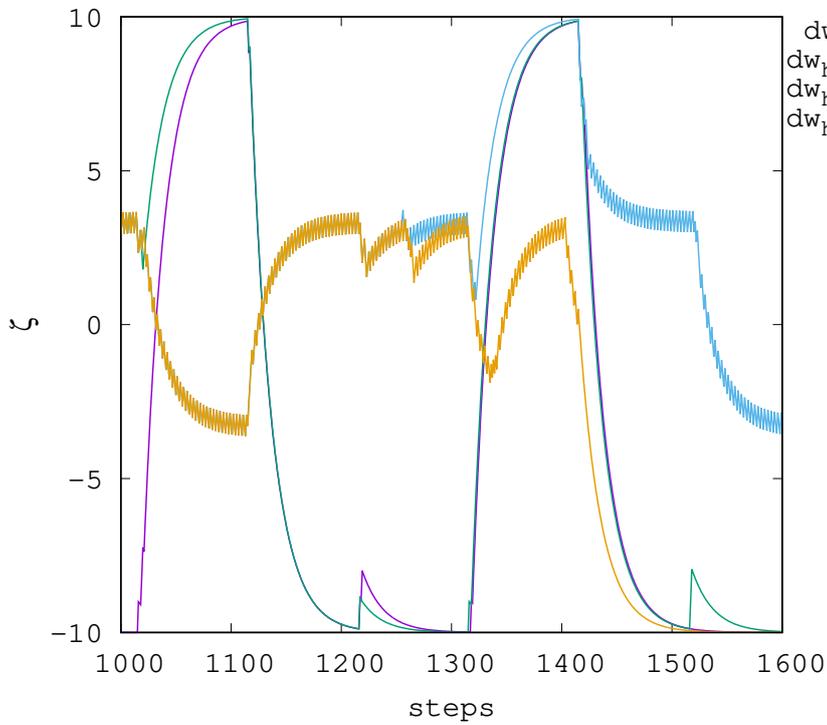


Figure 6.7 Expansion of Figure 6.6

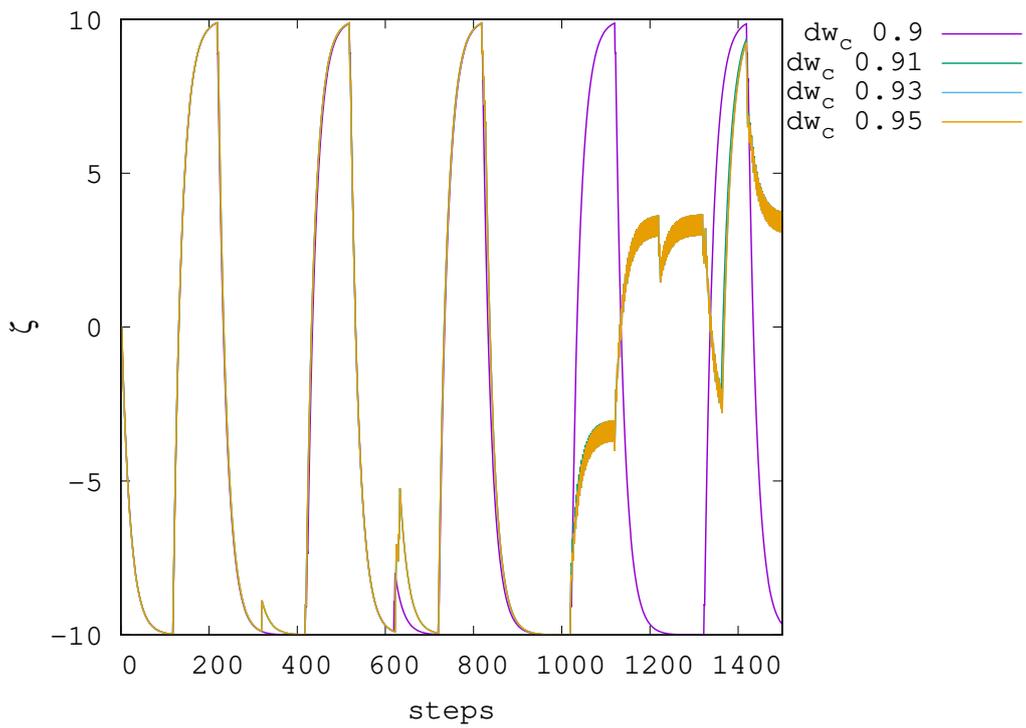


Figure 6.8 ζ of high Variation of connection weight in Cortex.

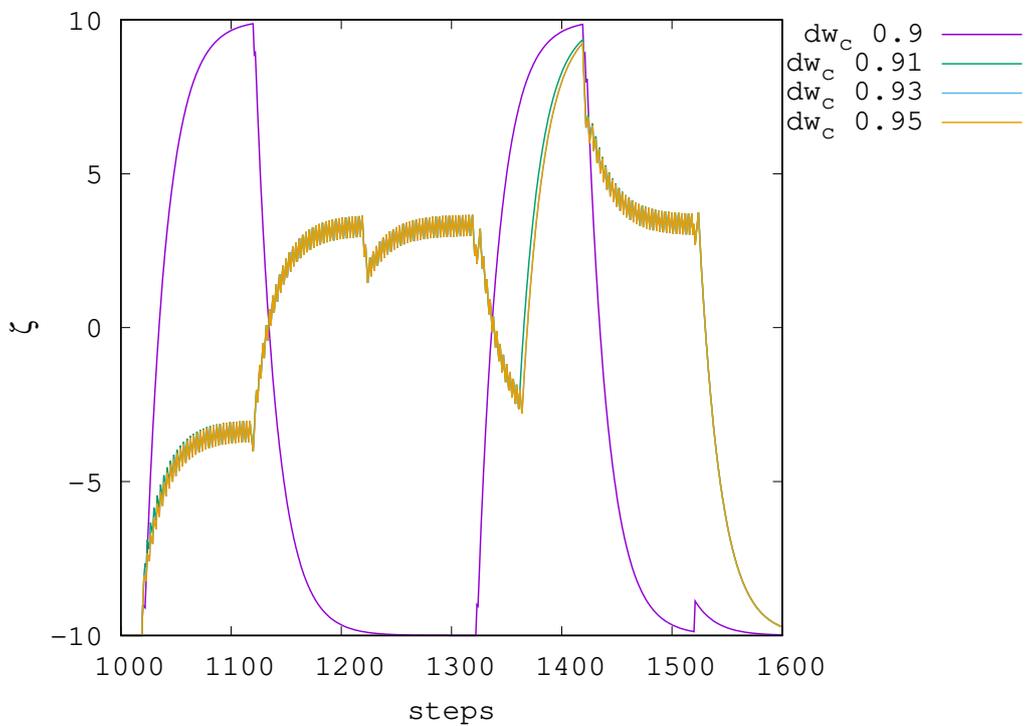


Figure 6.9 Expansion of Figure 6.6

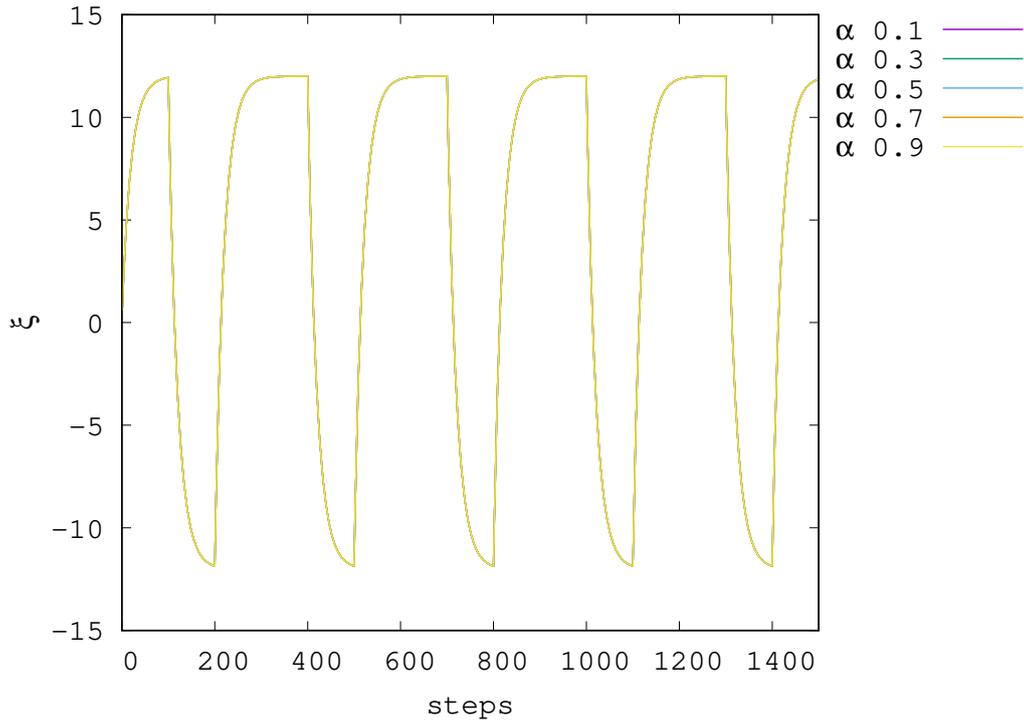


Figure 6.10 ξ by changing refractoriness coefficient change in Hippocampus.

の変化による海馬層の三項の挙動を Figure 6.10、Figure 6.11、Figure 6.12 に連合野層の三項の挙動を Figure 6.13、Figure 6.14、Figure 6.15 に示す。海馬層では、 ξ は不応性係数の大きさに関わらず同じ波形となっていた。 η と ζ は不応性係数を大きくすると振幅が大きくなるが、不連続に変化する波形となった。連合野層では ξ 、 η 、 ζ は全て不応性係数を大きくすると振幅が多くなり、不連続に変化する波形となった。しかし η に関しては海馬層の η と比べて振幅がとて小さくなった。

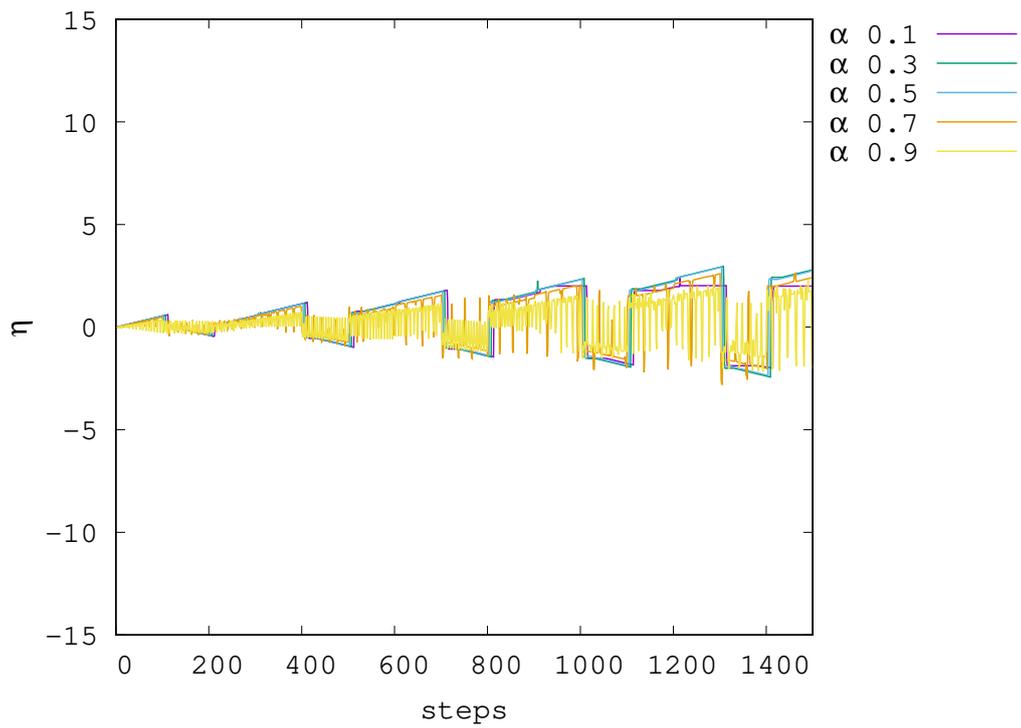


Figure 6.11 η by changing refractoriness coefficient change in Hippocampus.

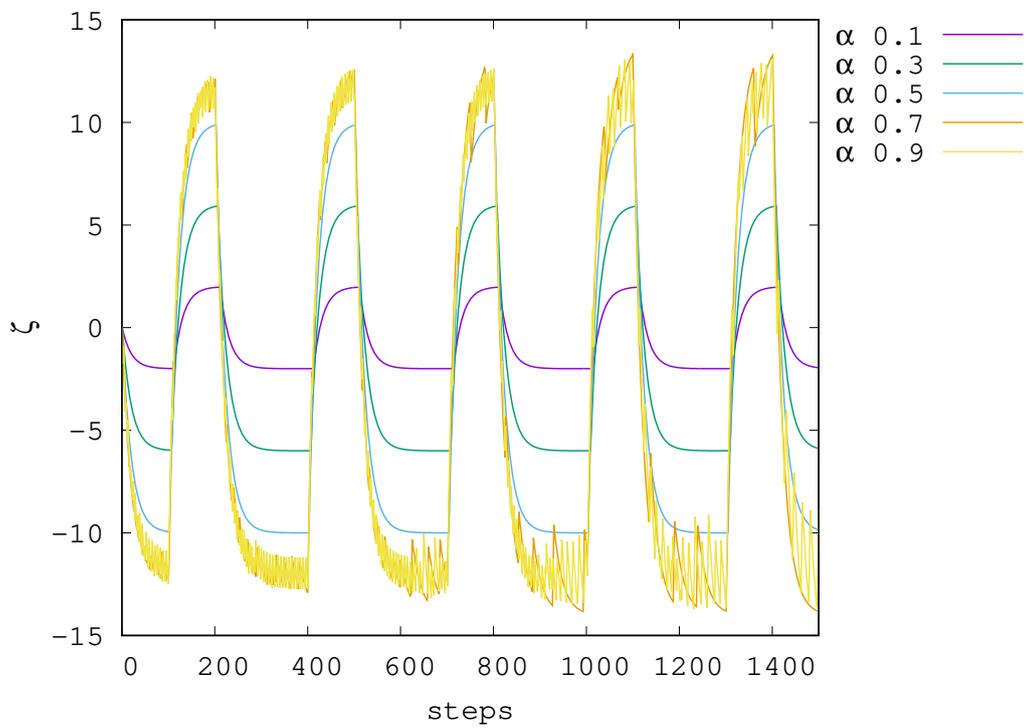


Figure 6.12 ζ by changing refractoriness coefficient change in Hippocampus.

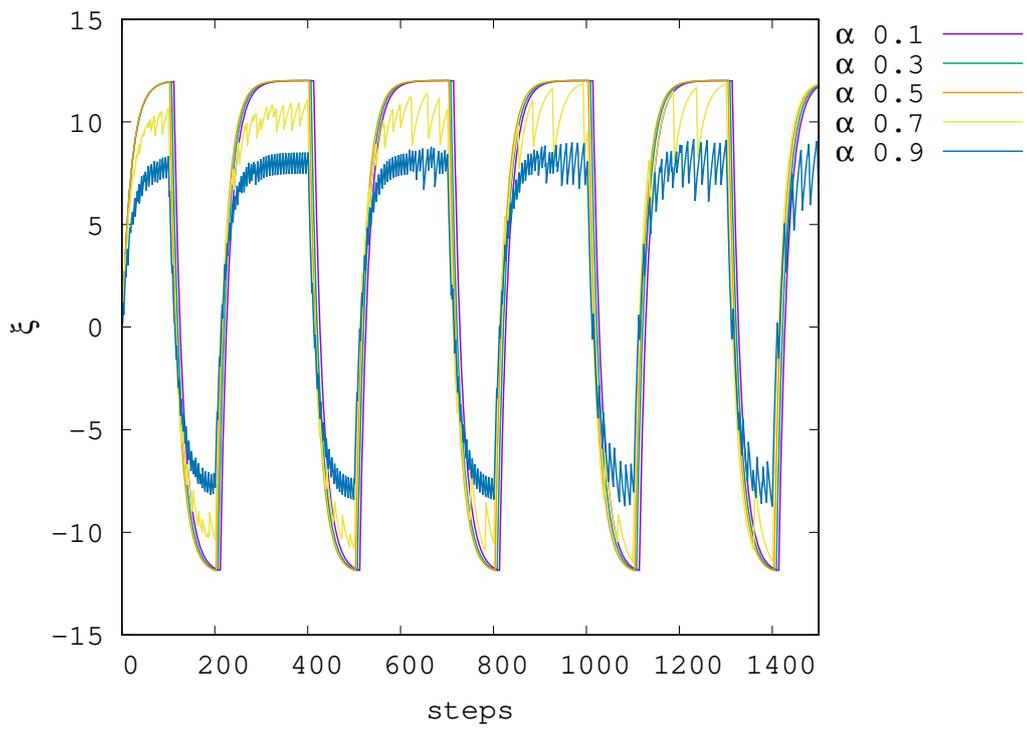


Figure 6.13 ξ by changing refractoriness coefficient change in Cortex.

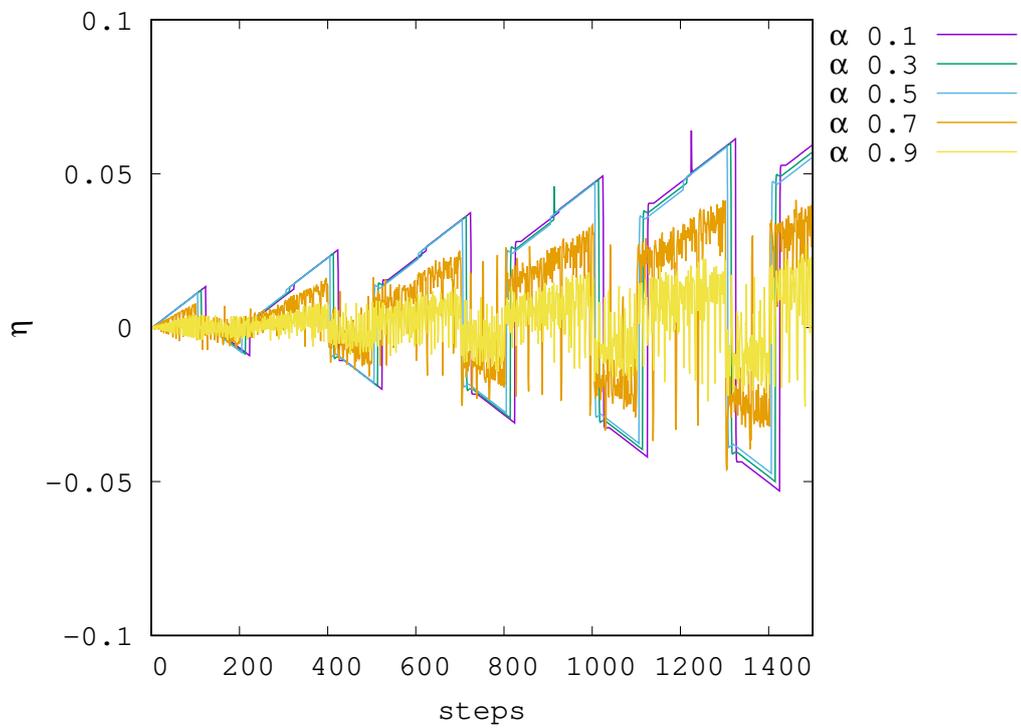


Figure 6.14 η by changing refractoriness coefficient change in Cortex.

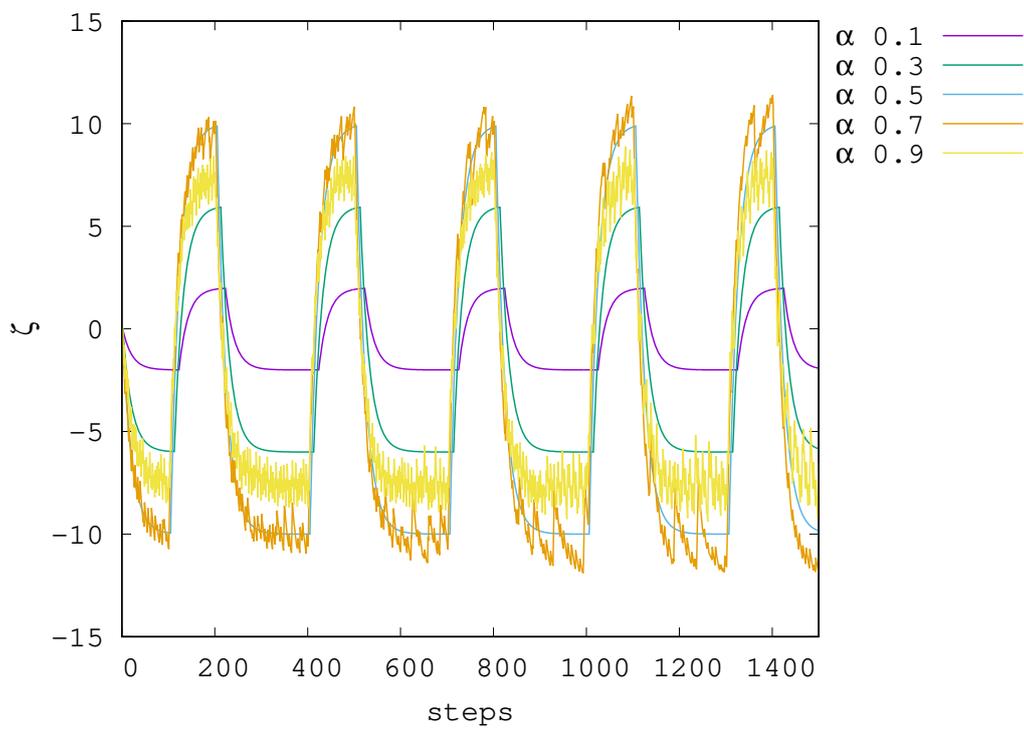


Figure 6.15 ζ by changing refractoriness coefficient change in Cortex.

第7章 結論

本研究では、多層カオスニューラルネットワークにおける逐次学習を行った。逐次学習には外部入力を表す項 (ξ)、ニューロン結合を表す項 (η)、不応性を表す項 (ζ) が重要となっている。その項を生成する結合荷重の変化量と不応性係数の変化による項の挙動を確認した。

実験1より、海馬層の η は結合荷重を増やすことで振幅が大きくなることが確認できた。 ζ は結合荷重の変化に関わらず同じような波形になることが分かった。連合野層の η は結合荷重を1000倍以上にすると振幅が大きくなることが分かり、それ以下の倍数では波形の変化はあまりなく、 ζ は結合荷重の変化に関わらず同じような波形になることが分かった。また、実験2では結合荷重をさらに大きくし、stepsも1500まで上げて挙動を確認してみた。すると、stepsが1000以上で結合荷重の変化量が0.91を超えるあたりで波形が細かく振動した。海馬、連合野層どちらも同じように波形が細かく振動した原因を見つけることはできなかった。実験3では不応性係数の変化による海馬、連合野層の三項の挙動を確認した。海馬層の ζ は不応性係数によらず、同じ波形を表したが、それ以外は不応性係数を大きくすると波形が細かく振動することが発見できた。

7.1 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日下部完氏、三上麟太郎氏に厚く御礼を申し上げます。

参考文献

- 1) 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）
- 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：カオス カオス理論の基礎と応用、サイエンス社（1988）
- 4) 中野馨：ニューロコンピュータの基礎、コロナ社（1990）
- 5) Ian・Stewart: カオス的世界像、白揚社（1992）
- 6) 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）
- 7) 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）
- 8) 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)