

特別研究報告題目

カオスニューラルネットワークによる逐次学習の
2層化に関する基礎的研究

A Fundamental Study on Two-Layer Incremental Learning
Using Chaotic Neural Network

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 専攻科 先端融合開発専攻

2018Y15 久保田 勘太郎

令和 2 年 (2020 年) 2 月 3 日 提出

Abstract

In this study, multi-layered chaotic neural network, for incremental learning, is inspected from the results and the value of the internal neurons in learning time. The network is composed of three layers of input layer, first layer, and second layer.

First, we changed the number of repetitions the network learns a pattern. Varying the parameter of times for which one pattern was input changed the learning results and the values inside the neurons. By learning one pattern many times, it was found that even a network that is difficult to learn can learn the pattern. Further it was found feedback from layer 2 to layer 1 was disrupting of layer 1 the learning.

Next, we changed the connection weights of the networks and the refractoriness of the neurons. The parameter was changed to cause learning when the first layer output and the second layer output are happened at the same time. Inspecting the state of learning at this time show that. Changing the refractoriness makes the network easier to learn new patterns, but the more frequent the learning, the more inside neurons the values will change, making the learning impossible. In this experiment, one of the two layers in the network could not memorize a pattern, but the other memorized all 2 patterns.

It was found that refractoriness had a great effect on network learning. By changing this refractoriness, the change in learning was investigated. The characteristics of refractoriness were discussed from the results. It was found that as the refractoriness increases, the signals handled in learning in the neuron also increase. However, when the refractoriness is further increased beyond a certain level, the signals decreases.

The behavior during incremental learning in a multilayered chaotic neural network was studied.

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	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
第 3 章 カオスニューラルネットワーク	6
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
第 4 章 学習	9
4.1 学習法の分類	9
4.2 ヘップ則	9
4.3 連想記憶	9
4.4 逐次学習	10
第 5 章 実験	11
5.1 実験目的	11
5.2 実験モデル	11
5.3 実験 1 学習手法を変更した場合の学習とその結果	13
5.3.1 実験概要	13
5.3.2 実験結果・考察	13
5.4 実験 2 不応性係数を増加させた学習 1	14
5.4.1 実験概要	14
5.4.2 実験結果・考察	14
5.5 不応性係数を増加させた学習 2	20
5.5.1 実験概要	20
5.5.2 実験結果・考察	20
第 6 章 総括	28

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 [1]。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 [2]。1949 年にはカナダの心理学者 Hebb がヘップ則を提唱し、ニューラルネットワークにおける学習の基礎を築き [2]、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プ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。

今回の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 [3]。

本研究の目的は、過去の研究 [4] 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、その時の振る舞いの違いを調べることである。

今回の研究では、過去の研究から引継ぎ、多層化されたカオスニューラルネットワークで逐次学習を行う。使用したネットワークモデルは入力と第 1・第 2 層の計 3 層から構成されている。これの初期パラメータを変更し、その時の学習結果や振る舞いを調査・考察する。

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。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 (図 2.1)。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)。

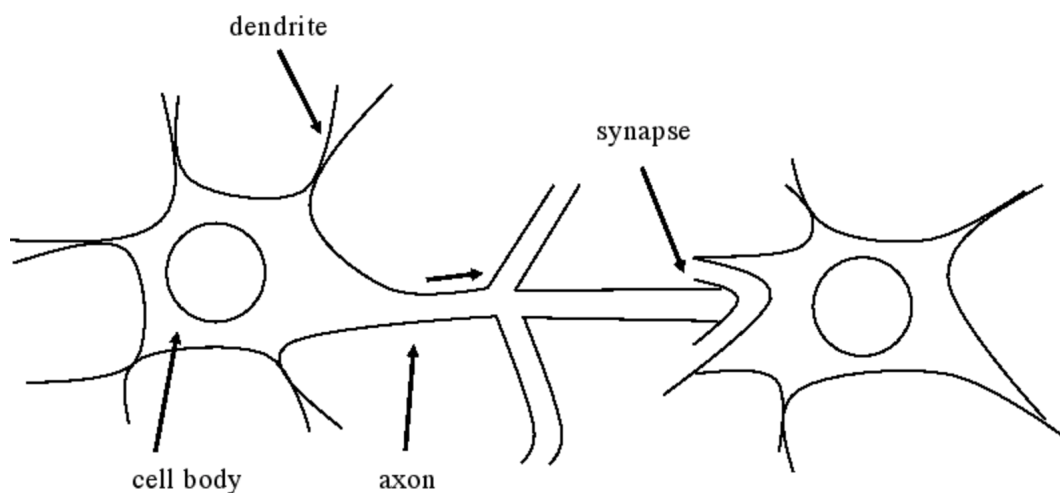


Figure 2.1: Neuron

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ごとである。

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

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、つまり記憶してられる情報数も同様に複数ある。

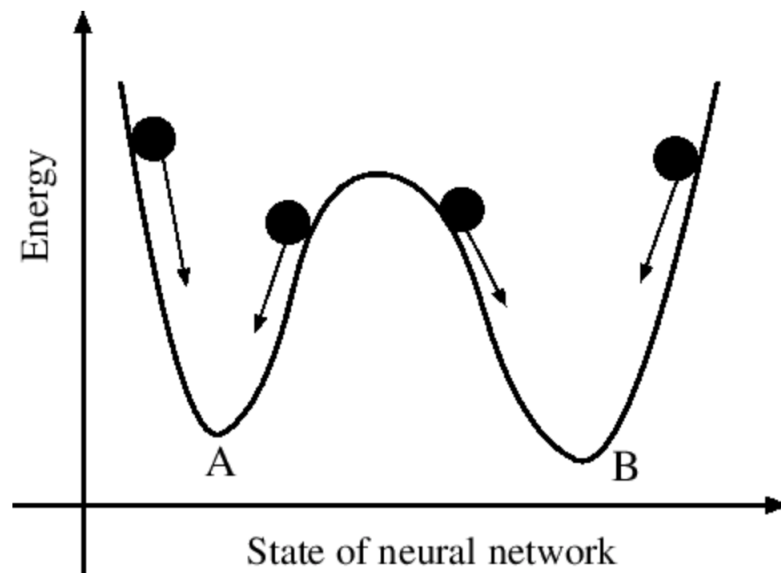


Figure 2.5: Energy function of neural network.

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 [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: $\alpha=3.9, X=0.5$.

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 [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、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

α : 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。

$$f(y) = \frac{2}{1 + \exp(\frac{-y}{\epsilon})} \quad (3.3)$$




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、 i 番目のニューロンの出力 x_i は以下の式で表される。

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

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

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

θ : i 番目のニューロンの閾値

式(3.4)のシグモイド関数 f に代入されるニューロンの内部式は、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、以下のように簡略化できる。

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

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

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(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・クラスタリング等ネットワークの学習に任せ分類するようなもの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 [7]。

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 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 [2]。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)。

4.3 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に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。 [1]

4.4 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。この手法では、まず、ニューロンは1つの絶対的な入力 A と、自身の出力 x を持つ。そしてニューロンはあらかじめ与えられた学習条件をもとに、自身の入力 A に出力 x が等しくなるように学習する。今回使用した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。 [8]

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

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。

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

ω_{ij}^{old} : 変化前の j 番目のニューロンから i 番目のニューロン間の結合荷重

ω_{ij}^{new} 変化後の j 番目のニューロンから i 番目のニューロン間の結合荷重

$\Delta\omega$ 結合荷重の変化量

第5章 実験

5.1 実験目的

本研究では、過去の研究で利用されていたネットワークモデルを引き継ぎ、多層化されたカオスニューラルネットワークモデルでの逐次学習を行い、その学習の振る舞いと原因を調べた。従来の研究では、入力と1層のネットワークという構造であったが、これにもう1層追加し、入力と第1・第2層の計3層からなるネットワーク構造とした。この時、各パラメータを変化させ、学習の結果や振る舞いを調査・考察する。

5.2 実験モデル

今回実験に使用されたニューロンモデルを図(5.1)に示す。ニューロンは逐次学習を行うため、絶対的な外部入力 ξ と、自身の出力 x を持つ。このニューロンはその他のニューロンと相互に結合する全結合型のネットワークを層内で構成するため、ニューロン同士の相互結合を示す η 、カオスニューロンの特徴である不応性を示す ζ を持つ。これらを含めたニューロンの状態式と、各文字の説明を次に示す。

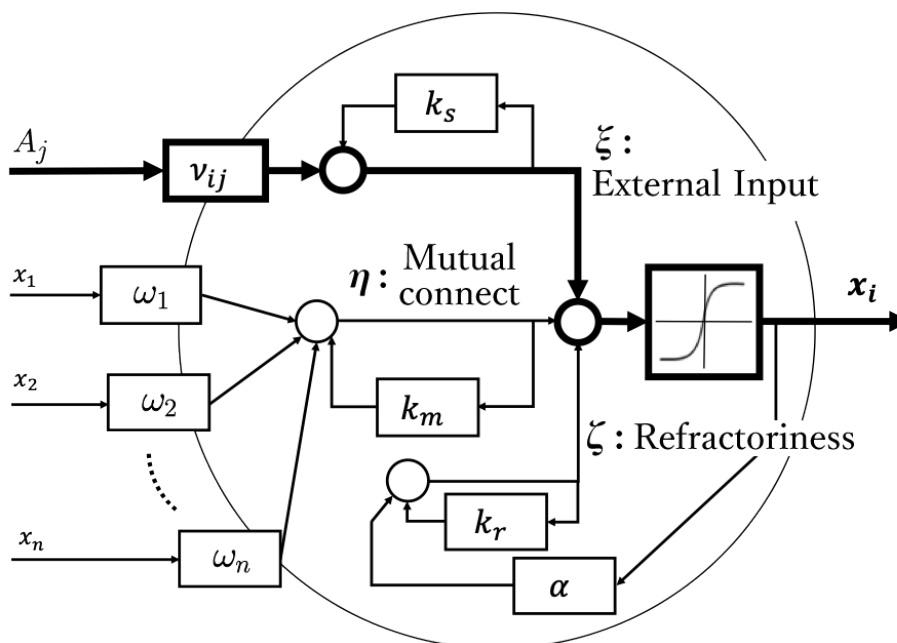


Figure 5.1: Neuron model.

$$x_i(t+1) = f[\xi_i(t+1) + \eta_i(t+1) + \zeta_i(t+1)] \quad (5.1)$$

$$\xi_i(t+1) = \begin{cases} k_s \xi_i(t) + \nu_{10} a_i(t) + \nu_{12} x_i^{(2)}(t) & (\text{第1層}) \\ k_s \xi_i(t) + \nu_{21} x_i^{(1)}(t) & (\text{第2層}) \end{cases} \quad (5.2)$$

$$\eta_i(t+1) = k_m \eta_i(t) + \sum_{i=1}^N \omega_{ij} x_j(t) \quad (5.3)$$

$$\zeta_i(t+1) = k_r \zeta_i(t) - \alpha x_i(t) \quad (5.4)$$

$x_i(t+1)$: 時刻 $t+1$ での i 番目のニューロンの出力

$k_s/k_m/k_r$: 外部入力 / 相互結合 / 不応性の減衰定数

$\xi_i(t+1)$: 時刻 $t+1$ での i 番目のニューロンへの外部入力

ν_{nm} : 第 m 層から第 n 層への信号にかかる係数

$a_i(t)$: 時刻 t における i 番目のニューロンへの外部入力

$x_i^{(k)}(t)$: 第 k 層の i 番目のニューロンの出力

$\eta_i(t+1)$: 時刻 $t+1$ でのその他ニューロンから i 番目のニューロンへの相互結合

N : その層における全てのニューロンの数

ω_{ij} : j 番目のニューロンから i 番目のニューロンへの出力にかかる結合定数

$x_j(t)$: 時刻 t における j 番目のニューロンの出力

$\zeta_i(t+1)$: 時刻 $t+1$ での i 番目のニューロンの不応性

α : 不応性係数

(5.2) 式は, 第1層と第2層とで構成する式が異なる. (5.1) 式の f は式 (5.5) に示すシグモイド関数である. ϵ はシグモイド関数の傾き係数であり, 従来の研究を参考に 0.015 とした.

$$f(y) = 2/(1 + \exp(-y/\epsilon)) \quad (5.5)$$

また, 学習方法については 4.4 節, 式 (4.1) の条件に基づき, 式 (4.2) に従って学習を行なった. 本実験で使うモデルの各種固定パラメータの値を表 5.1 に示す.

Table 5.1: Various parameters.

ϵ	0.015
km	0.1
kr	0.95
ks	0.95
$\Delta\omega$	0.000003
α	0.0006

5.3 実験1 学習手法を変更した場合の学習とその結果

5.3.1 実験概要

本研究で行う学習方法は、まず「1」と「-1」をランダムに100並べたものを1パターンとし、学習させたいパターン群を l_p 回ずつ順番に入力し、これを1セットとして l_s セット繰り返す(図5.2)。これにより学習されたパラメータを、2層の全結合型ネットワークモデルの係数として適用した後、再度パターンを入力することで何パターン学習できたかを評価する。 l_p と l_s の初期値はそれぞれ、 $l_p = 100$ 回、 $l_s = 100$ セットである。

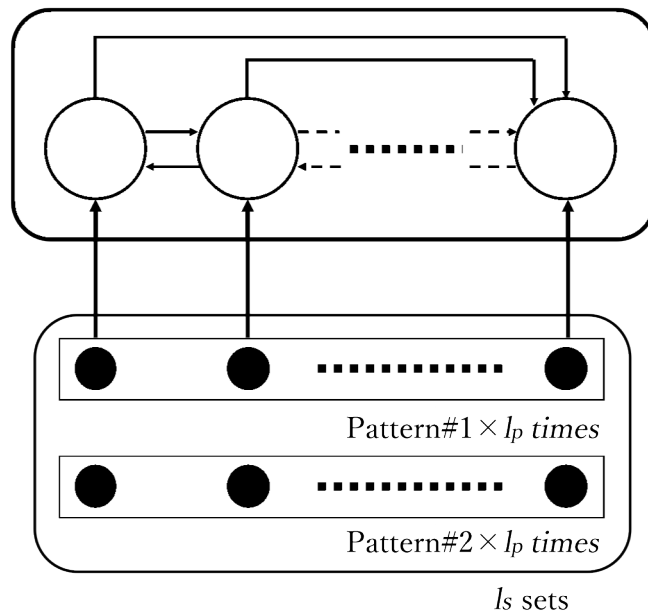


Figure 5.2: Learning Method.

過去の研究では、これらの条件で各層の出力にかかる係数 ν において、従来の研究モデルの設定値から ν_{21} を2とし、 $\nu_{10} + \nu_{12} = 2$ となるようにこれら2つの比率を変更して学習の変化を調査した結果、 $\nu_{10} = 1.01 : \nu_{12} = 0.99$ において学習できたパターンの数が大きく変化したことがわかった。

この実験ではまず、この大きく変化した比率における学習の振る舞いを調査する為に、入力するパターンの総数を2パターンまで絞り、学習中のニューロンの状態式の変化を調査した。また、学習における学習手法に関わるパラメータ l_p と l_s を変更し、その時の学習結果や振る舞いを調査した。

5.3.2 実験結果・考察

l_p, l_s を変更した結果、 l_s は学習最初の数セットで学習がほぼ収束した為、大きな変化を得ることはできなかった。 l_p を変更すると学習できたパターン数が増減するものがあった。学習手法における l_p の初期値では学習できたパターン数は第1層、第2層どちらも1パターンのみとなった。しかし l_p を200回に変更すると学習できるパターン数がどちらの層も2

パターン学習できた。この時、各層内で学習パターンが「-1」「1」の順で入力されるうちの1ニューロン、その第1・第2層の状態式を比較したものを図5.3～図5.8に示す。

外部入力、相互結合、不応性それぞれに違いが見られた。外部入力 ξ は、図5.3、図5.6において、 $l_p = 100$ の時は ξ の値が常に0より下にあるが、 $l_p = 200$ では0を超えて符号が反転し、正の値に振れる。この時点 (Times) 付近において、図5.5、図5.8では ζ の値が変化していることがわかる。そのうち、 $l_p = 100$ のものはすぐに変化が修正されたが、 $l_p = 200$ のものはそのまま変化し、 ξ と同様に符号が切り替わっている。またその点において、ニューロンの学習 (Learning points) が加速していることがわかる。このことから学習のきっかけは外部入力の ξ を除くと不応性 ζ の値が大きく関わっていると考えられる。

層間の関係を見ると、第1層の学習が第2層に影響していることがわかる。図5.9、図5.10は、それぞれの l_p における第1層と第2層の ξ を比較した図である。第1層で学習が行われた点が第2層の変化が始まる箇所と重なることがわかる。層間の結合係数は以前の学習から引き継いでいる為、第2層には第1層の学習結果が流れ、第2層が学習した結果が第1層にほぼフィードバックされている。この構造により第2層の古いパターンの学習結果が第1層に影響し、第1層の新しいパターンの学習を阻害していると考えられる。

5.4 実験2 不応性係数を増加させた学習1

5.4.1 実験概要

実験5.3から、学習結果に層間の結合と、不応性 ζ が大きく関わっていることがわかった。これを踏まえて、層の内部式や結合係数から、『第1層への外部入力と、第2層から第1層へのフィードバックが合わさった時、第1層の学習条件が満たされる』様な結合係数と不応性係数を求めた。使用したパラメータを表5.2に示す。その他のパラメータは変更せずに学習を進めた。

Table 5.2: Various parameters.

v_{10}	0.033
v_{21}	0.2
v_{12}	0.027
α	0.3

5.4.2 実験結果・考察

前述の条件のもと学習させた際、学習が初期の時点で収束しなかった為、 l_s を増やして100セットまでの学習第1層と第2層の学習結果を確認した。学習結果を図5.11に示す。

100セット学習させた時点で、第1層は0パターン、逆に第2層は2パターン全て学習することができている。第1層の状態式と学習状態を示した図を図5.12に示す。

『第1層への外部入力と、第2層から第1層へのフィードバックが合わさった時、第1層の学習条件が満たされる』様にパラメータを変更したが、第1層はほぼ常に学習条件を満




Figure 5.3: Variation of ξ in layer 1 with l_p .

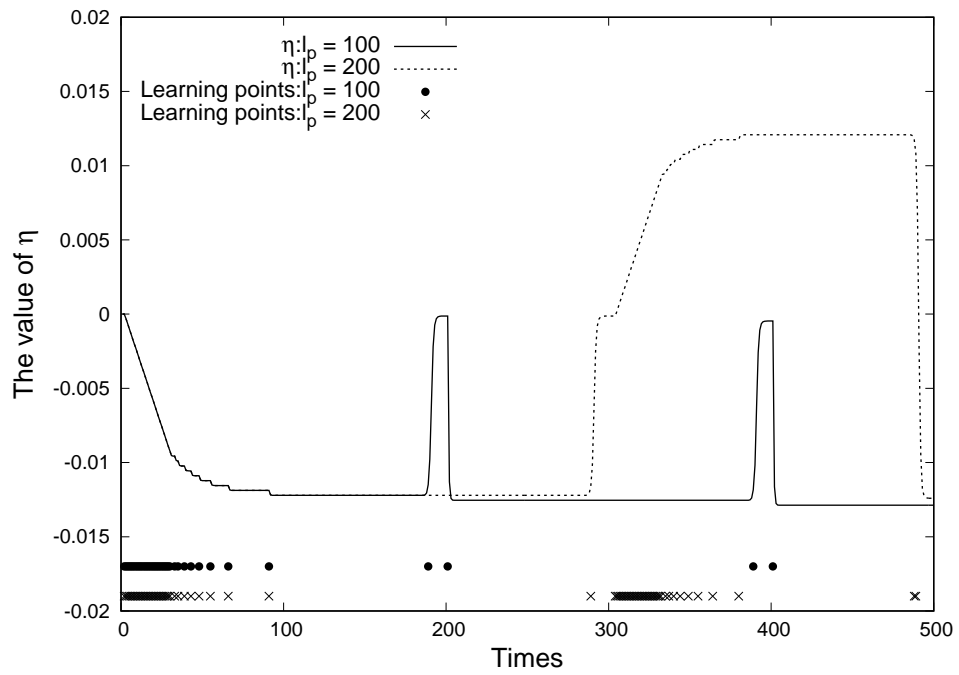


Figure 5.4: Variation of η in layer 1 with l_p .




Figure 5.5: Variation of ζ in layer 1 with l_p .




Figure 5.6: Variation of ξ in layer 2 with l_p .




Figure 5.7: Variation of η in layer 2 with l_p .

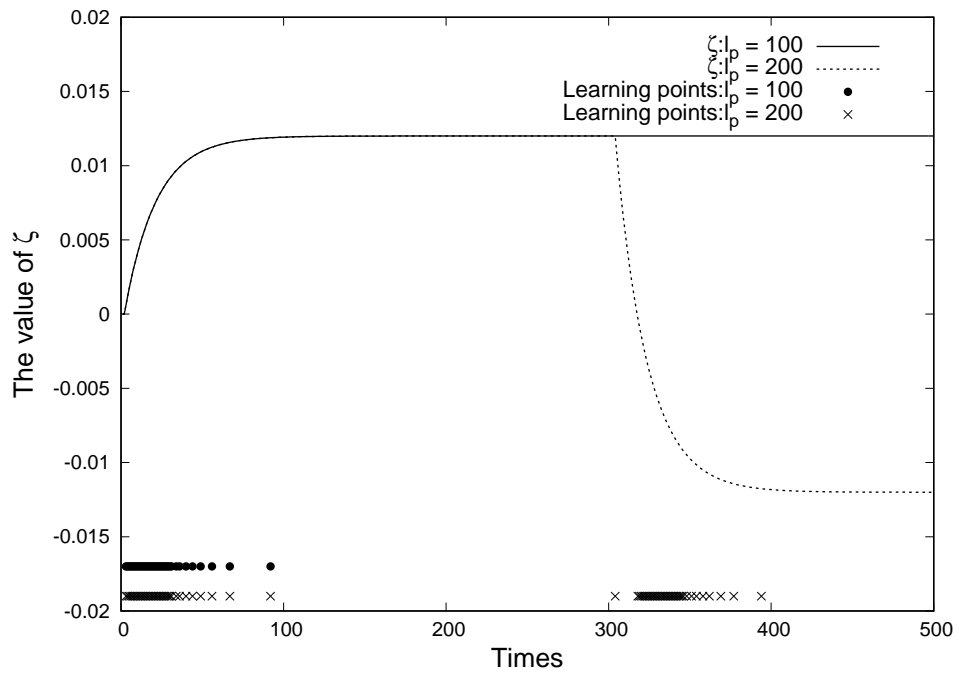


Figure 5.8: Variation of ζ in layer 2 with l_p .

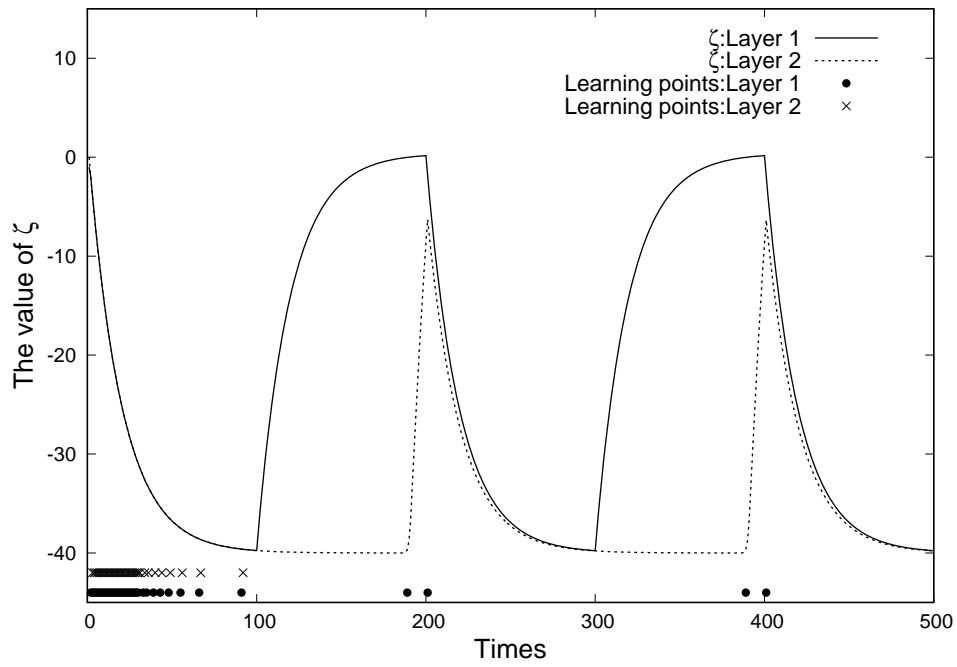


Figure 5.9: Comparison of ξ in layer 1 and 2 ($l_p = 100$).

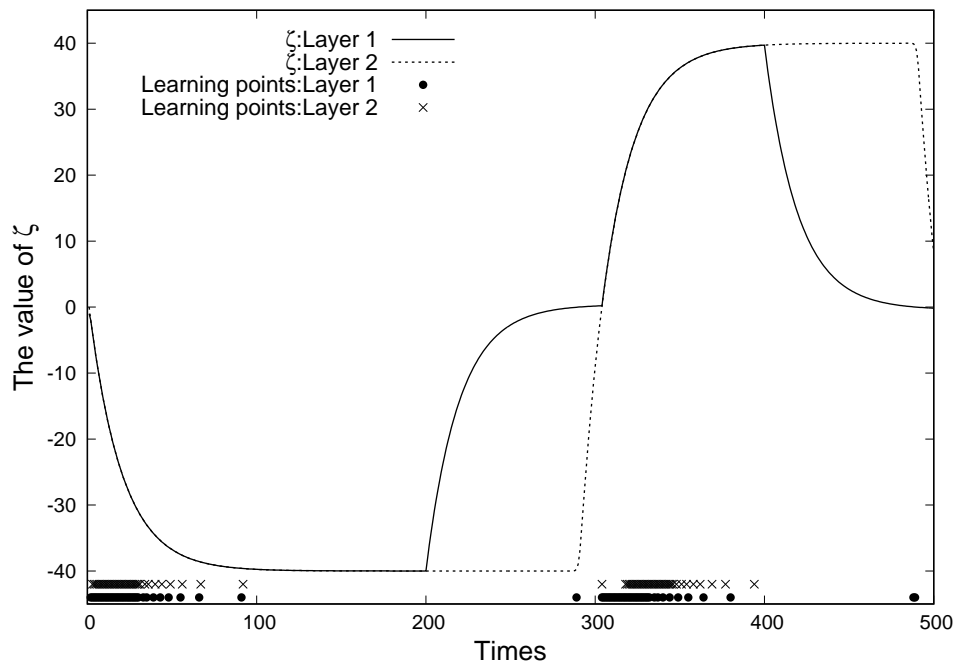


Figure 5.10: Comparison of ξ in layer 1 and 2 ($l_p = 200$).

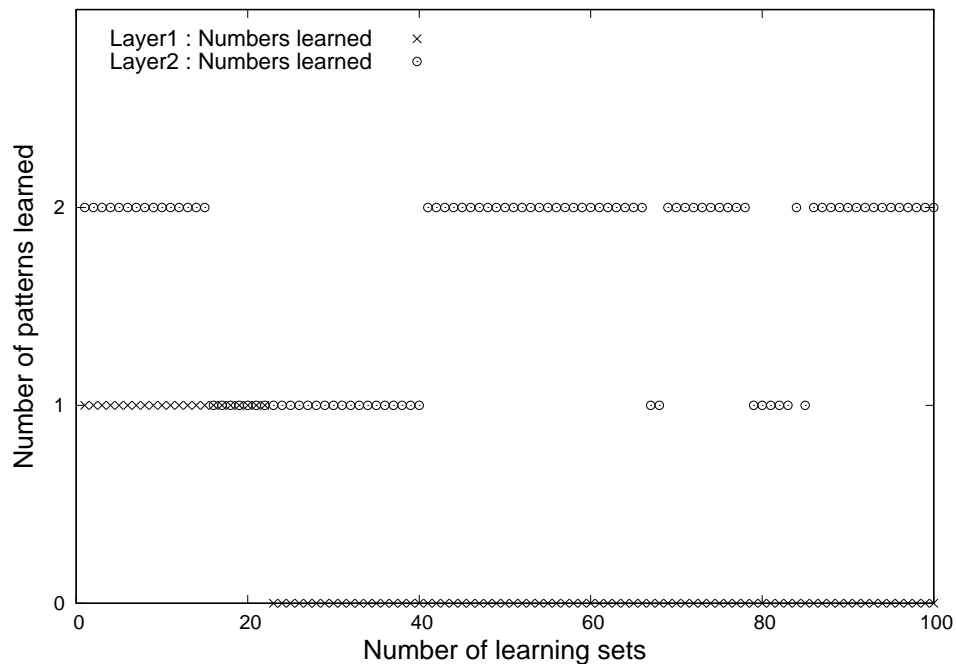


Figure 5.11: Layer 1 and layer 2 learning results.




Figure 5.12: Layer 1 state and learning.

たし、時折現れる『学習している』と『学習していない』の状態が交互に続く点で大きく変化している ($Times = 110, 210$ 付近など). 不応性係数 α を大きくしたことで、学習が起りやすくなった為にほぼ常時学習が行われている状態であると考えられる. また本研究で取り扱う逐次学習では、学習が行われるとあらかじめ定めた一定値 $\Delta\omega$ で重み付けが増減される. この増減が各状態式に見られる、振動を起こしていると考えられる. このことから、不応性係数や層間の結合係数が学習結果に大きく関わっていることが分かった.

5.5 不応性係数を増加させた学習 2

5.5.1 実験概要

実験 5.4 から、不応性係数や層間の結合係数が学習結果に大きく関わっていることが分かった. また、学習セット数 l_s を重ねることで学習結果も変化することとなった.

このうち、不応性係数 α についてより細かく値をとり、変更する前との違いを調査した. 元の値は非常に小さい為 (表 5.1), 桁上がりで現在の使用している値 (表 5.2) までを調査した.

5.5.2 実験結果・考察

α を変化させた時の各層状態式の変化を図 (5.13) (5.18) に示す.

図 5.13, 第 1 層の外部入力 ξ では、以前の α の数値では存在していた、0 付近での停滞が、 α が大きくなることで無くなっている. 図 5.14, 相互結合 η は、 α が大きくなるにつれ値も増大している. また、図 5.15 や図 5.18 の不応性 ζ では、状態式に α が関わってくることから指数的に値が大きくなっている. この為、図は正の範囲のみを対象として y 成分を対数軸に変更している. α が大きくなることで、 ζ の値が降下し始める点が早く現れていることがわかる. これも ξ と同じく、新しいパターンの影響を受けやすくなり変化が早まったのだと考えられる.

さらに、 $\alpha = 0.1$ から実験 5.4 で使用した値 $\alpha = 0.3$ までの変化をまとめたものを図 (5.19) (5.24) に示す.

外部入力 ξ (図 5.19, 図 5.22 では、特に 0.1 0.2 間での変化が目立つ. ここまでの変化とは違い、グラフの形自体は変わらないが ξ の値が減少している. また、 ξ の値に振動が発生している. 相互結合 η (図 5.20) では、ここまで値が増加を続けていたが、逆に減少し 0 に収束しようとしている. また、 ξ と同様に値が振動を始めている.

不応性 ζ (図 5.21) では、グラフ形状が ξ に似た形になり、ここまで値が増加していたが、以降 ξ の様に減少している. また、値が振動し始めているのも同様である. $\alpha = 0.1$ の時、 ξ と符号は反転しているが、絶対値はほとんど変わらなくなり、 ξ にちかいグラフの形となっている. 図 5.25 は $\alpha = 0.1$ の時における第 1 層の ξ と ζ を比較したものである.




Figure 5.13: Variation of ξ in layer 1 with $\alpha=0.001\sim 0.1$.




Figure 5.14: Variation of η in layer 1 with $\alpha=0.001\sim 0.1$.




Figure 5.15: Variation of ζ in layer 1 with $\alpha=0.001\sim 0.1$.




Figure 5.16: Variation of ξ in layer 2 with $\alpha=0.001\sim 0.1$.




Figure 5.17: Variation of η in layer 2 with $\alpha=0.001\sim 0.1$.

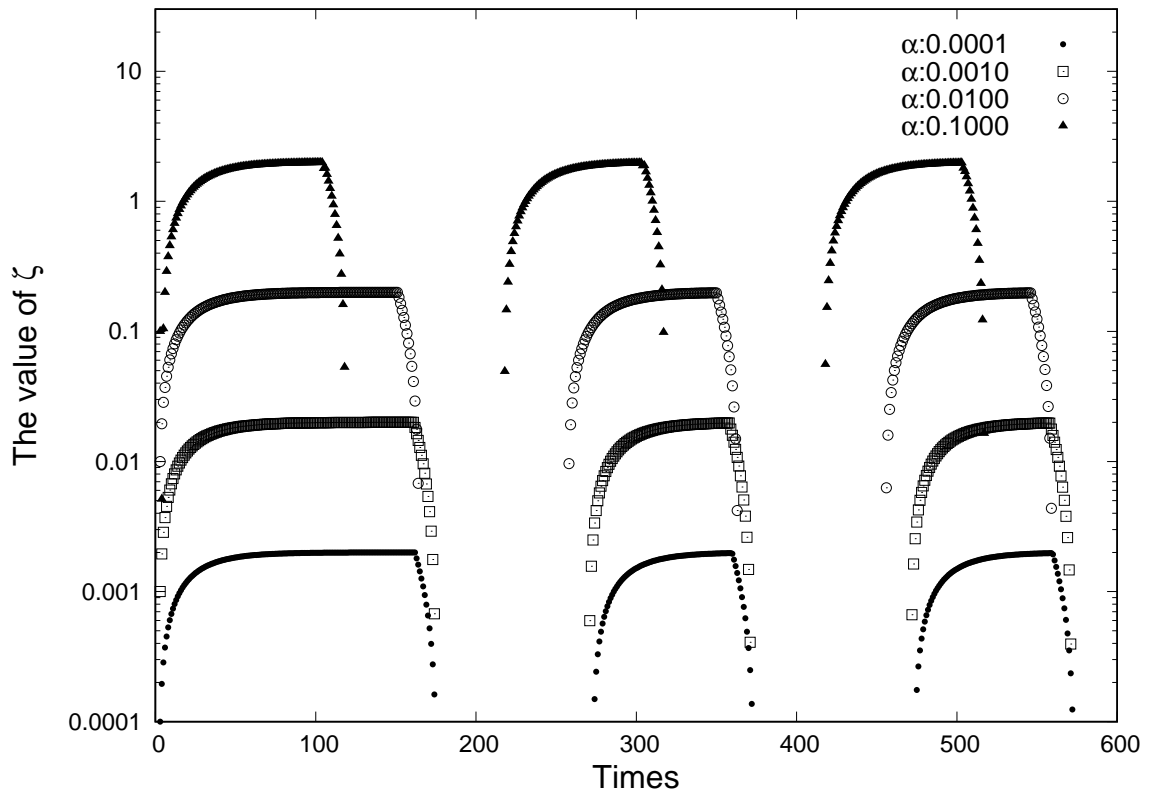


Figure 5.18: Variation of ζ in layer 2 with $\alpha=0.001\sim 0.1$.




Figure 5.19: Variation of ξ in layer 1 with $\alpha=0.1\sim 0.3$.




Figure 5.20: Variation of η in layer 1 with $\alpha=0.1\sim 0.3$.




Figure 5.21: Variation of ζ in layer 1 with $\alpha=0.1\sim 0.3$.




Figure 5.22: Variation of ξ in layer 2 with $\alpha=0.1\sim 0.3$.




Figure 5.23: Variation of η in layer 2 with $\alpha=0.1\sim 0.3$.




Figure 5.24: Variation of ζ in layer 2 with $\alpha=0.1\sim 0.3$.




Figure 5.25: Comparison of ξ and ζ in layer 1.

第6章 総括

ここまでの実験で、多層化されたカオスニューラルネットワークの逐次学習に関して、その学習方法や内部係数が学習結果にどのような結果を及ぼすかを調査した。

実験 5.3 より、ネットワークを学習させる時のパラメータ、特に l_p が大きく関わることがわかった。学習方法から、 l_p が増えることはそれだけ同じパターンをネットワークに学習させる回数が増えることになる。本研究で使用したネットワークモデルは、多層化により第 2 層からのフィードバックを第 1 層が受けていた為に第 1 層の学習が阻害されていたと考えられるが、これに対して l_p を増やすことで新しいパターンを学習できていた。同じパターンを何度も入力することで学習するのは、実際の学習にも共通する特性である。

実験 5.4 より、カオスニューラルネットワークの特性でもある不応性 ζ の係数 α を変更すると、今までとは違う振る舞いが見られた。学習結果については、ネットワーク内の全 2 層について、第 1 層はパターンを入力するほど学習できなくなり、逆に第 2 層は全パターンを学習することができた。また、学習の振る舞いについても今までには見られなかった『振動』が生まれた。状態式のうちの外部入力 ξ と不応性 ζ が、符号が反転しているが似たグラフの形を作り、その前までの実験で見られた形とは大きく異なっている。外部入力 ξ は 0 付近での停滞がなくなり符号が反転する。不応性 ζ は、前までの実験では、パターンが切り替わった後、しばらくの回数を経て符号が反転したが、 α が大きくなるごとに反転に至るまでの回数が少なくなり、最終的にパターンが切り替わるとすぐに ζ の符号も切り替わる様になった。これは不応性の特性そのものであるが、不応性係数 α を大きくしたことで学習しやすくなったということを示していると言える。

第7章 謝辞

最後に、本研究において一年間多大なご指導をいただいた出口利憲先生に深く感謝いたします。

参考文献

- [1] 吉富康成: 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: ニューロ・ファジィ・カオス, オーム社 (1993)
- [4] 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)
- [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] 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] 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] 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)
- [10] 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)
- [11] 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)
- [12] 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)