動的バイナリーニューラルネットの学習、安定化、応用

KOUZUKI, Ryota / 上月, 良太

(発行年 / Year)
2014-03-24

(学位授与年月日 / Date of Granted)
2014-03-24

(学位名 / Degree Name)
修士(工学)

(学位授与機関 / Degree Grantor)
法政大学 (Hosei University)

2013年度　修士論文

論文題名 動的バイナリーニューラルネットの
学習、安定化、応用

指導教授 斎藤 利通 教授

法政大学大学院工学研究科
電気工学専攻修士課程

学生証番号： 12R3109

コウヅキ　リョウタ
氏名 **上月　良太**

あらまし

本論文では、シグナム活性化関数、3 値重みパラメータと整数しきい値パラメータによって特徴づけられる単純な動的バイナリーニューラルネットワーク (Dynamic Binary Neural Networks:DBNN) を研究していく。DBNN は、シグナム関数と 3 値重みパラメータを有するフィードフォワード型のバイナリーニューラルネットワーク (Binary Neural Networks:BNN) に遅延フィードバックを適用することによって構成される。DBNN は、中間層のニューロン数が十分であれば、任意のブール関数を実現できる。また、ネットワークは、リカレントニューラルネットワークのデジタル版とみなすことができ、パラメータと初期値に依存して、様々な 2 値周期軌道 (Binary Periodic Orbit:BPO) を呈することができる。DBNN は様々な工学系応用が可能である。その例としては、信号処理や回路制御等が挙げられる。

しかしながら、これらの DBNN は取り扱う問題の規模により中間層ニューロン数の増加や、計算コストの上昇などの問題点を抱えている。これらの問題を解決するために、いくつかの学習法が提案されてきた。本論文では、所望の周期軌道を記憶するために、相関学習と遺伝的アルゴリズムに基づく二つの学習アルゴリズムを用いた 2 層の DBNN の学習について考察する。基本的な数値実験を通じて、所望の BPO の埋め込みとその BPO への自動安定化等について考察していく。その際、分析ツールとしてグレイコードに基づくリターンマップ (Gray-code based return map:Gmap) を導入する。

また、本論文では 3 層の DBNN についても研究し、インバータやマトリクスコンバータのスイッチ信号に対応した教師信号の学習について考察していく。教師信号への安定性の向上のために、GA に基づくスパース化学習を行う。さらに、Gmap を用いて教師信号の銘記を確認し、周期軌道の自動安定化について考察していく。

Learning, Stabilization and Applications of Dynamic Binary Neural Networks

Abstract

This paper studies the simple dynamic binary neural networks (DBNN) characterized by signum activation function, ternary weighting parameters and integer threshold parameters. The DBNN is constructed by applying delayed feedback to Binary Neural Networks (BNN) with ternary weighting parameters and signum activation function. If number of neurons in the hidden layer is sufficient, the DBNN can realize desired Boolean function. In addition, the network can be regarded as the digital version of the recurrent neural network. The DBNN can exhibit various Binary Periodic Orbit (BPO) depending on the parameters and initial value. The DBNN is capable of various engineering applications: Signal processing, control circuits, etc.

However, the DBNN has a problem such as an increase in computational cost and an increase in the number of hidden neurons by size of teacher signals. In order to solve these problems, some learning methods have been proposed. In this paper, we consider the 2-layer DBNN to store the desired BPO. The learning algorithm is based on the genetic algorithm (GA) and correlation learning. Performing a basic numerical experiment, we confirm that the teacher signal is stored successfully and is stabilized automatically. In order to visualize the dynamics of the DBNN, we introduce a systematic analysis tool: the Gray-code-based return map (Gmap).

Also, this paper studies the 3-layer DBNN. We propose the learning of teacher signal corresponding to switching patterns of the inverter and matrix converter. Applying the GA-based sparsity learning, stability of the stored BPOs is improved. Using the Gmap, we have confirmed storage of the teacher signal and automatic stabilization of the periodic orbits.

目 次

図 目 次

表 目 次

第1章　まえがき

ニューラルネットワークは、脳神経系に見られるいくつかの特性を数理モデル化したものである。人間の脳は、140 億個のニューロンから構成され、ニューロン同士が相互に連結し、巨大なネットワークを築いている。このニューロン同士のネットワークをソフトウェアで再現しようとニューラルネットワークの研究が行われてきた [1]。現在普及しているコンピュータである、データとして格納したプログラムを順番に読み込んで処理するノイマン型コンピュータは、メモリ読み込み速度等物理的な限界がある。また、判断基準が変化するパターン認識などの処理の難しさという観点から、別の情報処理のアプローチが考えられた。その一つが非ノイマン型の一つであるニューラルネットワークに代表される情報処理である。近年、コンピュータの性能が飛躍的に向上したことにより、メモリから命令を読み出す速度が律速になってしまうといったノイマン型の抱える弱点が目立ってきたため、様々な非ノイマン型の設計が提唱されている。その例として、ニューラルネットワークを利用したニューロコンピュータが挙げられる。様々なニューラルネットワークが考案されており、その代表にマルチレイヤーパーセプトロン (Multi Layer Perceptron:MLP[2]) がある。MLP は 1986 年に Rumelhart らに提案された入力層、中間層、出力層からなる 3 層以上のフィードフォワード型ニューラルネットワークである。そのニューロンの入出力には実数の信号を扱う。MLP の学習アルゴリズムの代表例にバックプロパゲーション (Back Propagation:BP) と呼ばれる教師あり学習がある。MLP の BP アルゴリズムは、出力値とターゲット値の誤差を最小にする重みを求めるために、最急降下法が使われており、線形分離不可能な問題を解くことができる。一方、2 値を入出力とするブール関数の近似のために、簡素な MLP として、2 値信号を入出力とするバイナリーニューラルネットワーク (Binary Neural

Networks:BNN) が提案された。BNN は N 入力 1 出力であり、MLP と同様な 3 層構造のフィードフォワードネットワークである。それぞれのニューロンは、シグナム活性化関数を有することで、2 値の信号を出力する [3] [4]。中間層には、3 値をとる重みパラメータと整数値を取るしきい値パラメータがあり、出力層の重みパラメータは 2 値を取る。これらのパラメータによって BNN は特徴づけられる。この BNN の発展形に動的バイナリーニューラルネットワーク (Dynamic Binary Neural Networks:DBNN) がある。DBNN は、BNN を N 入力 N 出力とし、遅延フィードバックを適用させたものである。DBNN は、BNN 同様シグナム活性化関数を有し、入出力は 2 値である。また、中間層ニューロンの重みパラメータは 3 値、出力層ニューロンの重みパラメータは 2 値、それぞれのしきい値パラメータは整数である。DBNN は動的なデジタルシステムであり、パラメータと初期値に依存して様々な 2 値周期軌道 (Binary Periodic Orbit:BPO) を呈することができる。また、DBNN は様々な工学的応用が可能であり、その例として、信号処理や回路制御等が挙げられる [5] [6] [7]。しかしながら、DBNN は取り扱う問題の規模による中間層ニューロン数の増加や、学習時間の増加といった問題が存在する。これらの問題を解決するために、いくつかの学習法が提案されてきた。

2 章では簡素な DBNN(Simple Dynamic Binary Neural Networks:SDNN) の紹介とその学習アルゴリズムについて紹介する。また典型的な計算機実験を示し、アルゴリズムの有効性を確認する。所望の BPO の記憶のため、相関学習 [8] に基づく学習法と遺伝的アルゴリズム (Genetic Algorithm:GA)[9] [10] に基づく学習法の 2 つを用いる。この 2 つの方法を用いて、いくつかの数値実験によりその有効性を示す。その実験では、いくつかの例題を用いる。例題として、DC-AC インバータのスイッチパターンを学習させ、実験を行う [11] [12]。また、SDNN のダイナミクスの視覚化のため、我々は、グレイコードを用いたリターンマップ (Gray-code based return map:Gmap)[10] を導入する。この Gmap を用いて、SDNN のダイナミクスの考察を行う。

3 章では 3 層の DBNN の学習アルゴリズムと回路の制御信号への応用を紹介する。また典型的な計算機実験を示し、アルゴリズムの有効性を確認する。3 章では中間層

ニューロンの数を固定した状態での DBNN の学習について考察を行う。DBNN は上記で触れたように取り扱う問題の規模により中間層ニューロンが増加し、計算時間が増加するといった問題が挙げられる。この問題に対して、中間層ニューロン数を教師信号の周期の数に固定して学習を行うことで、計算の簡略化を行う。学習では、学習させる教師信号を用いて中間層重みパラメータを決定することで、教師信号を DBNN に記憶させる。その後、教師信号への安定性の向上のため、GA に基づく学習法を用いることで、DBNN のスパース化を行う。数値実験によりその有効性を示す。その実験では、例題としてマトリクスコンバータのスイッチパターンを学習させ、実験を行う。また、Gmap を用いて、ダイナミクスの安定性について考察を行う。

4 章では本論文のむすびと今後の課題について示す。

第2章　簡素な動的バイナリーニューラルネットワークの学習

2.1　まえがき

本章では、簡素な動的バイナリーニューラルネットワーク (Symple Dynamic binary Neural Networks:SDNN) の学習を研究している。SDNN は、2 層ニューラルネットワークに遅延フィードバックを適用することによって構成され、シグナム関数、三元重み付けパラメータと整数閾値パラメータによって特徴付けられる。SDNN のパラメータは初期値に依存し、 様々な BPO を示すことができる。我々はいくつかの例で SDNN の基本的な問題を考える。所望の１つの BPO の埋込のための学習と、埋め込んだ BPO の安定性について。

まず、我々は、既存のシステムであるリカレントニューラルネットワーク (Recurrent Neural Network:RNN [8] [13] [14]) 、3 層 DBNN([9] [10])、及びセルオートマトン (Cellular Automaton:CA [5]) と SDNN との関連性を明確にする。大まかに言えば、 SDNN は、 RNN のデジタル版と見なすことができる。RNN は、 SDNN がデジタルシステムであるのに対し、滑らかな活性化関数と実数値パラメータによって特徴付けられたアナログシステムである。DBNN は 3 層ニューラルネットワークに遅延フィードバックを適用することによって構成されている。中間層ニューロンの数が十分に大きければ DBNN は SDNN より広いクラスの BPO を格納することができる。しかしながら、SDNN の学習アルゴリズムとネットワーク構造は DBNN のそれよりもはるかに単純である。SDNN は単純な実装に適している。CA は、豊かなダイナミクスと、多くの潜在的/実在のアプリケーションを有する一般的なデジタル力学系である [6] [7] [5]。SDNN のダイナミクスは、CA のクラスのそれに関連する [10]。SDNN は、デジタル力学系の

基本的な検討のための簡素な例である。

第２に、SDNN のダイナミクスを可視化に有用である Gmap を紹介する。SDNN は、格子点に対応する N 次元２値ベクトルのマッピングを実現し、そのダイナミクスは、格子点の集合からリターンマップ自身に組み込むことが出来る。Gmap は１次元アナログマップのデジタル版とみなすことができる [15]。

第３に、１つの BPO の埋め込みを目的として、２つの学習アルゴリズムを示す。一つ目は、簡素な式でパラメータを決定することが出来る相関学習に基づく学習法である。CL 法は、BPO の１つのクラスの埋め込みを保証する。２つ目は、遺伝的アルゴリズムに基づく学習法である。

2.2　簡素な動的バイナリーニューラルネットワーク

SDNN はシグナム活性化関数を有するニューラルネットワークに遅延フィードバックを適用することで構成される。図 2.1 に簡単な DBNN の例を示す。ネットワークのダイナミクスは以下の式 (2.1) で示される。

$$\begin{aligned} x_i^{t+1} &= \mathrm{sgn}\left(\sum_{j=1}^{N} w_{ij}x_j^t - T_i\right),\ i = 1 \sim N \\ \mathrm{sgn}(x) &= \begin{cases} 1 & \text{for } x \geq 0 \\ -1 & \text{for } x < 0 \end{cases} \end{aligned} \tag{2.1}$$

ここで $x_i^t \in \{-1, 1\} \equiv \boldsymbol{B}$ は離散時間 t における i 番目の x の値である。SDNN は 3 値重みパラメータ $w_{ij} \in \{-1, 0, 1\}$、及び整数しきい値パラメータ $T_i \in \boldsymbol{Z}$ によって特徴付けられる。離散時間 t における N 次元 2 値ベクトル $\boldsymbol{x}^t = (x_1^t, \cdots, x_N^t)$, はシグナム活性化関数により離散時間 $t+1$ において $\boldsymbol{x}^{t+1}$ に変化する。SDNN は $\boldsymbol{x}^t$ の写像 F_D を実現し、その反復により式 (2.2) のような 2 値ベクトル系列を生成することが出来る。

$$\boldsymbol{x}^{t+1} = \boldsymbol{F}_D(\boldsymbol{x}^t),\quad \boldsymbol{x}^t \in \boldsymbol{B}^N \tag{2.2}$$

SDNN はパラメータと初期値に依存して、様々な BPO を呈することが出来る。SDNN の立ち位置を明確にするため、SDNN はいくつかの既存のシステムに関連するものであることに留意する。第一に、SDNN は滑らかな活性化関数と実数値パラメータによっ

て特徴付けられた RNN のデジタル版と見なすことが出来る [13]。SDNN が動的デジタルシステムであるのに対し、RNN は動的アナログシステムである。第二に、SDNN は DBNN の簡易版である [9] [10]。DBNN は 3 層のフィードフォワード型 BNN[3]-[18] に遅延フィードバックを紀要することで構成される。DBNN は中間層ニューロンが十分大きければ SDNN より広いクラスの BPO を埋め込むことが出来る。しかしながら、DBNN や RNN と比較して、SDNN はより単純な構造をしており、簡素な実装に適している。第三に、SDNN のダイナミクスは CA のクラスに深く関係している。CA は典型的な単純なルールに制御された動的デジタルシステムである [5]-[7]。CA は単純な場合様々な時空パターンを呈することが出来、画像処理 [6] や音声データの圧縮 [7] 等に応用することが出来る。しかしながら、ダイナミクスの解析は容易ではない。

2.3　ダイナミクスの視覚化

SDNN の可視化のため、我々はグレイコードに基づくリターンマップ (Gmap) を紹介する。G_N は N 次元の 2 値ベクトル B^N の写像を格子点 I_N の写像に変換したもので、以下の式で定義される。

$$\begin{gathered} G_N : I_N \to B^N,\ I_N = \{C_1, C_2, \cdots, C_{2^N}\} \\ C_i \equiv i/2^N, i = 1 \sim 2^N \end{gathered} \tag{2.3}$$

ここで C_i は 1 次元のライン上に配置された格子点を示し、有理数 $i/2^N$ と等価であることに注意する。便宜上、グレイコードによる 1 つ隣の B^N をハミング距離 1 として表す。例えば、以下のような $N=3$ での G_N は次式ので与えられる。

$$\begin{array}{ll} G_3(C_1) = (-1,-1,-1) & G_3(C_5) = (+1,+1,-1) \\ G_3(C_2) = (-1,-1,+1) & G_3(C_6) = (+1,+1,+1) \\ G_3(C_3) = (-1,+1,+1) & G_3(C_7) = (+1,-1,+1) \\ G_3(C_4) = (-1,+1,-1) & G_3(C_{2^3}) = (+1,-1,-1) \end{array}$$

G_N に式 (2.2) を適用すると、次式のような Gmap が得られる。

$$F_G : I_N \to I_N,\ F_G = G_N^{-1} \circ \boldsymbol{F}_D \circ G_N \tag{2.4}$$

つまり、SDNN のダイナミクスは次式のように簡略化される。

$$\theta^{t+1} = F_G(\theta^t),\ \theta^t = G_N^{-1}(\boldsymbol{x}^t) \in I_N \tag{2.5}$$

ここで変数 θ^t は I_N の要素である。図 2.2 は図 2.1 の SDNN の Gmap の例を示している。N があまり大きくない場合 (本章においては $N = 6$ から 8 程度)、Gmap はダイナミクスの視覚化に有用である。ここで、基本的な Gmap の定義を示す。

定義：点 $\theta_p \in I_N$ は F_G の p 回合成が F_G^p とした時 $0 < k < p$ において $F_G^p(\theta_p) = \theta_p$ かつ $F_G^k(\theta_p) \neq \theta_p$ であるなら、周期 p の 2 値周期点 (Binary Periodic Point:BPP) であると言われる。BPP の系列 $\{F_G(\theta_p), \cdots, F_G^p(\theta_p)\}$ を周期 p の BPO と呼ぶ。図 2.2 は周期 4 の BPO を示している。BPP ではない、かつ $F_G^m(\theta_e)$ が BPP であるような整数 m が存在する場合、点 $\theta_e \in I_N$ は Eventually Periodic Point (EPP) と呼ばれる。図 2.2 に示すように、EPP からスタートした軌道がいずれかの BPO に収束する。BPO は軌道が BPO に収束する EPP が存在するならば安定であると言える。EPP は BPO の収束領域を特徴づける。

2.4 相関学習に基づく学習法

我々の提案する学習アルゴリズムの目的は、式 (2.6) に定義するような周期 T の BPO の埋め込みが目的である。

$$\begin{aligned}&\{\boldsymbol{z}^1, \boldsymbol{z}^2, \cdots, \boldsymbol{z}^T\},\ \boldsymbol{z}^t = (z_1^t, \cdots, z_N^t) \in \boldsymbol{B}^N\\&\boldsymbol{z}^{1+T} = \boldsymbol{z}^1,\ \boldsymbol{z}^k \neq \boldsymbol{z}^1 \text{ for } 2 \leq k \leq T\end{aligned} \tag{2.6}$$

ここで、2 つの連続した 2 値ベクトル $\boldsymbol{z}^t$ と $\boldsymbol{z}^{t+1}$ はそれぞれ SDNN の入力 $\boldsymbol{x}^t$ と出力 $\boldsymbol{x}^{t+1}$ に対応している。便宜上、我々は仮変数のベクトル

$$\boldsymbol{y}^t = \boldsymbol{z}^{t+1},\ \boldsymbol{y}^t = (y_1^t, \cdots, y_N^t),\ 1 \leq t \leq T$$

を導入する。例えば、図 2.2 のような周期 4 の BPO が以下の式 (2.7) のように与えられたとする。

$$\begin{aligned}\boldsymbol{y}^1 &= \boldsymbol{z}^2 = (-1, +1, -1)\\\boldsymbol{y}^2 &= \boldsymbol{z}^3 = (+1, -1, -1)\\\boldsymbol{y}^3 &= \boldsymbol{z}^4 = (+1, +1, +1)\\\boldsymbol{y}^4 &= \boldsymbol{z}^1 = (-1, +1, +1)\end{aligned} \tag{2.7}$$

これらを用いて、教師信号は式 (2.8) のような入出力対で表記される。

$$(\boldsymbol{z}^t,\ \boldsymbol{y}^t),\ t = 1 \sim T \tag{2.8}$$

ここで、$(\boldsymbol{z}^t,\ \boldsymbol{y}^t)$ の上限値は 2^N であり、教師信号の記憶は N が大きくなるにつれて難しくなることに留意されたい。本章では基本的な例 (1 つの BPO の埋め込み) について考え、将来的にはより複雑な例について考えていく。学習の目的は、SDNN に 1 つの教師信号を埋め込むことを保証するパラメータ w_{ij} と T_i を決定することである。我々は、学習のための基本的な実験結果が以下のようにある。

命題: 3 値重みパラメータ w_{ij} 及び教師信号式 (2.8) が以下を満たすなら教師信号の埋め込みは保証される。

$$L_i < R_i \ \text{ for all } i = 1 \sim N \tag{2.9}$$

ここで、R_i と L_i は以下の式 (2.10) のような整数となる。

$$\begin{aligned} R_i &= \min_t r(i,t),\ r(i,t) \equiv \sum_{j=1}^{N} w_{ij} z_j^t \ \text{ for } y_i^t = 1 \\ L_i &= \max_t l(i,t),\ l(i,t) \equiv \sum_{j=1}^{N} w_{ij} z_j^t \ \text{ for } y_i^t = -1 \end{aligned} \tag{2.10}$$

証明: 条件 2.9 を満たした場合、整数値 T_i は以下の式 (2.11) のようになる。

$$L_i < T_i \le R_i,\ i = 1 \sim N \tag{2.11}$$

式 (2.11) により以下の式 (2.12) が保証される。It guarantees

$$\begin{aligned} l(i,t) \equiv \sum_{j=1}^{N} w_{ij} z_j^t < T_i \quad & \text{for } y_i^t = -1 \\ T_i \le \sum_{j=1}^{N} w_{ij} z_j^t \equiv r(i,t) \quad & \text{for } y_i^t = 1 \end{aligned} \tag{2.12}$$

これらは式 (2.13) のような BPO の埋め込みを保証する。

$$y_i^t = \operatorname{sgn}\left(\sum_{j=1}^{N} w_{ij} z_j^t - T_i \right),\ i = 1 \sim N,\ 1 \le t \le T \tag{2.13}$$

全ての i において $y_i^t = -1 (y_i^t = -1)$ ならば $R_i (L_i)$ は存在しない。この場合、式 (2.11) を $L_i < T_i (T_i \le R_i)$ に置き換えることで式 (2.13) が与えられる。QED。

ここで重みパラメータ w_{ij} が式 (2.14) のように教師信号の相関に基づく重み s_{ij} を 3 値化することで与えられる相関学習に基づく学習法を示す。

$$w_{ij} = \begin{cases} 1 & \text{for } s_{ij} > 0 \\ 0 & \text{for } s_{ij} = 0 \\ -1 & \text{for } s_{ij} < 0 \end{cases} \quad s_{ij} = \sum_{t=1}^{T} z_i^t y_j^t \tag{2.14}$$

ここで $i=1\sim N$、$j=1\sim N$、$t=1\sim T$ である。すなわち、信号 (式 (2.8)) を式 (2.14) に代入することで、w_{ij} が得られる。相関に基づく重み s_{ij} の意味は [14] を含む多くの文献で議論されている。次に、整数しきい値パラメータは以下の式 (2.15) で与えられる。

$$T_i = \begin{cases} (R_i+L_i)/2 & \text{if } R_i - L_i = \text{even} \\ (R_i+L_i+1)/2 & \text{if } R_i - L_i = \text{odd} \\ N+1 & \text{if } R_i \text{ is not exist} \\ -(N+1) & \text{if } L_i \text{ is not exist} \end{cases} \tag{2.15}$$

ここで R_i と L_i は式 (2.10) に信号 (2.8) と w_{ij} を代入して与えられたものである。ここで $L_i \le N$ かつ $-N \le R_i$ であることに留意したい。我々は、相関学習に基づく学習法として式 (2.14) や式 (2.15) によるパラメータ設定を参照する。w_{ij} が式 (2.9) を満たす場合、T_i は式 (2.11) を満たし、教師信号 BPO の埋め込みが保証される。

数値実験:例 1

アルゴリズムの性能を調べるため、3 種類の教師信号による数値実験を行う。1 つ目の信号は DC-AC インバータの制御信号に関連している。図 2.3 は DC-AC インバータの回路モデルと 6 つのスイッチの制御信号を示している。直流入力電圧 $V_s/2$ は 6 つのスイッチを介して 3 相の線間電圧 v_{ab}、v_{bc}、v_{ca} に変換される。線間電圧をフィルタリングすることで、3 相交流出力電圧が得られる。スイッチ S_1、S_3 及び S_5 は周期 $T(\omega=2\pi/T)$ で、それぞれスイッチ S_4、S_6 及び S_2 に逆相で動作する。時間軸を 6 分割 (時間単位 $\omega T/6$) することで、スイッチ信号は $\boldsymbol{z}^t=(z_1^t\cdots z_6^t)$ を状態 S_1 から S_6 に対応する、表 2.1 に示すような周期 6 の 6 次元 BPO で表すことが出来る。例えば、”$z_1^3=+1$”及び”$z_6^3=-1$”は時間単位 3 においてそれぞれ”$S_1=$on”かつ”$S_6=$off”であることを意味する。以上が 1 つ目の教師信号である。相関学習に基づく学習法を適用すると、BPO を SDNN に埋め込むことが出来た。図 2.4 および表 2.2 は SDNN の形状と学習後のパラメータを示している。図 2.5 は図 2.4 の Gmap を示している。ここで、図 2.5 より教師信号 BPO(緑の軌道) を埋め込むことが出来たことがわかる。また、この Gmap は教師信号の他に 6 周期の BPO と 3 つの不動点を有する。教師信号の収束領域の特性付けのため、Convergence

Rate(CR) を以下の式 (2.16) のように定義する。

$$CR = \frac{\#\text{教師信号に落ち入る (EPP + BPP)}}{\#\ \text{全ての格子点の数}} \tag{2.16}$$

CR は教師信号 BPO に最終的に落ち入る初期入力の比率である。例えば、$CR = 0$ は BPO が埋め込めなかったことを意味し、$CR = 1$ は教師信号を埋め込むことが出来、かつ全ての入力が自動的に教師信号 BPO に安定化したことを意味する。図 2.5 において、$CR = 0.65$ であることが確認できた。すなわち、BPO は 65%の初期格子点から成る収束領域を有し、BPO が安定であることを示している。ここで教師信号は収束領域についての情報を有しておらず、かつ自動的に 65%の入力が安定化したことに留意したい。また、しかしながら、スイッチ信号の収束領域が十分に考慮されていない、このようなスイッチ信号の実装法が多数存在することに留意したい。

2.5 遺伝的アルゴリズムに基づく学習法

相関学習に基づく学習法で教師信号を埋め込むことが出来ない場合、次に紹介する GA に基づく学習法を用いる。l を進化過程のステップ数とし、G_m を最大世代数とする。初めに、重みパラメータの候補値である各々の染色体を M_g 個用意する。l ステップ目の k 番目の染色体は式 (2.17) に示すような $N \times N$ の重みパラメータの候補地で構成される。

$$\boldsymbol{C^k}(l) \equiv \{w_{11}^k(l), \ldots, w_{NN}^k(l)\} \tag{2.17}$$

ここで、$k = 1 \sim M_g$、$0 \leq l < G_m$ であり、$w_{ij}^k(l)$ は w_{ij} の候補である 3 値となる。染色体は $N \times N$ の要素を有するので、探索空間は $3^{N \times N}$ 点となり、N が増加すると直接探索が困難となり、事実上不可能となる。これが GA を用いる理由の一つである。次に、一つの初期染色体には相関学習に基づく学習で得られる w_{ij}2.14 が与えられる。この場合、GA に基づく学習の w_{ij} の評価値 (式 (2.19)) は相関学習に基づく学習の評価値以上である必要がある。他の $M_g - 1$ 個の初期染色体はランダムに与えられる。染色体は以下の操作で更新される。

1. 一点交叉： 1 点交叉は i 番目の重みベクトル $\boldsymbol{w}_i = (w_{i1}, \cdots, w_{iN})$、$i = 1 \sim N$ に確率 P_c で適用される。例えば、k 番目及び l 番目の候補の j 番目の要素が交差点として選ばれたなら、以下の式 (2.18) が実行される。

$$
\begin{array}{c}
\left(w_{i1}^k, \cdots, w_{ij}^k, w_{ij+1}^k, \cdots, w_{iN}^k\right) \\
\left(w_{i1}^l, \cdots, w_{ij}^l, w_{ij+1}^l, \cdots, w_{iN}^l\right) \\
\Downarrow \\
\left(w_{i1}^k, \cdots, w_{ij}^k, w_{ij+1}^l, \cdots, w_{iN}^l\right) \\
\left(w_{i1}^l, \cdots, w_{ij}^l, w_{ij+1}^k, \cdots, w_{iN}^k\right)
\end{array}
\tag{2.18}
$$

2. 突然変異： 一つの遺伝子 $w_{ij}^k(l)$ は確率 P_m で選ばれ、その値は 1/2 の確率で他のどちらかの値に変化する (例：$w_{ij}^k(l)$ が 1 なら 0ka-1 のどちらかに変化する)。

3. 評価： 各染色体は式 (2.19) によって適応度を評価される。

$$
F(\boldsymbol{C}^k(l)) = \min_i (R_i^k(l) - L_i^k(l)) \tag{2.19}
$$

ここで 2 つの整数値 $R_i^k(l)$ と $L_i^k(l)$ は式 (2.10) に $w_{ij}^k(l)$ を代入することで得られる。この評価値に基づいて、エリート戦略を適用する。エリート戦略では、染色体のソートを行い、評価の一番低い染色体を淘汰し、評価の一番高い染色体を複製する。$F(\boldsymbol{C}^k(l)) \geq 1$ を満たす染色体を得ることができたら、その染色体の w_{ij} は条件 (2.9) を満たし、かつ教師信号の埋め込みを保証する。上記の場合、学習を終了する。w_{ij} が与えられたら、しきい値パラメータ T_i は式 (2.15) で与えられる。

4. 終了判定: GA は $F(\boldsymbol{C}^k(l)) \geq 1$ を満たす、または学習回数が最大世代数を超えるような染色体が得られるまで学習を繰り返す。

我々の提案する学習法では重みパラメータ w_{ij} をまとめて学習することが出来ることに留意したい。このような集団決定法は DBNN の学習では不可能である [10]。DBNN では、中間層ニューロンの数が学習プロセスの中で増加し、重みパラメータは各々の中間層ニューロンごとに決定する。我々は、相関学習に基づく学習法で埋め込むことの出来ない 2 つの人工的な教師信号の例を用いて GA に基づく学習アルゴリズムの基本的なパフォーマンスを考察する。学習結果は、成功例の平均収束率 (ACR) 及び学習の成功率 (SR) により評価される。

数値実験:例 2

表 2.3 は例 2 の教師信号 BPO を示す。この教師信号に相関学習に基づく学習法を適用した。表 2.4 及び図 2.7(a) はそれぞれ学習後のパラメータと Gmap を示す。図 2.7(a) より、BPO を埋め込むことが出来ず ($CR = 0$)、Gmap は不動点 1 つのみが存在している。次に、表 2.4 の重みパラメータを初期染色体の 1 つとして用いた GA に基づく学習法を適用する。パラメータを以下のように設定して学習を行った。

$$(G_M, M_g, P_c, P_m) = (400, 100, 0.8, 0.1) \tag{2.20}$$

ここで学習結果の典型例として、SDNN の形状とパラメータを図 2.6 および表 2.5 に示す (178 世代目の評価値:$F(\boldsymbol{C}^k(178)) = 1$)。図 2.7 (b) は図 2.6 の Gmap であり、Gmap は一つの教師信号 BPO のみを有することがわかる。他の格子点入力は EPP であり、CR=1 である。すなわち、教師信号 BPO を埋め込むことが出来、自動安定化していることがわかる。

初期染色体、交叉、突然変異のために異なる乱数を用いて 100 回の数値実験を行った。学習後、SR=0.78、ACR=0.98 であることを確認した。ここで ACR は学習後の評価であることに留意したい。学習過程で CR を制御することは極めて難しい。しかしながら、このような評価値データは将来的に CR を制御するための基本データと成り得る。

数値実験:例 3

表 2.6 に例 3 の教師信号 BPO を示す。この教師信号に相関学習に基づく学習法を適用した。表 2.7 と図 2.9(a) はそれぞれ学習後のパラメータと Gmap を示している。図 2.9(a) より教師信号 BPO が埋め込めなかったことがわかる。次に、表 2.7 の重みパラメータを初期染色体の 1 つとして用いた GA に基づく学習法を適用する。パラメータは式 (2.20) のように設定した。学習結果の例として図 2.9 および表 2.8 に Gmap とパラメータを示す。学習後の SDNN は図 2.8 のようになる (205 世代目の評価値:$F(\boldsymbol{C}^k(205)) = 1$)。図

2.9 より、教師信号 BPO を埋め込むことが出来、かつ自動的に安定化したことがわかる。同様の実験を 100 回試行した結果、SR=0.11、ACR = 0.58 であった。GA に基づく学習法の性能は問題の難易度に依存する。例 3 は例 2 に比べて SR、ACR ともに相対的に低い結果が得られた。

2.6 むすび

本章では SDNN 及びその学習について研究を行った。系統的な DBNN のダイナミクスの可視化のために、Gmap を導入した。学習アルゴリズムの性能は、3 つの教師信号の例で検討を行った。

1 つ目の例である AC-DC インバータの制御信号では、教師信号を相関学習に基づく学習法で記憶することが出来た。2 つ目、3 つ目の例である人工的な教師信号 BPO では、教師信号は相関学習に基づく学習法では記憶できなかったが、GA に基づく学習法で記憶することが出来た

Gmap による教師信号の記憶と安定性の可視化を行った。本章では効率的な学習アルゴリズムとそのアプリケーションの開発のための基礎の段階について議論を行った。

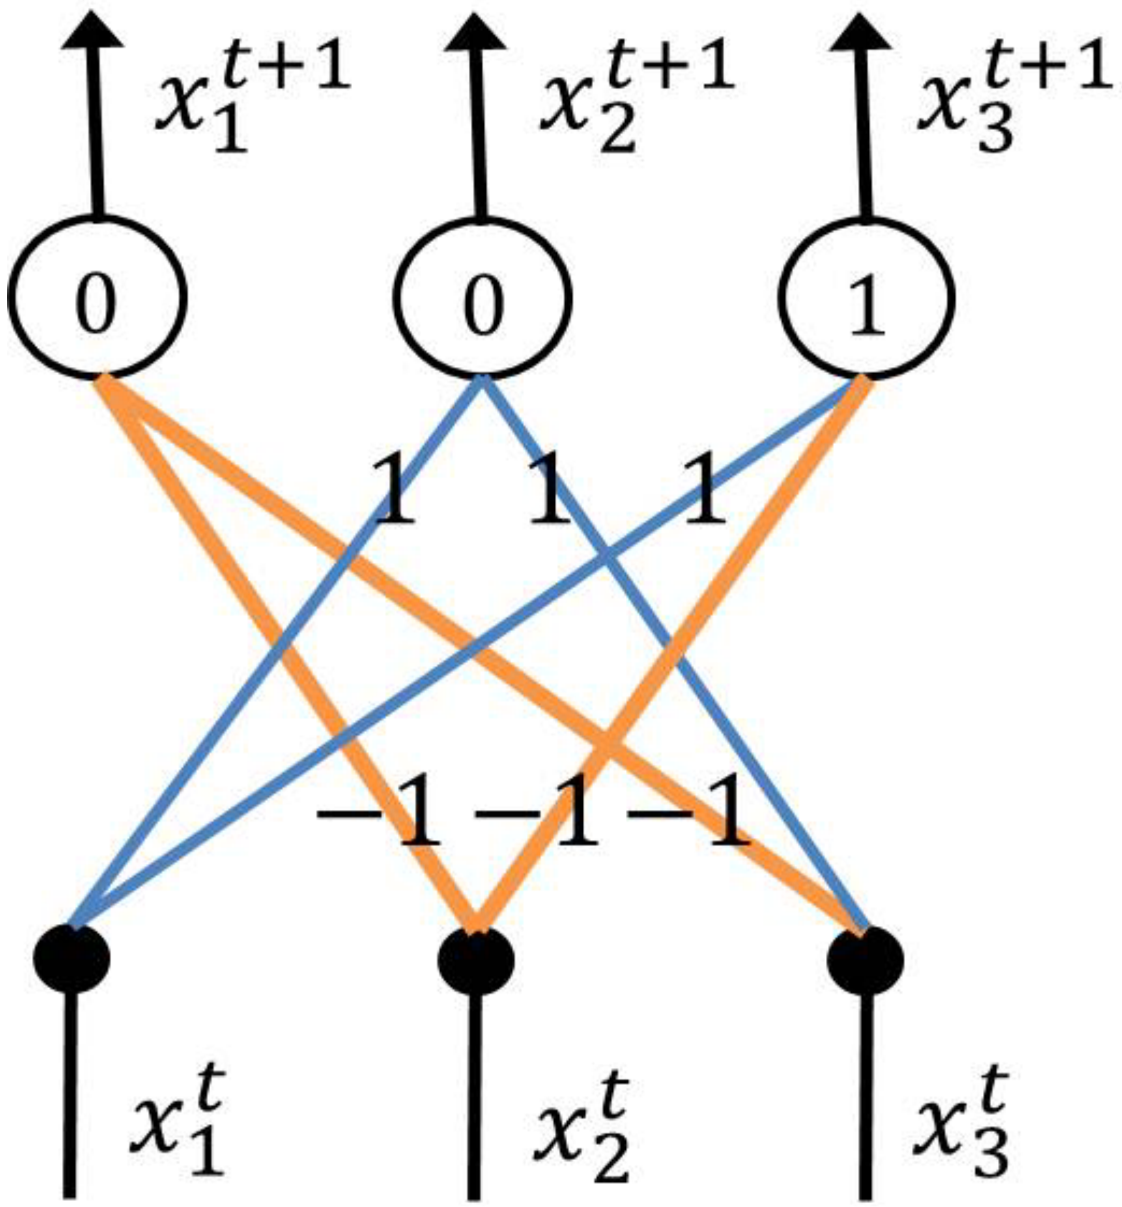

図 2.1: SDNN の例

橙と青の線はそれぞれ $w_{ij} = -1$、$w_{ij} = 1$ の接続を表す。$w_{ij} = 0$ は接続されていないことを意味する。しきい値パラメータは円の中の値である。

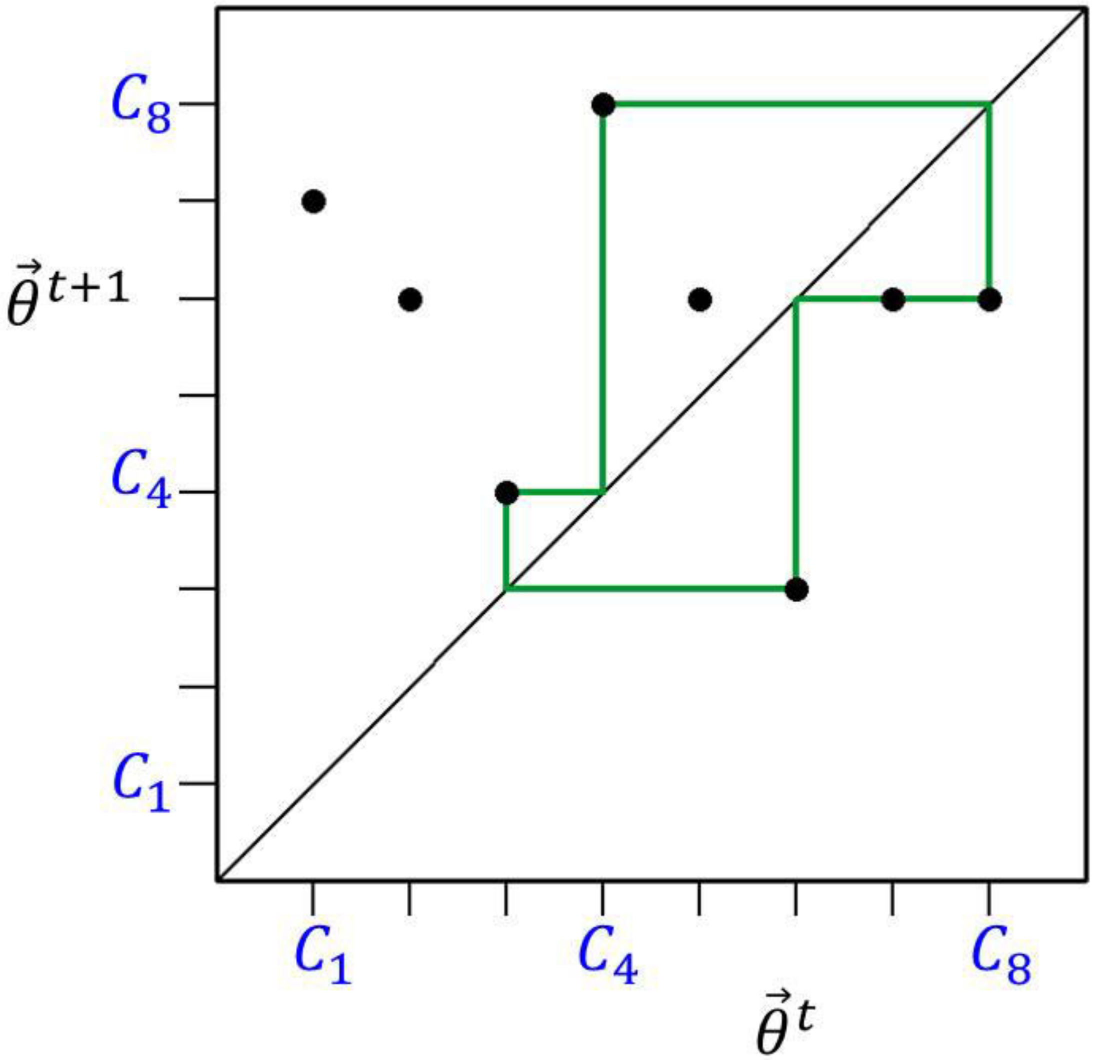

図 2.2: Gmap の例
図 2.1 の SDNN の Gmap。$F_G(C_1) = C_7$、$F_G(C_2) = C_6$、$F_G(C_3) = C_4$、$\cdots$ というようになっている。この Gmap は $C_3 \to C_4 \to C_8 \to C_6 \to C_3$ という周期 4 の BPO を示している。他の格子点 C_1、C_2、C_5 そして C_7 は EPP であり、最終的に BPO に収束する。

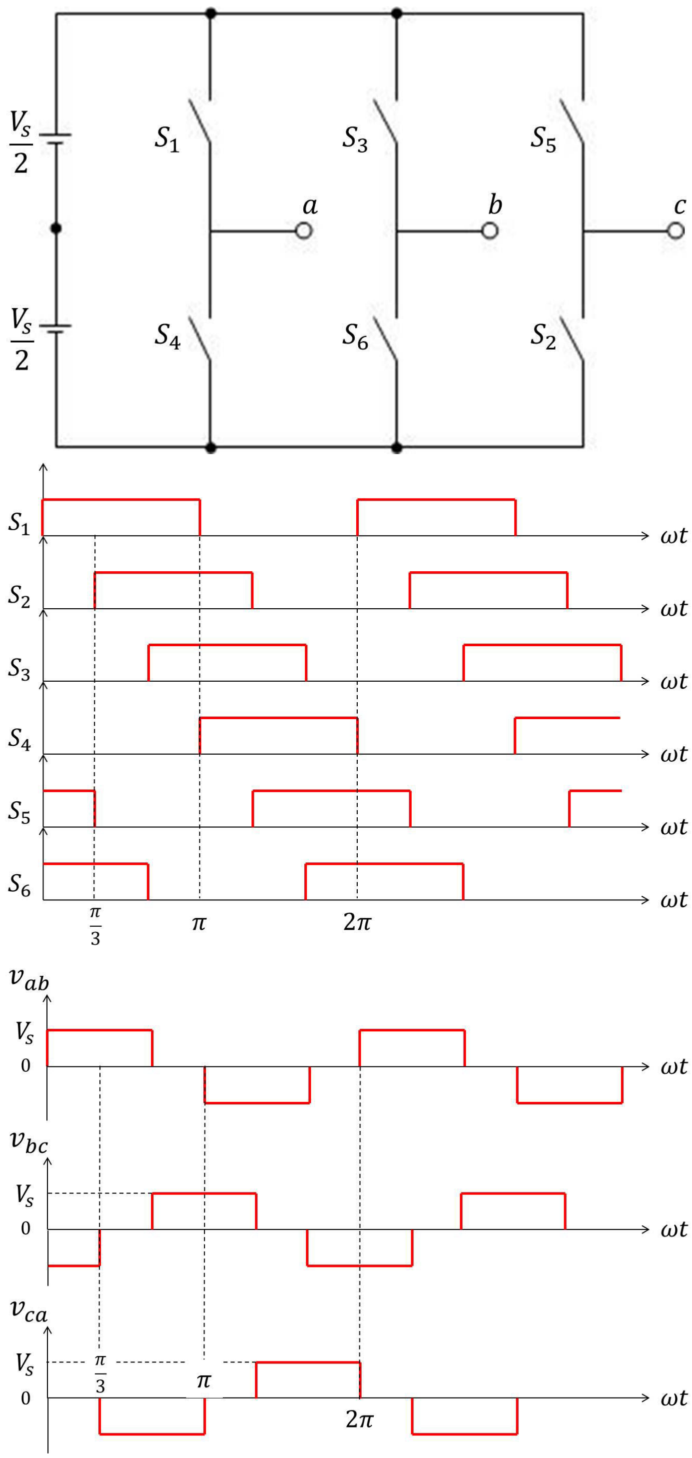

図 2.3: DC/AC インバータの回路図及び制御信号

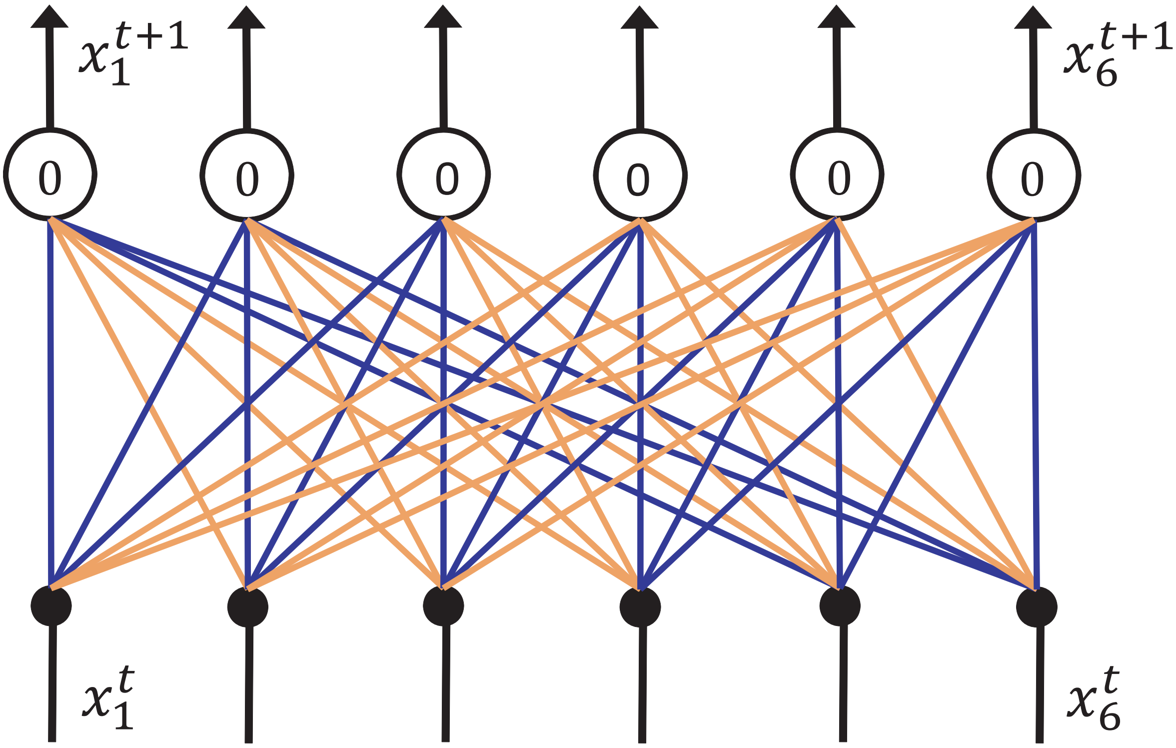

図 2.4: 相関学習に基づく学習後の例 1 の SDNN

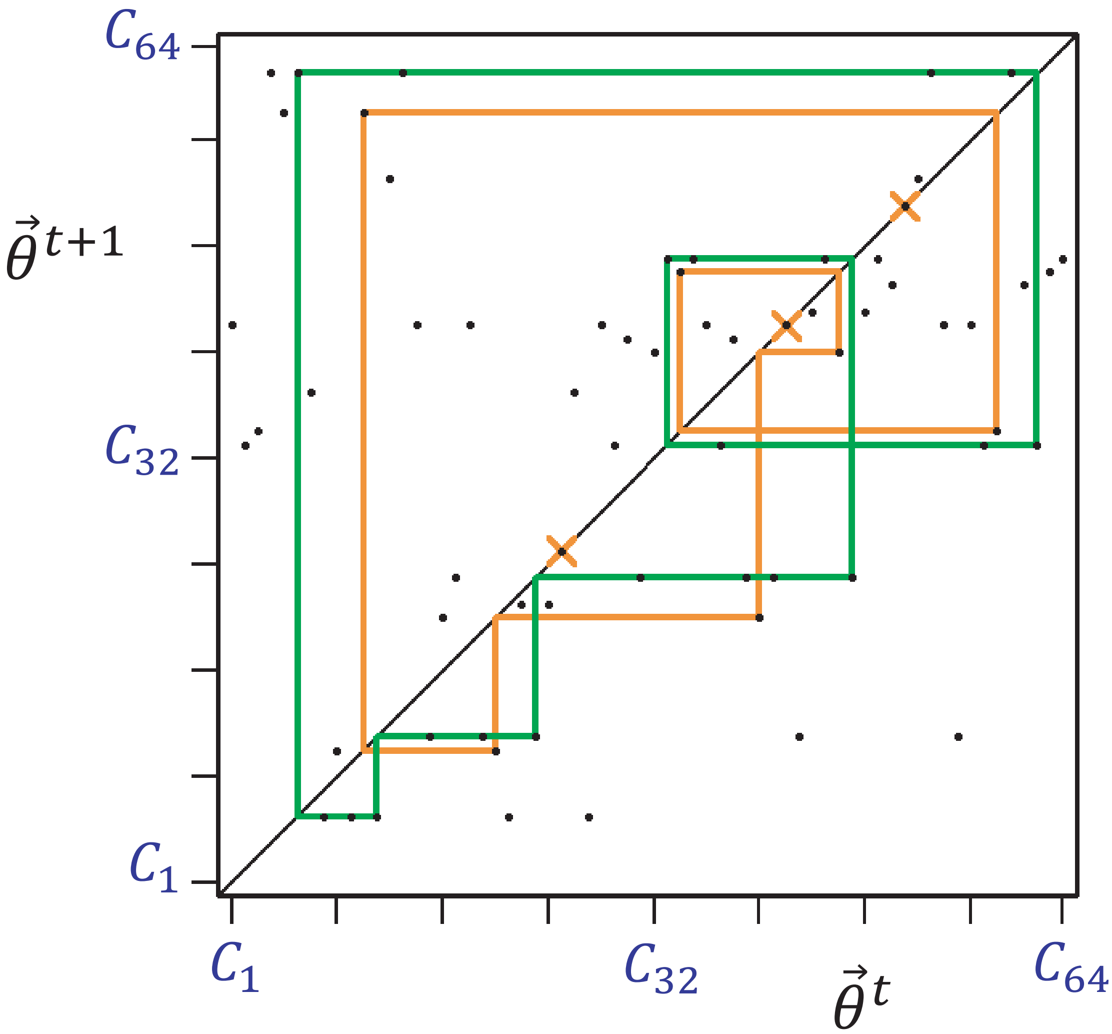

図 2.5: 相関学習に基づく学習後の例 1 の SDNN の Gmap
この Gmap では教師信号 BPO(緑の線) と他の BPO(橙の線)、および 3 点の不動点が存在している。

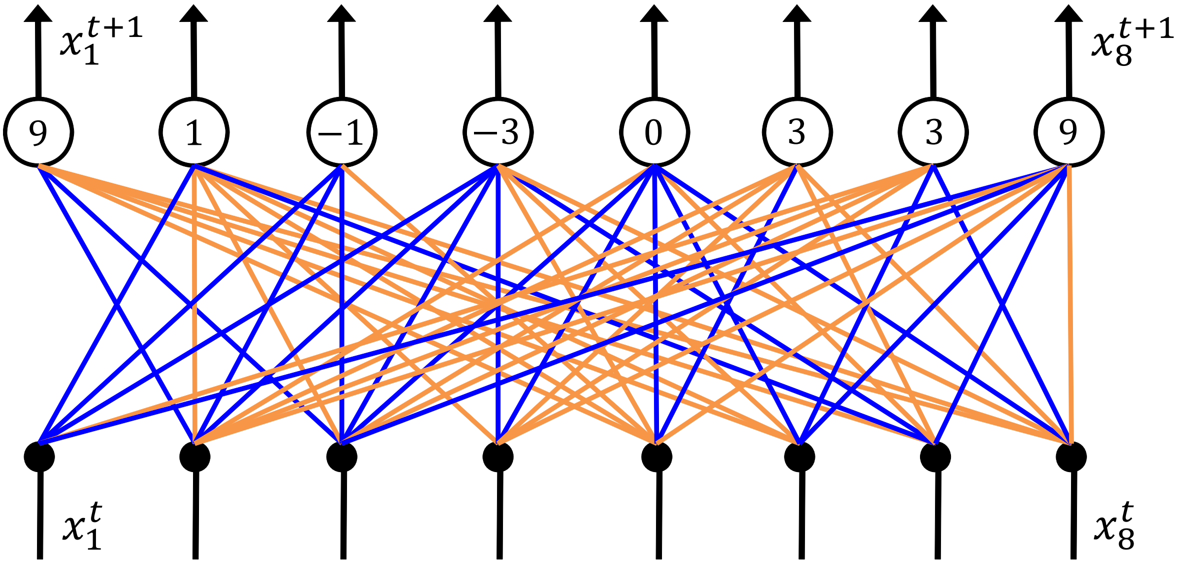

図 2.6: GA に基づく学習後の例 2 の SDNN($l = 178$)

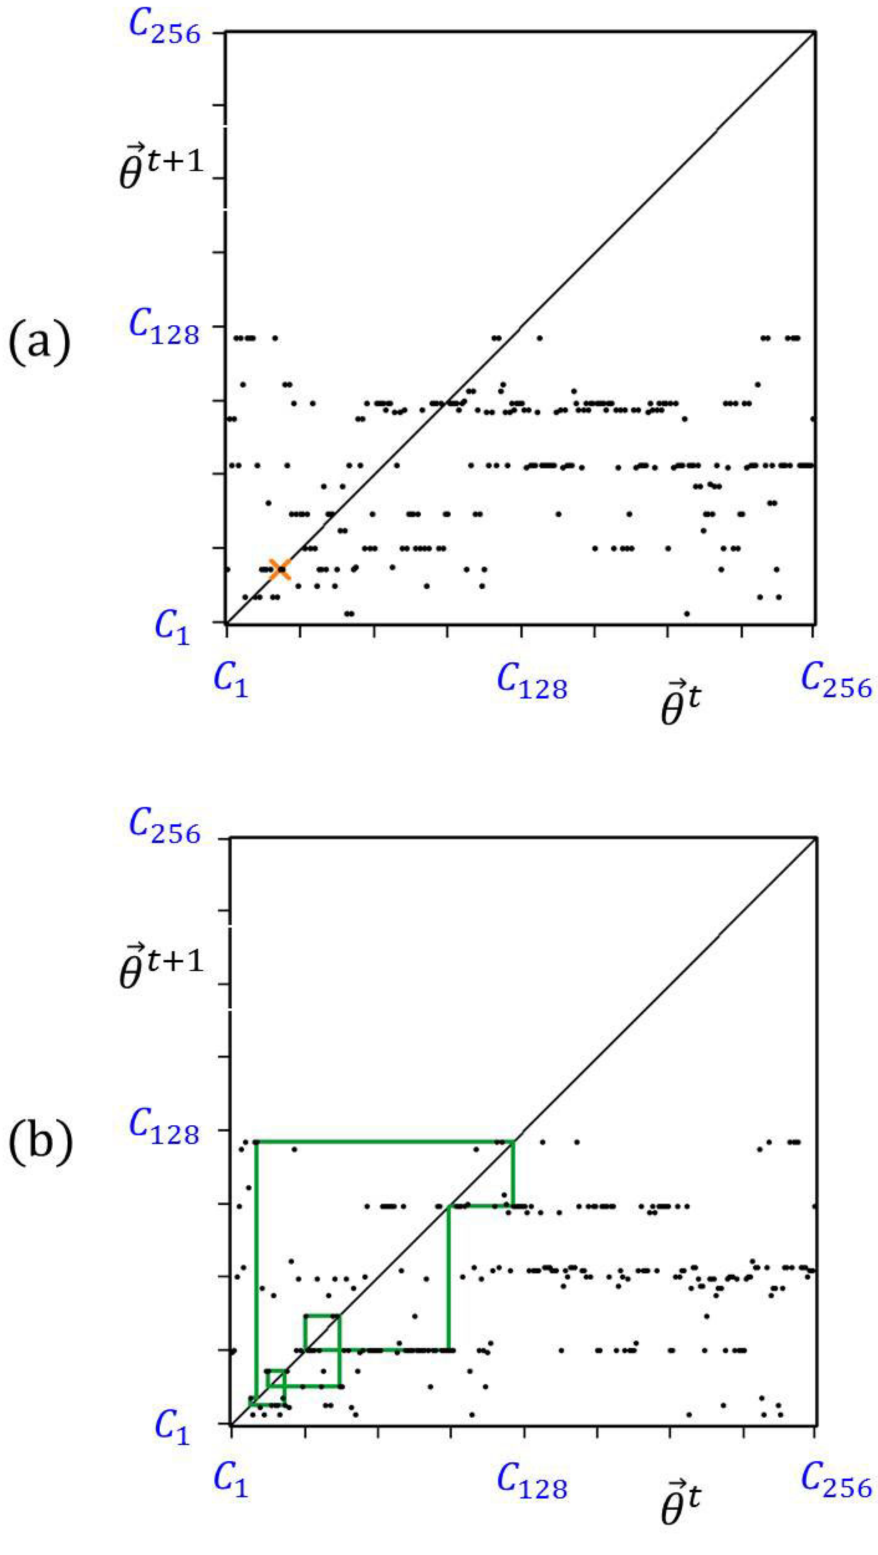

図 2.7: 例 2 の SDNN の Gmap
(a) 相関学習に基づく学習後 ($l = 0$) $CR = 0$、すなわち評価値は $F(\vec{C}^k(l)) = 0$ である。 (b) GA に基づく学習後 ($l = 178$) $CR = 1$、すなわち評価値は $F(\vec{C}^k(178)) = 1$ である。

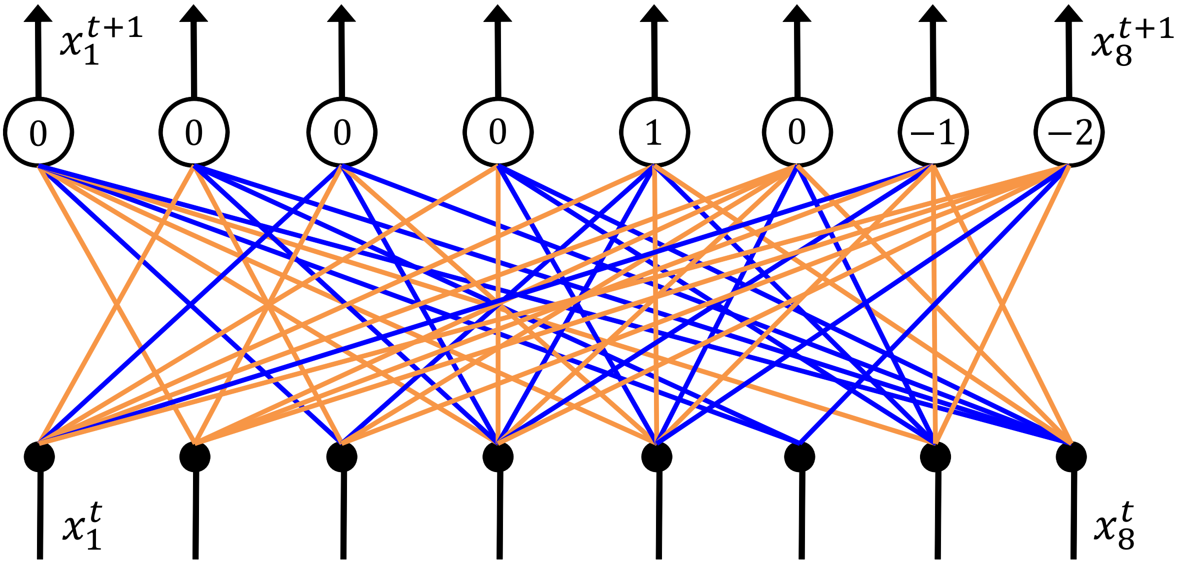

図 2.8: GA に基づく学習後の例 3 の SDNN($l = 205$)

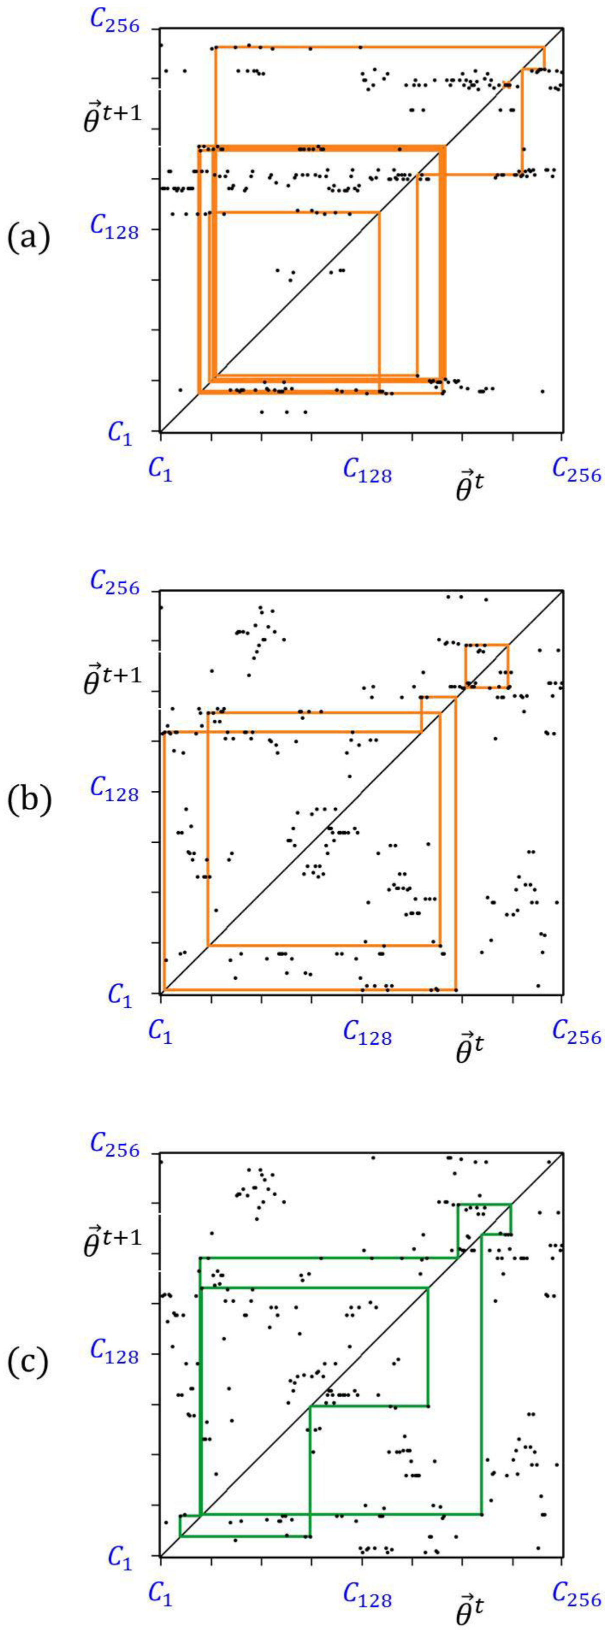

図 2.9: 例 2 の SDNN の Gmap
(a) 相関学習に基づく学習後 ($l = 0$)　$CR = 0$、すなわち評価値は $F(\vec{C}^k(l)) = 0$ である。　(b) 学習途中 ($l = 28$)　$CR = 0$、この時点で教師信号は埋め込めず　(c) GA に基づく学習後 ($l = 205$)　$CR = 1$、すなわち評価値は $F(\vec{C}^k(205)) = 1$ である。

表 2.1: 教師信号:例 1

$\boldsymbol{z}^1$	$(+1,-1,-1,-1,+1,+1)$
$\boldsymbol{z}^2$	$(+1,+1,-1,-1,-1,+1)$
$\boldsymbol{z}^3$	$(+1,+1,+1,-1,-1,-1)$
$\boldsymbol{z}^4$	$(-1,+1,+1,+1,-1,-1)$
$\boldsymbol{z}^5$	$(-1,-1,+1,+1,+1,-1)$
$\boldsymbol{z}^6$	$(-1,-1,-1,+1,+1,+1)$
$\boldsymbol{z}^7=\boldsymbol{z}^1$	$(+1,-1,-1,-1,+1,+1)$

表 2.2: 例 1：相関学習に基づく学習後のパラメータ

i	w_{i1}	w_{i2}	w_{i3}	w_{i4}	w_{i5}	w_{i6}	T_i
1	$+1$	-1	-1	-1	$+1$	$+1$	0
2	$+1$	$+1$	-1	-1	-1	$+1$	0
3	$+1$	$+1$	$+1$	-1	-1	-1	0
4	-1	$+1$	$+1$	$+1$	-1	-1	0
5	-1	-1	$+1$	$+1$	$+1$	-1	0
6	-1	-1	-1	$+1$	$+1$	$+1$	0

表 2.3: 教師信号:例 2

$\boldsymbol{z}^1$	$(-1,+1,+1,+1,-1,-1,-1,-1)$
$\boldsymbol{z}^2$	$(-1,-1,+1,+1,-1,-1,-1,-1)$
$\boldsymbol{z}^3$	$(-1,-1,+1,+1,+1,-1,-1,-1)$
$\boldsymbol{z}^4$	$(-1,-1,-1,+1,+1,-1,-1,-1)$
$\boldsymbol{z}^5$	$(-1,-1,-1,+1,+1,+1,-1,-1)$
$\boldsymbol{z}^6$	$(-1,-1,-1,-1,+1,+1,-1,-1)$
$\boldsymbol{z}^7$	$(-1,-1,-1,-1,+1,+1,+1,-1)$
$\boldsymbol{z}^8$	$(-1,+1,-1,-1,-1,+1,+1,-1)$
$\boldsymbol{z}^9 = \boldsymbol{z}^1$	$(-1,+1,+1,+1,-1,-1,-1,-1)$

表 2.4: 例 2:相関学習に基づく学習後のパラメータ

i	w_{i1}	w_{i2}	w_{i3}	w_{i4}	w_{i5}	w_{i6}	w_{i7}	w_{i8}	T_i
1	$+1$	$+1$	$+1$	-1	-1	0	$+1$	$+1$	9
2	$+1$	$+1$	-1	-1	-1	$+1$	$+1$	$+1$	-1
3	$+1$	$+1$	$+1$	0	-1	-1	$+1$	$+1$	-2
4	-1	$+1$	$+1$	$+1$	-1	-1	-1	-1	0
5	-1	-1	0	$+1$	$+1$	-1	-1	-1	3
6	0	-1	-1	-1	$+1$	$+1$	0	0	1
7	$+1$	0	-1	-1	$+1$	$+1$	$+1$	$+1$	1
8	$+1$	$+1$	$+1$	-1	-1	0	$+1$	$+1$	9

表 2.5: 例 2:GA に基づく学習後のパラメータ

i	w_{i1}	w_{i2}	w_{i3}	w_{i4}	w_{i5}	w_{i6}	w_{i7}	w_{i8}	T_i
1	0	$+1$	$+1$	0	-1	-1	-1	-1	9
2	$+1$	-1	-1	-1	-1	-1	$+1$	-1	1
3	$+1$	$+1$	$+1$	0	-1	0	0	0	-1
4	$+1$	$+1$	$+1$	$+1$	-1	-1	$+1$	-1	-3
5	0	-1	$+1$	$+1$	$+1$	$+1$	-1	$+1$	0
6	0	-1	-1	-1	$+1$	0	-1	-1	3
7	-1	-1	-1	-1	0	$+1$	0	$+1$	3
8	$+1$	-1	$+1$	-1	-1	$+1$	$+1$	-1	9

表 2.6: 教師信号:例 3

$\boldsymbol{z}^1$	$(+1,-1,+1,-1,+1,-1,+1,-1)$
$\boldsymbol{z}^2$	$(-1,-1,-1,+1,-1,+1,+1,+1)$
$\boldsymbol{z}^3$	$(+1,+1,+1,+1,+1,+1,+1,+1)$
$\boldsymbol{z}^4$	$(-1,+1,+1,+1,-1,-1,-1,-1)$
$\boldsymbol{z}^5$	$(-1,-1,-1,-1,+1,-1,+1,-1)$
$\boldsymbol{z}^6$	$(-1,-1,-1,+1,-1,+1,-1,+1)$
$\boldsymbol{z}^7$	$(+1,+1,+1,-1,-1,-1,+1,+1)$
$\boldsymbol{z}^8$	$(+1,-1,+1,+1,-1,-1,-1,-1)$
$\boldsymbol{z}^9=\boldsymbol{z}^1$	$(+1,-1,+1,-1,+1,-1,+1,-1)$

表 2.7: 例 3:相関学習に基づく学習後のパラメータ

i	w_{i1}	w_{i2}	w_{i3}	w_{i4}	w_{i5}	w_{i6}	w_{i7}	w_{i8}	T_i
1	0	-1	-1	$+1$	-1	$+1$	-1	$+1$	-2
2	-1	0	-1	$+1$	0	$+1$	0	$+1$	0
3	$+1$	0	0	$+1$	-1	$+1$	0	$+1$	0
4	$+1$	0	0	-1	$+1$	0	$+1$	$+1$	-2
5	-1	0	0	$+1$	-1	0	-1	-1	$+2$
6	-1	-1	-1	-1	$+1$	0	$+1$	-1	0
7	-1	-1	0	$+1$	-1	0	-1	-1	-1
8	-1	-1	-1	-1	$+1$	$+1$	$+1$	0	0

表 2.8: 例 3:GA に基づく学習後のパラメータ

i	w_{i1}	w_{i2}	w_{i3}	w_{i4}	w_{i5}	w_{i6}	w_{i7}	w_{i8}	T_i
1	0	0	-1	-1	-1	$+1$	-1	$+1$	-2
2	-1	0	-1	$+1$	0	$+1$	0	$+1$	0
3	$+1$	0	0	$+1$	-1	$+1$	0	$+1$	0
4	$+1$	0	0	-1	0	-1	$+1$	$+1$	-1
5	-1	0	$+1$	$+1$	-1	0	0	-1	$+1$
6	-1	-1	-1	-1	$+1$	0	$+1$	-1	0
7	-1	-1	$+1$	0	-1	0	-1	-1	0
8	-1	-1	-1	-1	$+1$	0	0	0	-1

第3章　3層動的バイナリーニューラルネットワーク:周期系列の銘記と安定化

3.1　まえがき

3 層動的バイナリーニューラルネットワーク (DBNN) は、シグナム関数と 3 値重みパラメータを有する 3 層のフィードフォワード型のバイナリーニューラルネットワーク (BNN) に遅延フィードバックを適用することによって構成される。DBNN は、中間層のニューロン数が十分であれば、任意のブール関数を実現できる。DBNN は、パラメータと初期値に依存して、様々な 2 値周期軌道 (BPO) を呈することができる。また、DBNN は様々な工学系応用が可能である。その例としては、信号処理や回路制御等が挙げられる。しかしながら、これらの DBNN は取り扱う問題の規模により中間層ニューロン数の増加や、計算コストの上昇などの問題点を抱えている。

これらの問題を解決するために、いくつかの学習法が提案されてきた。本論文では、中間層ニューロン数を固定した状態での DBNN の学習について考察する。この DBNN は、シグナム活性化関数を有し、荷重パラメータを 3 値、しきい値パラメータを整数としている [14] [20]。DBNN は 2 値パターンやデジタル回路による実装の実現に適している。

DBNN の動作を視覚化するために、グレイコード表示のリターンマップである Gray-code Based Return Map (Gmap) を用いる。DBNN は N 次元格子点上の 2 値ベクトルを扱うので、ダイナミクスを格子点上のマップに表すことができる。グレイコード表示を格子点に適用することで、Gmap を得ることができる。Gmap は BPO やそれらの収束領域のような基本特性を把握するのに有用である。学習では、学習させる教師信号

を用いて重みパラメータを理論的に決定することで、教師信号を DBNN に埋め込む。その後、教師信号への安定性の向上のために、遺伝的アルゴリズム (GA) に基づくスパース化学習を行う。学習アルゴリズムの機能を調べるために、基本的な BPO の教師信号による数値実験を行い、所望の BPO の埋め込みとその BPO の安定性について検討する。

3.2 3 層 DBNN

DBNN は図 3.1 に示す 3 層構造のネットワークに遅延フィードバックを適用することうに記述される。

$$
\begin{aligned}
x_i^{t+1} &= f\left(\sum_{j=1}^{N} w_{ij}^o \xi_j^t - T_i^o\right),\ i = 1 \sim N \\
\xi_j^{t+1} &= f\left(\sum_{i=1}^{N} w_{ji} x_i^t - T_j\right),\ j = 1 \sim M \\
f(x) &= \begin{cases} 1 & \text{for } x \geq 0 \\ -1 & \text{for } x < 0 \end{cases}
\end{aligned}
\tag{3.1}
$$

ただし、 $\boldsymbol{x}^t = (x_1^t, \cdots, x_N^t)$ 、 $x_j^t \in \{-1, 1\} \equiv B$ は離散時間 t における N 次元の 2 値ベクトルである。また、 $\boldsymbol{\xi}^t \equiv (\xi_1^t, \cdots, \xi_N^t)$ 、 $\xi_j^t \in \{-1, 1\}$ は t での M 次元中間出力ベクトルである。式 (3.1) を次式で略記する。

$$
\boldsymbol{x}^{t+1} = \boldsymbol{F}_D\left(\boldsymbol{x}^t\right),\ \boldsymbol{F}_D : B^N \rightarrow B^N \tag{3.2}
$$

中間層ニューロンは 3 値の荷重パラメータ w_{ji} 及び整数のしきい値パラメータ T_j で特徴づけられる:

$$
\begin{aligned}
w_{ji} &=\in \{-1, 0, 1\} \\
T_j &= \text{Integer}
\end{aligned}
\tag{3.3}
$$

ただし、$i = 1 \sim N, j = 1 \sim M$ は中間層ニューロン数 M を制御する内部パラメータである。同様に出力層ニューロンは 2 値の荷重パラメータ w_{ji}^o としきい値パラメータ T_i^o で特徴づけられる。

3.3 学習アルゴリズム

次に教師信号が次式で示すような周期 T の BPO である場合を対象として、中間層ニューロン数を固定した状態での DBNN の学習の問題を考える。

$$\boldsymbol{z}^1, \cdots, \boldsymbol{z}^T, \boldsymbol{z}^{T+1} = \boldsymbol{z}^1,\ \boldsymbol{z}^t = (z_1^t, \cdots, z_N^t) \tag{3.4}$$

ここで、教師信号を構成する z_j^t と z_j^{t+1} は DBNN の変数 x_j^t と x_j^{t+1} に各々対応する。学習の目的は、教師信号を埋め込む重みパラメータとしきい値パラメータを探すことである。本論文では重みパラメータの初期値について、以下の式 (3.5) のように w_{ji} は教師信号の入力 z_i^j を、w_{ij}^o は教師信号の出力 z_i^{j+1} を代入する。

$$w_{ji} = z_i^j,\ w_{ij}^o = \begin{cases} 1 & \text{if } z_i^{j+1} = 1 \\ 0 & \text{if } z_i^{j+1} = -1 \end{cases} \tag{3.5}$$

この様にして決めた重みパラメータで教師信号を埋め込む場合、しきい値パラメータを以下の式 (3.6) により決めることで埋め込みが保証される。ここで、しきい値パラメータ T_j は式 (3.6) によって得られる値において、2 番目に大きい値とする:

$$\begin{aligned} T_j &= \sum_{i=1}^{N} w_{ti} z_i^j + 1,\ j \neq t,\ t = 1 \sim N \\ T_i^o &= 1 - \sum_{j=1}^{M} |w_{ji}^o| \end{aligned} \tag{3.6}$$

これに対して、教師信号への収束率の大きい重みパラメータ w_{ji} を学習によって決定する。その方法として、スパース化を用いた安定化手法を考える。

スパース化を用いた学習

教師信号への収束率の大きい重みパラメータ w_{ji} の決定ために、GA に基づく学習を使ってスパース化を行う。同アルゴリズムでは、3 値重みパラメータ w_{ji} で構成される N 個の要素からなるベクトルを染色体とする。

Step1:(初期遺伝子の決定)

k をある染色体の番号とし、t 番目の初期染色体を手動で生成した重み値パラメータ行列 $w_{ji}(k)$ とする。初期染色体の値は教師信号を重みパラメータに代入したものとする。このような染色体を Ge 個用意する。進化過程では、評価の高い上位 1 割の染色体は保

存することとする。便宜上、その染色体を 1 番目 ($k = 1$) の染色体とする。また、g を現在の世代数とし、最大世代数を G_{max} とする。

Step2:(探索対象の決定)

現在の各染色体の持つ重みパラメータ行列 w_{ji} から得られる BPO の中に教師信号の点を多く含む染色体を探索対象とする。

Step3:(評価・並び替え)

Ge 個の染色体それぞれについて、染色体の w_{ji} から得られた DBNN が持つ BPO に含まれる教師信号へ 1 離散時間で落ち込む初期値の割合 (CR) が多い順に染色体を並べ替える。CR は以下の式 (3.7) で定義される:

$$\mathrm{CR} = \frac{\#(1\text{ 離散時間で教師信号に落ち入る初期値})}{2^N} \tag{3.7}$$

Step4:(淘汰・増殖)

上位 1 割の染色体を次世代へ残す。また、DBNN の持つ BPO に教師信号 BPO が含まれない染色体は淘汰し、上位 1 割の染色体を淘汰した数だけ増殖する。

Step5:(GA に基づく探索)

Ge 個の染色体について、GA を用いて全ての入力が教師信号により多く収束するようなネットワークとなる染色体を決定する。下位 9 割の染色体の全ての要素 w_{ji} について突然変異確率 Pm に従い、1 または -1 の要素には 0 の値を代入し、0 の要素には式 (3.5) の値を代入する。

尚、この学習では交叉を用いないものとする。

Step6:(終了判定)

$g = g + 1$ とし、Step3 へ戻る。g が最大世代数となったら学習終了となる。

3.4 数値実験

GA の学習性能を検証するために、N 次元 M 周期の教師信号を用いて学習を行った。この実験では各パラメータを以下のように設定する。

$$(G_{max}, G_e, P_m) = (100, 100, 0.1) \tag{3.8}$$

この実験で用いた教師信号は、３相交流電圧を別な周波数、大きさの３相交流電圧に変換する、マトリクスコンバータのスイッチングパターンである BPO(表 3.1) を用いる

この教師信号について学習を行った。図 3.4 に GA に基づく学習を行う前の DBNN に対応する GMAP を示す。

図 3.4 において、CR は初期状態において 14%となった。またこの図におけるその他の入力は全て不動点 0 に収束していることがわかった。続いて、GA に基づく学習結果を示す。表 3.3 は GA に基づくスパース化学習の結果の重みパラメータ w_{ji} である。この学習結果の DBNN に対応する GMAP を図 3.5 に、図 3.6 に GA に基づくスパース化学習の学習過程を示す。GA に基づく学習を行った結果、例１において図 3.5 では CR が 78%となり、図 3.6 からもわかる通り CR の上昇が起きていることからこの学習が機能していることがわかる。また、この学習の結果から得られた軌道では不動点 0 に収束する初期値が 22%残っていることがわかる。ここでもう一つの学習結果の例として例２を以下に示す。表 3.4 は GA に基づくスパース化学習の結果の重みパラメータである。この学習結果の DBNN に対応する GMAP を図 3.7 に、図 3.8 に GA に基づくスパース化学習の学習過程を示す。

例２において、図 3.7 では CR が 61%となり、図 3.8 から収束率の上昇が起きていることからこの学習が機能していることがわかる。また、例２の結果から得られた軌道では不動点が教師信号 BPO とは別に２つ現れており、そちらへ収束する割合は 39%ということがわかる。

考察

例１、例２より重みパラメータをスパース化することで安定性の向上が見られた。このことから、教師信号を初期重みパラメータとした場合、不要な結合が多く存在し、そ

れらを切り離すことで安定化したと考えられる。

3.5 むすび

本章では、DBNN における中間層数を固定した状態での GA に基づく学習について考察した。それらによって得られる DBNN のダイナミクスを系統的に解析するために、GMAP を導入した。GMAP を用いることで、DBNN のダイナミクスを調べることができた。典型的な結果として、その教師信号 BPO を銘記することができ、教師信号以外の初期値から出発する信号の収束特性を確認することができた。GA に基づく学習により、教師信号への収束安定性の向上が確認することができた。

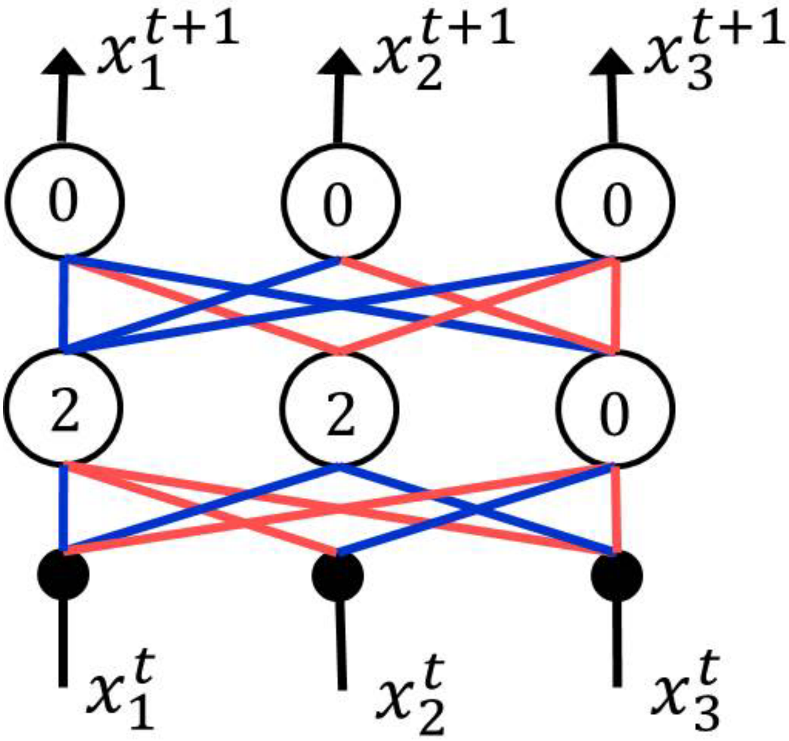

図 3.1: DBNN の例
青の線は $w_{ji} = 1$ 、赤の線は $w_{ji} = -1$ で繋がっていることを示す。また $w_{ji} = 0$ は線が繋がっていないことを示す。

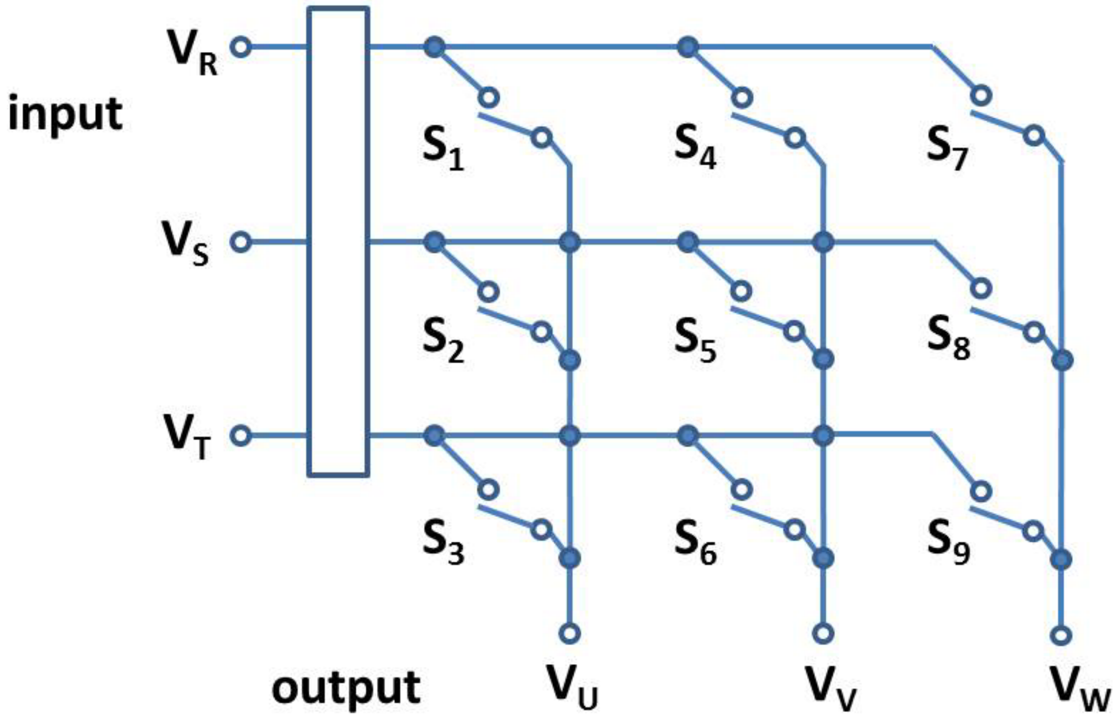

図 3.2: 回路図：マトリクスコンバータ

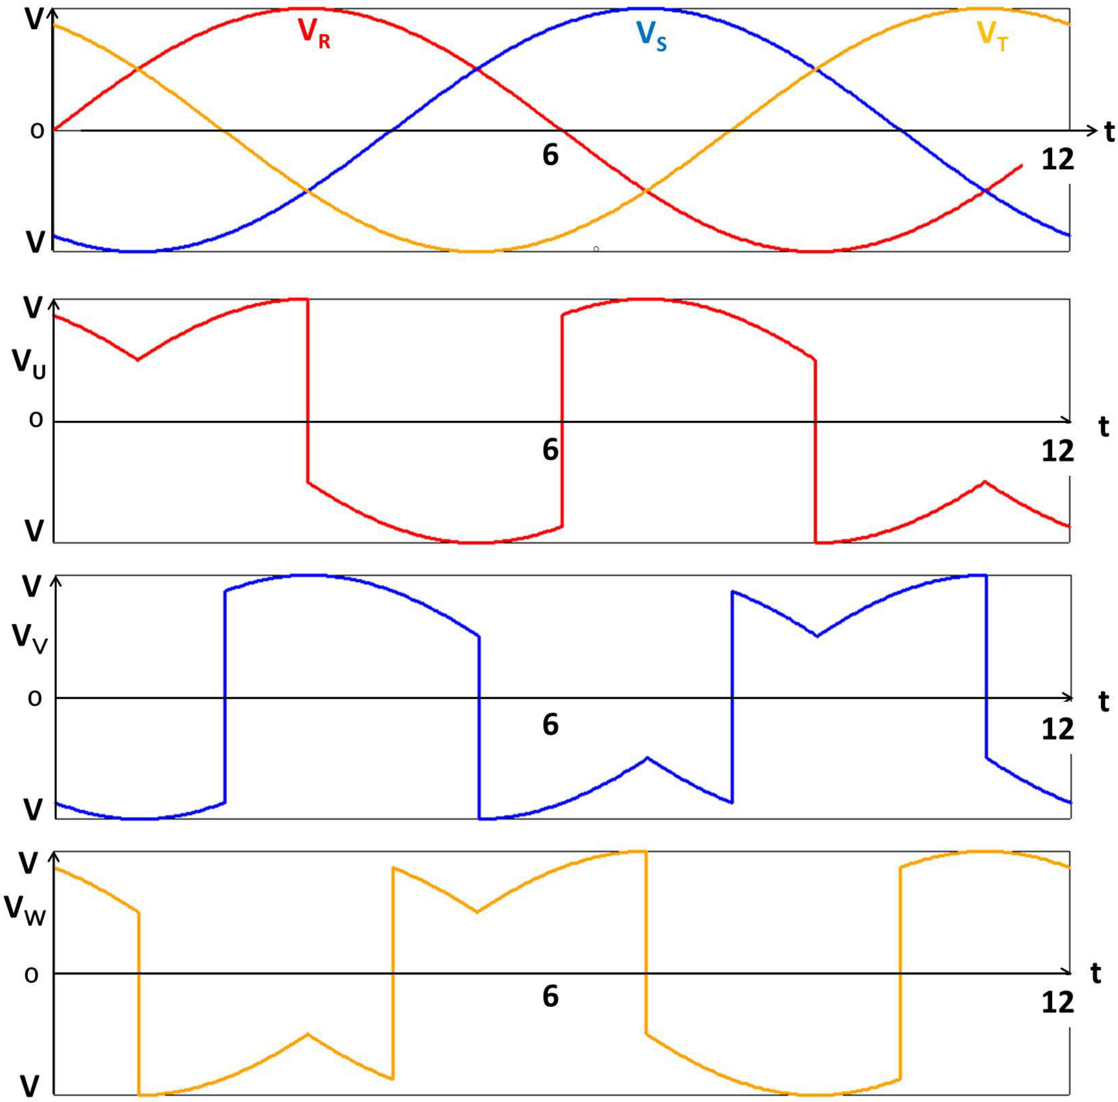

図 3.3: 出力波形：マトリクスコンバータ

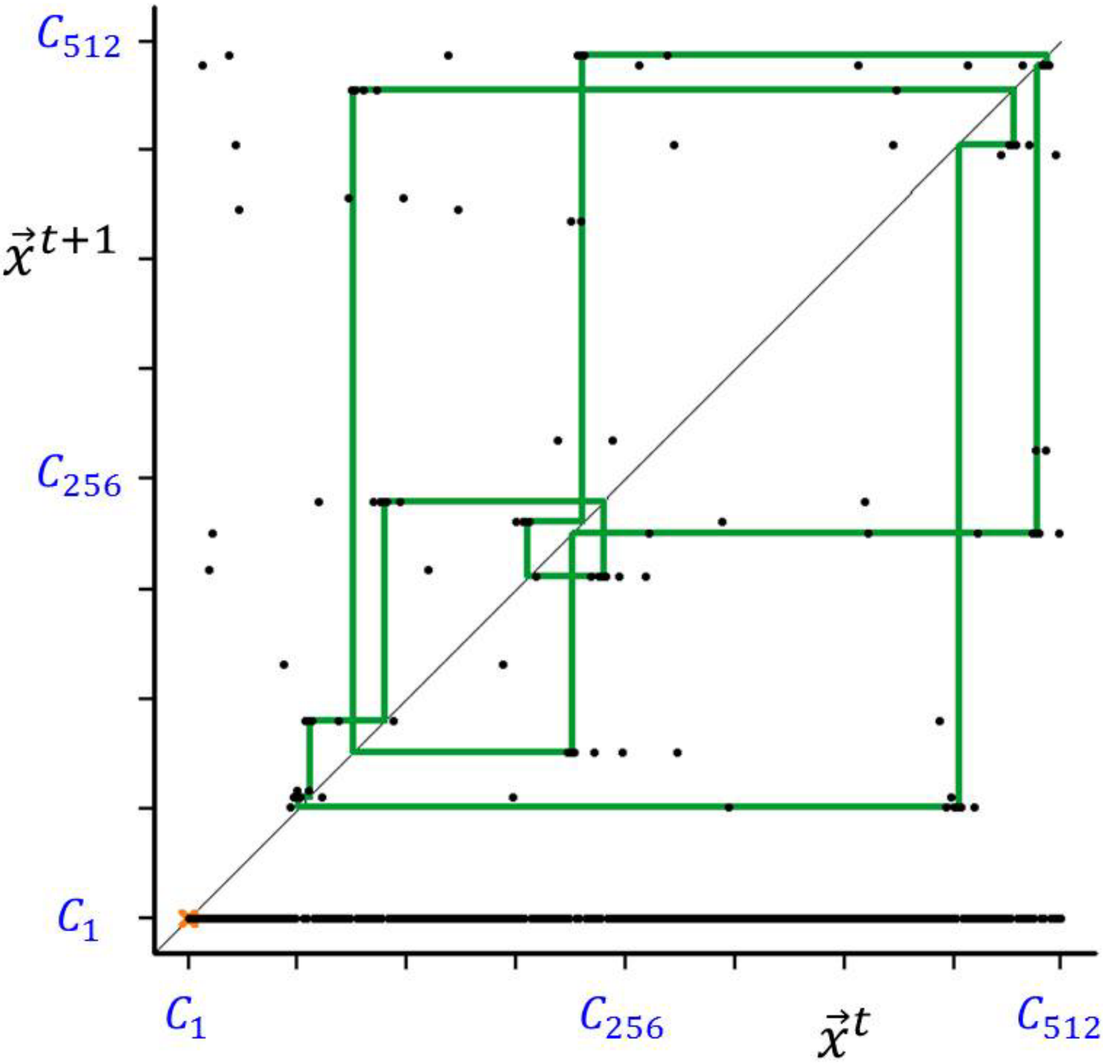

図 3.4: 教師信号 BPO のスパース化前の Gmap:g=0,CR=14%

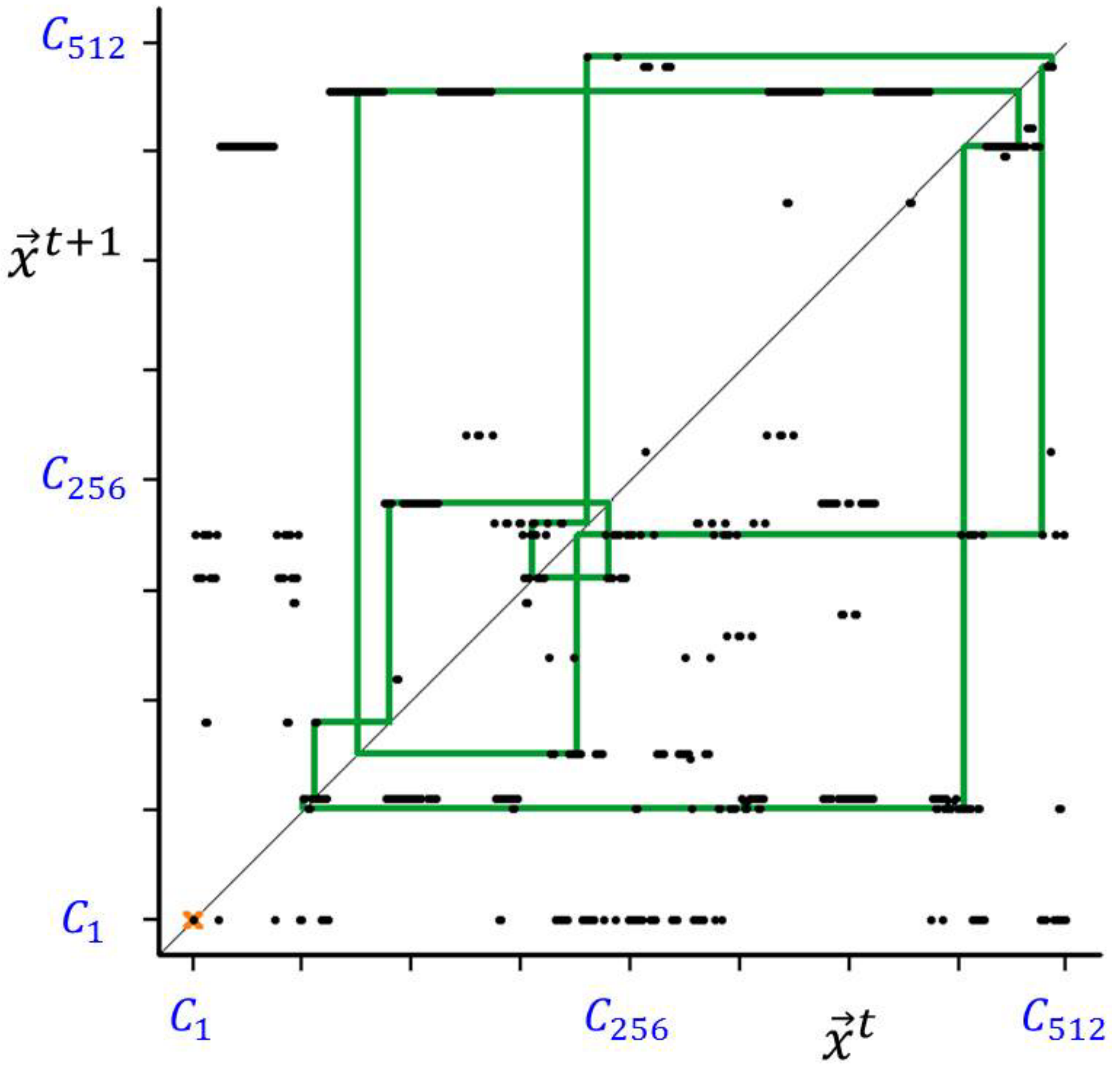

図 3.5: 例１：教師信号 BPO の GA に基づく学習後の Gmap:g=100,CR=78%

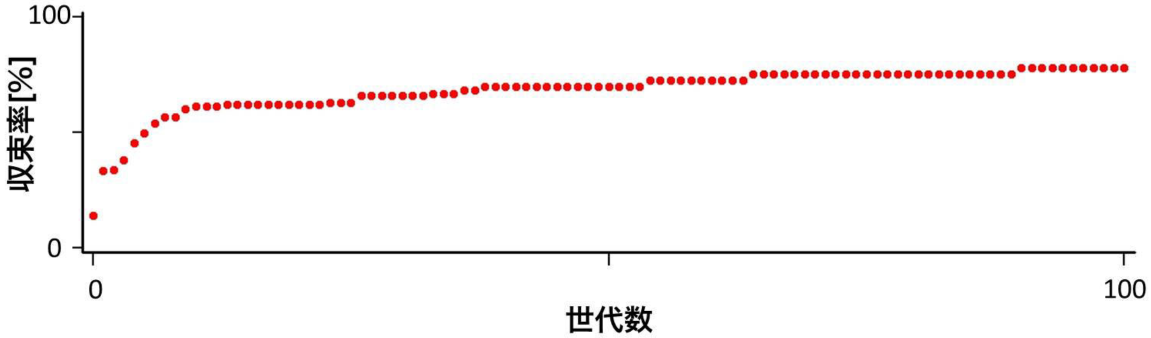

図 3.6: 例１：教師信号 BPO の GA に基づく学習過程

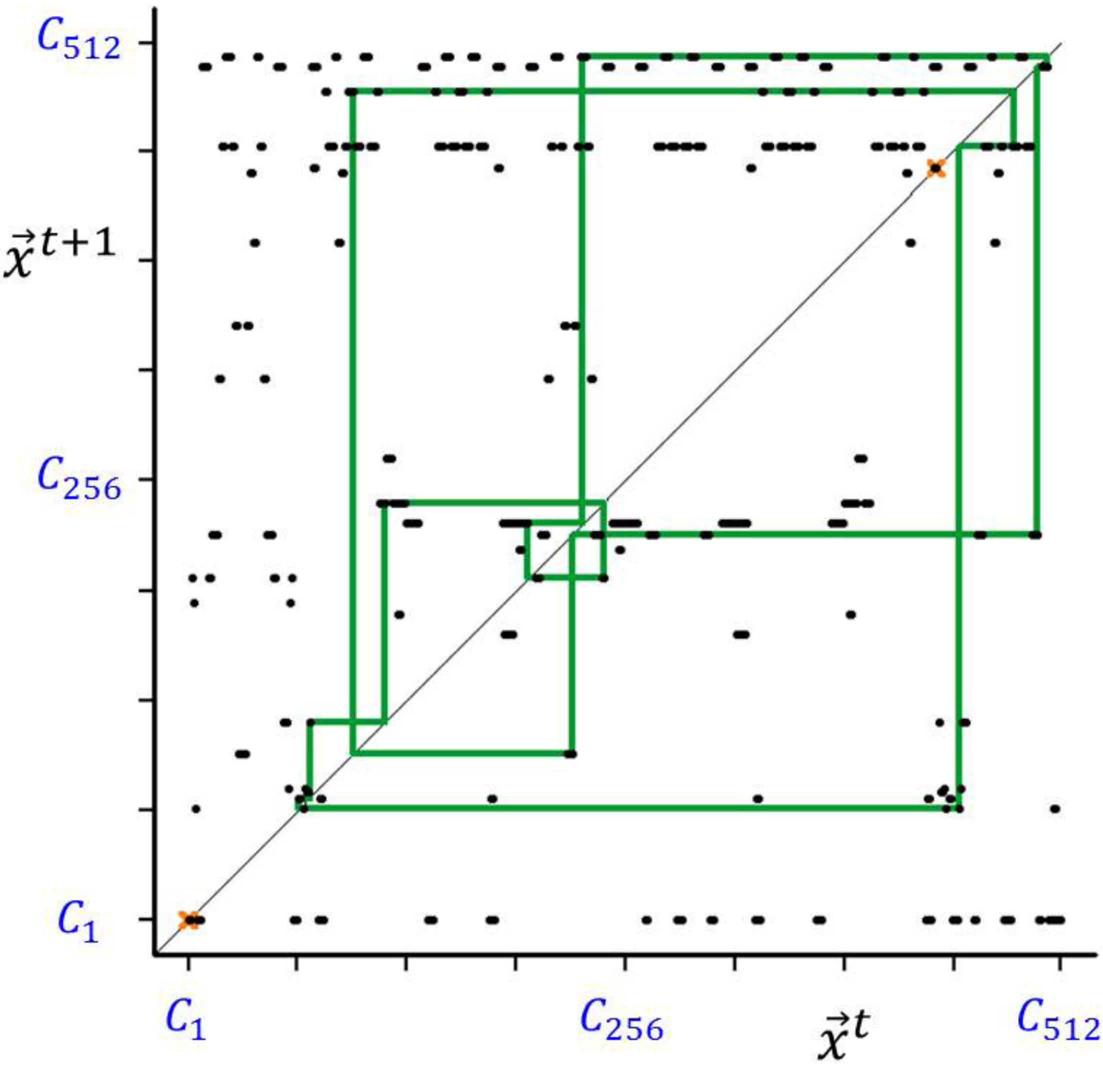

図 3.7: 例２：教師信号 BPO の GA に基づく学習後の Gmap:g=100,CR=61%

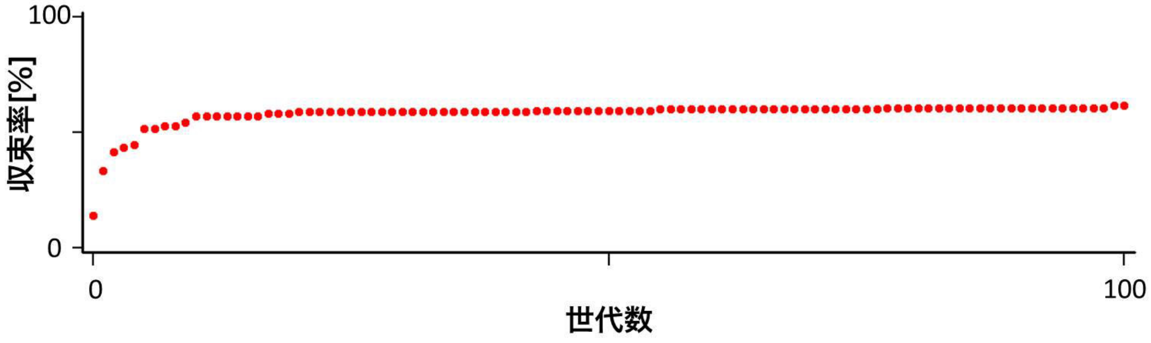

図 3.8: 例２：教師信号 BPO の GA に基づく学習過程

表 3.1: 教師信号 BPO

$\boldsymbol{z}(1)$	$(-1,-1,+1,-1,+1,-1,-1,-1,+1)$
$\boldsymbol{z}(2)$	$(+1,-1,-1,-1,+1,-1,-1,+1,-1)$
$\boldsymbol{z}(3)$	$(+1,-1,-1,+1,-1,-1,-1,+1,-1)$
$\boldsymbol{z}(4)$	$(-1,-1,+1,+1,-1,-1,-1,-1,+1)$
$\boldsymbol{z}(5)$	$(-1,-1,+1,+1,-1,-1,+1,-1,-1)$
$\boldsymbol{z}(6)$	$(-1,-1,+1,-1,-1,+1,-1,+1,-1)$
$\boldsymbol{z}(7)$	$(-1,+1,-1,-1,-1,+1,-1,+1,-1)$
$\boldsymbol{z}(8)$	$(-1,+1,-1,+1,-1,-1,+1,-1,-1)$
$\boldsymbol{z}(9)$	$(-1,+1,-1,-1,+1,-1,+1,-1,-1)$
$\boldsymbol{z}(10)$	$(+1,-1,-1,-1,-1,+1,+1,-1,-1)$
$\boldsymbol{z}(11)$	$(+1,-1,-1,-1,-1,+1,-1,-1,+1)$
$\boldsymbol{z}(12)$	$(+1,-1,-1,-1,-1,+1,-1,-1,+1)$

表 3.2: 例１：スパース化前の重みパラメータ w_{ji}

j	w_{j1}	w_{j2}	w_{j3}	w_{j4}	w_{j5}	w_{j6}	w_{j7}	w_{j8}	w_{j9}	T_j
1	-1	-1	$+1$	-1	$+1$	-1	-1	-1	$+1$	6
2	$+1$	-1	-1	-1	$+1$	-1	-1	$+1$	-1	6
3	$+1$	-1	-1	$+1$	-1	-1	-1	$+1$	-1	6
4	-1	-1	$+1$	$+1$	-1	-1	-1	-1	$+1$	6
5	-1	-1	$+1$	$+1$	-1	-1	$+1$	-1	-1	6
6	-1	-1	$+1$	-1	-1	$+1$	-1	$+1$	-1	6
7	-1	$+1$	-1	-1	-1	$+1$	-1	$+1$	-1	6
8	-1	$+1$	-1	$+1$	-1	-1	$+1$	-1	-1	6
9	-1	$+1$	-1	-1	$+1$	-1	$+1$	-1	-1	6
10	$+1$	-1	-1	-1	-1	$+1$	$+1$	-1	-1	6
11	$+1$	-1	-1	-1	-1	$+1$	-1	-1	$+1$	6
12	-1	$+1$	-1	-1	$+1$	-1	-1	-1	$+1$	6

表 3.3: 例１：学習後の重みパラメータ w_{ji}

j	w_{j1}	w_{j2}	w_{j3}	w_{j4}	w_{j5}	w_{j6}	w_{j7}	w_{j8}	w_{j9}	T_j
1	0	0	+1	0	+1	0	0	0	0	1
2	+1	0	0	−1	+1	0	0	0	0	2
3	0	−1	−1	+1	−1	0	0	+1	0	2
4	0	0	0	0	−1	−1	0	0	+1	2
5	−1	−1	0	+1	0	0	0	0	−1	3
6	−1	0	+1	0	0	0	0	+1	0	2
7	0	+1	0	0	0	0	0	+1	0	1
8	0	0	−1	0	−1	−1	+1	0	−1	4
9	−1	0	0	0	+1	0	0	0	−1	2
10	+1	0	0	0	0	0	+1	0	0	1
11	+1	0	0	0	0	+1	−1	−1	+1	2
12	−1	+1	0	0	+1	0	0	0	+1	3

表 3.4: 例２：学習後の重みパラメータ w_{ji}

j	w_{j1}	w_{j2}	w_{j3}	w_{j4}	w_{j5}	w_{j6}	w_{j7}	w_{j8}	w_{j9}	T_j
1	0	-1	$+1$	-1	0	0	0	-1	0	3
2	0	0	0	0	$+1$	0	0	$+1$	0	1
3	0	0	-1	$+1$	-1	0	0	$+1$	0	3
4	-1	-1	0	0	-1	-1	-1	0	0	4
5	0	-1	$+1$	0	0	-1	0	0	-1	3
6	-1	-1	0	0	0	0	0	$+1$	0	2
7	0	0	-1	-1	-1	0	0	$+1$	0	3
8	0	$+1$	0	0	-1	0	0	-1	0	2
9	-1	0	0	0	$+1$	0	0	0	-1	2
10	0	-1	-1	0	0	0	0	-1	-1	3
11	0	0	0	0	0	$+1$	-1	-1	0	2
12	0	$+1$	0	0	0	0	0	0	$+1$	1

第4章　むすび

本論文では、2層や3層のニューラルネットワークの入出力を2値としたDBNNについて研究を行った。学習アルゴリズムにはそれぞれが抱える問題に対処するため、相関学習に基づく学習法及びヒューリスティックなアルゴリズムであるGAに基づいたアルゴリズムを提案した。数値実験を行うことによって学習アルゴリズムの有効性を検証した。また、数値実験ではGmapによる安定性の確認を行った。さらに、実際に用いられている回路への適用も考察した。

第2章では、SDNNと相関学習に基づく学習について考察した。まず、系統的にSDNNのダイナミクスを解析するために、Gmapを導入した。学習アルゴリズムの性能は、3つの教師信号の例で検討を行った。この時、Gmapによる教師信号の記憶の確認と安定性の可視化を行った。AC-DCインバータの制御信号を相関学習に基づく学習法で記憶することが出来た。人工的な教師信号BPOでは、教師信号は相関学習に基づく学習法では記憶できなかったが、GAに基づく学習法で記憶することが出来た。この時、信号の大きさによって埋め込み成功率や自動安定化性能が変化することを確認した。

第3章では、DBNNにおける中間層数を固定した状態でのGAに基づく学習について考察した。GMAPを用いて、それらによって得られるDBNNのダイナミクスを系統的に解析した。典型的な結果として、その教師信号BPOを銘記することができ、教師信号以外の初期値から出発する信号の収束特性を確認することができた。GAに基づく学習により、教師信号への収束安定性の向上が確認することができた。全体の収束率ではなく、一回で教師信号に落ち入る初期値の数を評価関数としたことで、DBNNの符号誤り訂正能力の向上を検討した。スパース化学習により、不要な重みパラメータの切り離しを行い、自動安定化することが出来た。

今後の課題として、学習パラメータの改善、学習プロセスの解析、ダイナミクスの解析、安定化のメカニズムの解明等が挙げられる。また、ハード化も考えていく。

参考文献

[1] [Think IT] 第 1 回:ニューラルネットワークとは?
http://thinkit.co.jp/article/30/1/ (2014-2)

[2] D. E. Rumelhart, G. E. Hinton and R. J. Williams, Learning internal representations by error propagation. Parallel distributed processing: explorations in the microstructure of cognition, vol. 1, pp. 318-362, 1986.

[3] D. L. Gray and A. N. Michel, A training algorithm for binary feed forward neural networks. IEEE Trans. Neural Networks, 3, 2, pp. 176-194, 1992.

[4] J. H. Kim and S. K. Park, The geometrical learning of binary neural networks. IEEE Trans. Neural Networks, 6, 1, pp. 237–247, 1995.

[5] L. O. Chua, A nonlinear dynamics perspective of Wolfram's new kind of science, I, II, World Scientific, 2005.

[6] P. L. Rosin, Training cellular automata for image processing, IEEE Trans. Image Process., 15, 7, pp. 2076-2087, 2006.

[7] W. Wada, J. Kuroiwa, S. Nara, Completely reproducible description of digital sound data with cellular automata, Physics Letters A 306, pp. 110-115, 2002.

[8] K. Araki and T. Saito, An associative memory including time-variant self-feedback, Neural Networks, 7, 8, pp. 1267-1271, 1994.

[9] R. Ito and T. Saito, Dynamic Binary Neural Networks and Evolutionary Learning, Proc. of IEEE-INNS/IJCNN, pp. 1683-1687, 2010.

[10] R. Ito, Y. Nakayama and T. Saito, Analysis and Learning of Periodic Orbits in Dynamic Binary Neural Networks, Proc. IEEE-INNS/IJCNN, pp. 502-508, 2012.

[11] M. A. Boost and P. D. Zipgas, State-of-the-art carrier PWM techniques: a critical evaluation, IEEE Trans. Ind. Applicat., 24, pp. 271-280, 1988.

[12] B. K. Bose, Neural network applications in power electronics and motor drives - an introduction and perspective, IEEE Trans. Ind. Electron., 54, 1, pp. 14-33, 2007.

[13] J. J. Hopfield, Neural networks and physical systems with emergent collective computation abilities, Proceedings of the National Academy of Science, USA, 79, pp. 2554-2558 (1982)

[14] K. Nowara and T. Saito, Guaranteed storing of limit cycles into a discrete-time asynchronous neural network, Trans. IEICE, E75-A, 11, pp. 1579-1582, 1992.

[15] E. Ott, Chaos in dynamical systems, Cambridge Univ. Press, 1993.

[16] F. Chen, G. Chen, Q. He, G. He and X. Xu, Universal perceptron and DNA-like learning algorithm for binary neural networks: non-LSBF implementation, IEEE Trans. Neural Networks, 20, 8, pp. 1293-1301, 2009.

[17] A. Yamamoto and T. Saito, A flexible learning algorithm for binary neural networks, IEICE Trans. Fundamentals, E81-A, 9, pp. 1925-1930, 1998.

[18] Y. Nakayama, R. Ito and T. Saito, A Simple Class of Binary Neural Networks and Logical Synthesis, IEICE Trans. Fundamentals, E94-A, 9, pp. 1586-1589, 2011.

[19] R. Kouzuki, T. Suzuki and T. Saito, Learning of Periodic Attractors in Simple Dynamic Binary Neural Networks, Proc. of NDES, pp. 177-180, 2012.

[20] R. Kouzuki, and T. Saito, Learning of Simple Dynamic Binary Neural Networks, Trans. IEICE, E96-A, 8, pp. 1775-1782, 2013

研究業績

(論文)

R. Kouzki and T. Saito, ”Learning of Simple Dynamic Binary Neural Networks”, IEICE Trans. Fundamentals, E96-A, 8, pp. 1775-1782 (2013)

(国際会議)

R. Kouzki, T. Suzuki and T. Saito, ”Learning of Periodic Attractors in Simple Dynamic Binary Neural Networks”, Proc. of the 20th conference on Nonlinear Dynamics of Electronic Systems NDES 2012, pp. 245-248, Wolfenbüttel, Germany, (2012-7)

J. Moriyasu, R. Kouzki and T. Saito, ”Dynamic Binary Neural Networks and Storage of Control Signals for Switching Circuits”, Proc. of IEEE Asia Pacific Conference on Circuits and Systems, Kaohsiung, Taiwan, pp. 491-494, (2012)

Y. Nakayama, R. Kouzki and T. Saito, ”Application of the Dynamic Binary Neural Networks to Switching Circuits”, (M. Lee et al. ((Eds.): ICONIP 2013, Part II), LNCS 8227, pp. 697-704. Springer, (2013)

(国内発表)

上月良太, 伊藤良, 斎藤利通, ”空間的にルールを組み合わせたセルラーオートマトンについて”, 電子情報通信学会ソサイエティ大会, A-2-14, 北海道, (2011-9)

上月良太, 伊藤良, 斎藤利通, ”混合ルールに基づくセルオートマトンの動作解析”, 電子情報通信学会技術研究報告 (NLP 研究会), vol. 111, No. 395, pp.75-79, 福島, (2012-1)

上月良太, 斎藤利通, ”簡素な動的バイナリーニューラルネットワークの学習機能” 回路とシステムワークショップ論文集, pp. 235-238, 淡路島, (2012-7)

上月良太, 中山雄太, 斎藤利通, ”動的バイナリーニューラルネットの学習と応用”, 電子情報通信学会技術研究報告 (NC 研究会), vol. 112, No. 227, pp.85-89, 福岡, (2012-10)

上月良太, 斎藤利通, ”動的バイナリーニューラルネットの学習:所望の周期軌道の銘記とその安定性”, 電子情報通信学会技術研究報告 (NLP 研究会), vol. 112, No. 389, pp.165-168, 北海道, (2013-1)

上月良太, 中山雄太, 斎藤利通, ”簡動的バイナリーニューラルネットスイッチング回路への応用” 回路とシステムワークショップ論文集, pp. 309-312, 淡路島, (2013-7)

上月良太, 斎藤利通, ”動的バイナリーニューラルネット：周期系列の銘記と安定化”, 電子情報通信学会技術研究報告 (NLP 研究会), vol. 113, no. 225, pp. 45-49, 岐阜, (2013-9)

上月良太, 森安淳吾, 斎藤利通, ”3 層動的バイナリーニューラルネット:周期起動の埋込と安定化”, 電子情報通信学会総合大会, A-2-14, 新潟, (2014-3), submitted.

謝辞

本論文は著者が法政大学大学院工学研究科電気工学専攻に在学中の 2 年間、同大学理工学部電気電子工学科教授斎藤利通博士の指導下で行ったものである。研究活動を遂行するにあたり、同教授から懇切に御指導、御鞭撻下さった同博士に深謝致します。

最後に法政大学理工学部電気電子工学科斎藤利通研究室の皆様にはいろいろな有益な御討論・ご助言を戴きました。ここに深謝致します。