

法政大学学術機関リポジトリ

HOSEI UNIVERSITY REPOSITORY

PDF issue: 2025-03-14

動的バイナリーニューラルネットワークについて の基礎研究

伊藤, 良 / ITOH, Ryo

(発行年 / Year)

2012-03-24

(学位授与年月日 / Date of Granted)

2012-03-24

(学位名 / Degree Name)

修士(工学)

(学位授与機関 / Degree Grantor)

法政大学 (Hosei University)

2011年度 修士論文

論文題名 動的バイナリニューラルネットワークについての基礎研究

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： 10R3105

イトウ リョウ

氏名 伊藤 良

あらまし

本論文は、 N 次元の2値の動的バイナリニューラルネットワーク (DBNN) を提案する。DBNN はバイナリニューラルネットワーク (BNN) を基本としている。

BNN はマルチレイヤーパーセプトロン (MLP) を基本とした三層のフィードフォワード型のネットワークである。BNN は N 次元の2値入力、 M 次元の2値出力を有する。また、中間層ニューロンは3値であり、中間層ニューロンのしきい値パラメータは整数型である。BNN の基本的アルゴリズムを紹介し、計算機実験を行いアルゴリズムの有効性を確認する

DBNN のネットワーク構造は2値の N 入力 N 出力をもつ遅れフィードバック型である。DBNN はシグナム活性化関数を特性にもち、中間層での荷重パラメータは3値である。本稿では、効果的なネットワークを構造するために、GA を基にした学習アルゴリズムを提案する。また、GA の初期値パラメータを教師信号と一致させ、中間層ニューロンを共有することで中間層ニューロンの数を抑制する。

DBNN は異なる周期信号パターンを生成できる。その解析手法としてグレーコードを基にしたリターンマップ (Gmap) を紹介する。基本的な数値実験を通じてそのアルゴリズムの効果と自動安定化について確認する。また、音声データを用いた計算機実験を行い、Gmap による DBNN の特性について言及する。

Abstract

This paper presents dynamic binary neural networks (DBNN) of N -bit binary sequences. The DBNN is based on the binary neural network (BNN).

The BNN is a three-layer feed-forward artificial neural network based on the multi-layer perceptron. The BNN transforms N -dimensional binary input to M -dimensional binary output. The parameters are simplified the weighting in the hidden neuron is ternary and the threshold in the hidden neuron is integer. Performing basic numerical experiment, the algorithm efficiency is confirmed.

The DBNN is constructed by the delayed feedback of the N -bit output to the N -bit input. The DBNN has signum activation function and the weighting parameter in the hidden neuron is ternary. In order to approximate an objective teacher signal of binary sequence, we present a novel learning algorithm based on the genetic algorithm (GA). Using an efficient initial chromosome and hidden neuron sharing, we can reduce the number of hidden neurons and computation cost.

The DBNN can generate various periodic patterns. We introduce a systematic analysis tool: the Gray-code-based return map (Gmap). Performing basic numerical experiment, the algorithm efficiency and automatic stabilization are confirmed. We have also considered application of the GA-based learning and Gmap-based analysis to basic voice data.

目次

第1章	まえがき	7
第2章	バイナリーニューラルネットワーク (BNN)	10
2.1	バイナリーニューロン	10
2.2	バイナリーニューラルネットワーク (BNN)	11
2.3	BNN の学習アルゴリズム	12
2.4	計算機実験	20
第3章	動的バイナリーニューラルネットワーク (DBNN)	25
3.1	動的バイナリーニューラルネットワーク (DBNN)	25
3.2	DBNN の学習アルゴリズム	26
3.3	DBNN の解析手法 (Gmap)	33
3.4	計算機実験	36
3.4.1	インバータのスイッチ制御信号	36
3.4.2	DBNN の教師信号 (2)	37
3.4.3	DBNN の教師信号 (3)	37
3.4.4	DBNN の教師信号 (音声データ)	38
第4章	むすび	74
	参考文献	75
	研究業績	77
	謝辞	80

目 次

2.1	単一ニューロンのモデル図	15
2.2	単一ニューロンの動作図 (符号関数)	16
2.3	BNN の構造図	17
2.4	フローチャート (a) メインルーチン (b) GA サブルーチン	18
2.5	BNN の典型的な学習過程 ($N = 3$)	19
2.6	表 2.1 に対応する BNN ($N = 7$)	22
2.7	表 2.2 に対応する BNN (7 入力 1 出力を 7 回)	24
3.1	DBNN の構造図	30
3.2	表 3.1 に対する DBNN ($N = 3$) の構造図と分離超平面	32
3.3	DBNN ($N = 4$) の典型例	34
3.4	DBNN の Gmap ($N = 4$) の典型例	35
3.5	表 3.2 に対する DBNN (インバータのスイッチ制御信号)	41
3.6	図 3.5 対応する Gmap (インバータのスイッチ制御信号)	43
3.7	表 3.4 (教師信号 (2)) に対応する DBNN	45
3.8	表 3.4 (教師信号 (2)) に対応する DBNN ($l = 1$)	47
3.9	表 3.4 (教師信号 (2)) に対応する DBNN ($l = 2$)	48
3.10	表 3.4 (教師信号 (2)) に対応する DBNN ($l = 3$)	49
3.11	図 3.8 に対応する Gmap ($l = 1$)	50
3.12	図 3.9 に対応する Gmap ($l = 2$)	51
3.13	図 3.10 に対応する Gmap ($l = 3$)	52
3.14	表 3.6 (教師信号 (3)) に対応する DBNN ($l = 1$)	55

3.15 表 3.6 (教師信号 (3)) に対応する DBNN ($l = 2$)	56
3.16 表 3.6 (教師信号 (3)) に対応する DBNN ($l = 3$)	57
3.17 表 3.6 (教師信号 (3)) に対応する DBNN ($l = 4$)	58
3.18 図 3.14 に対応する Gmap ($l = 1$)	59
3.19 図 3.15 に対応する Gmap ($l = 2$)	60
3.20 図 3.16 に対応する Gmap ($l = 3$)	61
3.21 図 3.17 に対応する Gmap ($l = 4$)	62
3.22 音声データ	63
3.23 表 3.8 に対応する音声データの DBNN ($l = 1$)	66
3.24 表 3.8 に対応する音声データの DBNN ($l = 2$)	67
3.25 表 3.8 に対応する音声データの DBNN ($l = 3$)	68
3.26 表 3.8 に対応する音声データの DBNN ($l = 4$)	69
3.27 図 3.23 に対応する音声データの Gmap ($l = 1$)	70
3.28 図 3.24 に対応する音声データの Gmap ($l = 2$)	71
3.29 図 3.25 に対応する音声データの Gmap ($l = 3$)	72
3.30 図 3.26 に対応する音声データの Gmap ($l = 4$)	73

表 目 次

2.1	教師信号 ($N = 7$)	21
2.2	教師信号 ($N = 7$ を 7 回)	23
3.1	DBNN の教師信号 ($N = 3$)	31
3.2	インバータのスイッチ制御の教師信号	40
3.3	表 3.2 に対する学習後のパラメータ (インバータのスイッチ制御信号)	42
3.4	DBNN の教師信号 (2)	44
3.5	表 3.4 に対応する学習後のパラメータ (教師信号 (2))	46
3.6	教師信号 (3)	53
3.7	学習後のパラメータ (教師信号 (3))	54
3.8	教師信号 (音声データ)	64
3.9	学習後のパラメータ (音声データ)	65

第1章 まえがき

ニューラルネットワークは、脳の神経回路に見られるいくつかの特性を計算機上のシミュレーションによって表現することを目的とした数式モデルであり、数多くの研究がされている。単一の非線形素子であるニューロンをシナプスにより複数結合させることによりネットワークを構成する。これにより、関数を近似し、パターン認識や時系列予測などの情報処理に応用される。

ニューラルネットを利用したニューロンコンピュータは、高度な学習機能を持ち、自己組織化能力を有している。そのことにより、ノイマン型コンピュータの処理速度の限界などの欠点を補ったシステムの一つとして注目された。様々な種類の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 (MLP) がある。MLP は 1986 年ロメルハート & マッククレランドらに提案された入力層、中間層、出力層からなる 3 層のフィードフォワード型ネットワークである。また、そのニューロンの入出力には実数の信号を扱う。3 層構造のニューラルネットワークを考案することで、2 層構造のニューラルネットよりも情報処理能力を大幅に向上した。

MLP の学習アルゴリズムの代表にバックプロパゲーション (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、最急降下法を基本としており、教師信号が適切であれば、汎化能力を持つネットワークを構成できる。しかし、BP アルゴリズムは滑らかな非線形関数有するニューラルネットを対象としているので、2 値を入出力とするブール関数の近似には不適切である。また、近似が出来たとしても学習時間がかかる。そこで簡素な MLP として、入出力信号を 2 値のみとする N 入力 M 出力のバイナリニューラルネットワーク (BNN) が提案された。

BNN は $M = 1$ とすることにより所望のブール関数を実現できる。BNN の応用とし

ては、パターン分類、誤り修正コード、時系列予測、2値スイッチパターン生成などがある。しかしながら、BNNには取り扱う問題の規模に伴う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。BNNの学習方法の一つに近似解を探索する遺伝的アルゴリズム (GA) があり、それをを用いた学習方法が多く提案されており、有効性が示されてきた [1]-[9]。

2章ではBNNの紹介とその学習アルゴリズムを紹介する。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。しかしながら、BNNは主に N 入力 1 出力のネットワーク構造を有するものである。また、1次元出力のBNNについての研究は多少されているが、複数の出力についての研究はあまりされていない。 N 入力 1 出力のBNNを N 回繰り返すことによって様々な2値の信号パターンを生成できる。また、出力信号を入力信号へフィードバックさせることにより、BNNはさまざまな周期的な2値パターンを連続的な信号として生成することができる。

3章では、 N 入力 N 出力の動的バイナリニューラルネットワーク (DBNN) を紹介する。DBNNはBNNを基本とした N 入力 N 出力の遅れフィードバックをネットワーク構造にもつ。また、パラメータも簡素であり、入力信号、出力信号ともに"0"か"1"の2値のみで表され、中間層ニューロンは3値で表される。DBNNは出力信号を入力信号へフィードバックさせることにより、さまざまな周期的な2値パターンを連続的な信号として生成することができる。したがって、DBNNはダイナミックな信号を扱う事に適している。しかしながら、DBNNについての研究はあまりされておらず、そのアルゴリズムは確定的ではない。3.2章ではDBNNのGAを用いた基本的な学習アルゴリズムを提案する [10][11]。また、基本的な計算機実験によって、アルゴリズムの有効性を確認する。3章の後半では様々な教師信号によるDBNNの構造やグレーコードを基にしたリターンマップ (Gmap) を示していく。Gmapは、アナログの1次元のリターンマップ (1次元マップ) をデジタル化したものである。1次元マップ (e.g., ロジスティックマップ [12]) は簡素であり、様々な分岐現象を表すことができる。また、1次元マップは様々な動的システムの解析手法でもある [13]。それをデジタル化し、グ

レーコードによって表したものが Gmap である。3.2 章の学習アルゴリズムによって構築された DBNN と Gmap を用いた計算機実験を 3.4 章に示していく。教師信号にはパワーエレクトロニクスの DC/AC インバータの PWM 制御信号に関係のある制御信号 [14] や、さまざまな周期的な信号パターンを用いる。また、実際の音声データについての計算機実験を行う。DBNN を音声データに適応し、学習結果の汎化能力を解析するために Gmap を用いる。その結果について言及していく。

4 章では全体のむすびと今後の課題について示す。

第2章 バイナリーニューラルネットワーク (BNN)

2.1 バイナリーニューロン

本論文では入出力信号が”1”、”-1”の2値: $B \equiv \{-1, 1\}$ の非線形素子であるバイナリーニューロンを単一の素子として考える。また、図 2.1 にニューロンのモデル図、図 2.2 に動作図を示す。ただし、ニューロンの結合荷重パラメータ w は3値であり、しきい値パラメータ T は整数値として扱う。その活性化関数に符号関数を持つ。以下にニューロンの動作式、シグナム活性化関数を示す。

$$y = \operatorname{sgn} \left(\sum_{i=1}^N w_i x_i - T \right), i \in \{1, \dots, N\} \quad (2.1)$$

$$\operatorname{sgn}(X) = \begin{cases} 1 & \text{for } X \geq 0 \\ -1 & \text{for } X < 0 \end{cases} \quad (2.2)$$

式 (2.1) と図 2.1 が示すように、単一のニューロンは N 個の入力端子と1個の出力端子からなる。ただし、 $x_i \in B$ は i 番目の入力、 $y \in B$ は出力である。また、 w_i は i 番目の入力 x_i とニューロンとの結合荷重パラメータ、 T はニューロンのしきい値パラメータである。ニューロン内では、それぞれ N 個の入力信号と結合荷重パラメータを線形結合させる。式 (3.4)、図 2.2 より、この入力ベクトルと結合荷重ベクトルの内積の和がしきい値以上であれば、ニューロンは”1”の信号を出力し、しきい値未満であれば”-1”の信号を出力する。式 (2.1) のダイナミクスには、 N 次元のユークリッド空間を $N - 1$ 次元の分離超平面 (ab. SHP) で分離し、結合荷重ベクトル w の指す側の入力に対して”1”の値を出力し、反対側の入力に対しては”-1”の値を出力する線形分離の性質がある。そのため、SHP による出力の分類が幾何学的に可能である。ニューロンの結合荷重としきい値が求めれば SHP が一意に決まることになる。

2.2 バイナリーニューラルネットワーク (BNN)

本論文で対象としているバイナリーニューラルネットワーク (ab. BNN) は、人工ニューラルネットワークのデジタルな静的モデルである。また、BNN はバイナリーニューロンを複数結合したネットワークモデルである。図 2.3 に BNN のネットワーク構造を示す。BNN は 3 層のフィードフォワード型ネットワークである。この N 次元の 2 値入力ベクトル信号をシグナム活性化関数を用いて 2 値出力のスカラ信号へと変換するものである。BNN は入力層ニューロン N 個、中間層ニューロン M 個、出力層ニューロン 1 個で構成される。中間層ニューロンを十分な数用意すれば、所望のブール関数 F_B の入出力関係を満たす近似関数を生成することができる。:

$$F_B : \mathbf{B}^N \rightarrow \mathbf{B}, \mathbf{y} = F_B(\mathbf{x}) \quad (2.3)$$

ただし、 $\mathbf{y} \equiv \{-1, 1\} \in \mathbf{B}$ は 2 値の出力ベクトルである。式 (2.4)、式 (2.5) に動作式を示す。

$$y = \text{sgn} \left(\sum_{i=1}^M w_{ij}^o \xi_j - T_j^o \right), j = 1 \sim M \quad (2.4)$$

$$\xi_j = \text{sgn} \left(\sum_{i=1}^N w_{ji} x_i - T_j \right), i = 1 \sim N \quad (2.5)$$

ただし、 $\mathbf{x} \equiv (x_1, \dots, x_N)$ 、 $x_i \equiv \{-1, 1\} \in \mathbf{B}$ であり、 N 次元の 2 値の入力ベクトルである。また、 $\boldsymbol{\xi} \equiv (\xi_1, \dots, \xi_M)$ 、 $\boldsymbol{\xi} \in \mathbf{B}$ であり、 $\boldsymbol{\xi}$ は $j \in \{1, \dots, M\}$ となるような M 次元の中間層出力ベクトルである。中間層ニューロンの結合荷重パラメータ w_{ji} は 3 値であり、しきい値パラメータ T_j は $-N$ から N までの整数値をとる。:

$$w_{ji} \in \{-1, 0, 1\}, T_j = \sum_{i=1}^N |w_{ji}| - \beta_j, \beta_j \in \{1, 3, 5, \dots\} \quad (2.6)$$

$$w_{ij}^o \in \{0, 1\}, T_j^o = 1 - M \quad (2.7)$$

また、 w_{ij}^o は出力層ニューロンの結合荷重パラメータであり、 T_j^o は出力層ニューロンのしきい値パラメータである。 β_j は中間層ニューロン M の数を調整することができる。このとき、中間層ニューロンの出力の OR 演算によって所望のブール関数を実現

あるいは近似する。また、BNN を次式で略記する。

$$\mathbf{y} = F_1(\mathbf{x}) \quad (2.8)$$

2.3 BNN の学習アルゴリズム

ここでブール関数 F_B を実現する為の基本的な GA に基づいた学習アルゴリズムを紹介する。まず、準備としていくつかの定義を与える。 $U = \{u_1, \dots, u_{N_u}\}$ を $F_B(u_j) = 1$ のような教師信号の集合とする。学習の基本的な問題は、教師信号を実現するために、式 (2.6) と式 (2.7) の各パラメータを決定することである。ただし、 $u_j \equiv \{u_{j1}, \dots, u_{jN}\}$ 、 $u_{ji} \in B$ とする。また、 $V = \{v_1, \dots, v_{N_v}\}$ を $F_B(u_j) = -1$ のよう教師信号の集合とする。ただし、 $v_j \equiv \{v_{j1}, \dots, v_{jN}\}$ 、 $v_{ji} \in B$ とする。また、 u_j と v_j を、それぞれ真頂点、偽頂点と呼ぶ。真と偽の頂点の数は $N_u + N_v \leq N$ を満たしている。もし U でもなく、 V でもない B^N の要素が存在するならば、それらの要素は”don't care”とする。与えられた教師信号により、アルゴリズムはネットワークの構造を決め、目的の関数を近似する。以下に BNN の学習アルゴリズムを示す。

アルゴリズムの流れを図 2.4 に示す。

メインルーチン

Step 1: (初期化)

j をある中間層ニューロンの番号とし、 $j = 1$ とする。

Step 2: (GA を用いた探索)

j 番目の中間層ニューロンについて、後述の GA サブルーチンによって分離超平面 (SHP) を決定する。それぞれの重みに関して最も多く真頂点を分離することのできる β_j を決定する。また、 j 番目の中間層ニューロンは j 番目の分離超平面 (SHP_j) とみなすことができる。出力 y の j 番目の中間層ニューロンが与えられたあと、 j 番目の SHP_j により分離されたものとし、頂点を”don't care”とする。

Step 3: (繰り返し)

学習を繰り返し、全ての真頂点を分離し終えたとき、学習終了となる。このとき、もし分離されていない真頂点が残っている場合は $j = j + 1$ とし、Step 2 へ戻る。

出力層

出力層は式 (2.7) により、中間層出力の OR 演算により決定される。

GA サブルーチン

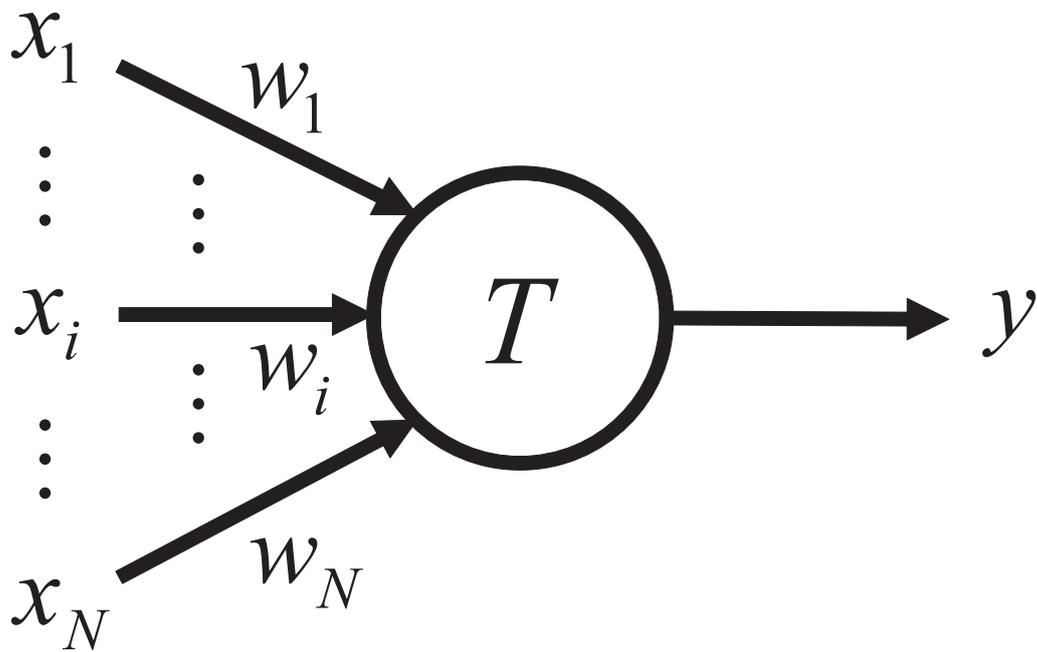
GA について評価値は: $F_g(C_r) = \# \{ \text{分離した真頂点の数} \}$ によって与えられ、真頂点を出来るだけ多く含むものを採用する。まずはじめに、 M_g 個の染色体 (C_1, \dots, C_{M_g}) を用意する。それぞれの染色体は次式で構成される。

$$C_k = (w_{j1}^k, \dots, w_{jN}^k), w_{ji} \in \{-1, 0, 1\} \quad (2.9)$$

ただし、 $k = 1 \sim M_g$ である。初期染色体の一つには教師信号のうち、出力信号 $y = 1$ となる入力信号 x を用いる。初期染色体の一つを教師信号を用いることで、真頂点を分離することのできる SHP が少なくとも一つだけ決定する。それが出来るだけ多くの真頂点を分離できるように発展させる。それ以外の初期染色体はランダムに決定する。それぞれの染色体に対して出来るだけ多く真頂点を分離できる (評価値が高くなる) ように β_j を調整する。評価値の高い染色体についてランキング選択を用い、評価値が高い染色体同士を交叉確率 P_c で二点交叉させる。評価値の低い染色体を淘汰させ、突然変異確率 P_m に従い次世代の染色体を生成する。最大世代数 G_{max} 回これをくりかえし、最も多く真頂点を分離することのできる染色体を j 番目の中間層パラメータとし、 SHP_j を決定する。本 GA は M_g 、 P_c 、 P_m 、 G_{max} の 4 つのパラメータによって特徴づけられる。

基本的な例として図 2.5 に $N = 3$ としたときの学習過程と学習結果を示す。与えられた教師信号によりアルゴリズムはネットワークを構築し、目的の関数を近似する。以下に図 2.5 の解説をする。まず、(a) のように 1 つ目の SHP である SHP_1 を決定する。次に、(b) のように SHP_1 で分離された頂点を "don't care" と宣言し、2 つ目の SHP で

ある SHP_2 を決定する。最後に、(c) のように SHP_2 で分離された頂点を ”don't care” と宣言する。●、○、× はそれぞれ教師信号の出力 ”1”、”-1”、”don't care” を意味する。(d) は典型例のブール関数とそれに対応する BNN の構造である。青色の線を $w_{ji} = 1$ とし、赤色の線を $w_{ji} = -1$ とする。



N : 入力の数
 x_i : 入力信号
 w_i : 出力信号
 y : 結合荷重
 T : しきい値

図 2.1: 単一ニューロンのモデル図

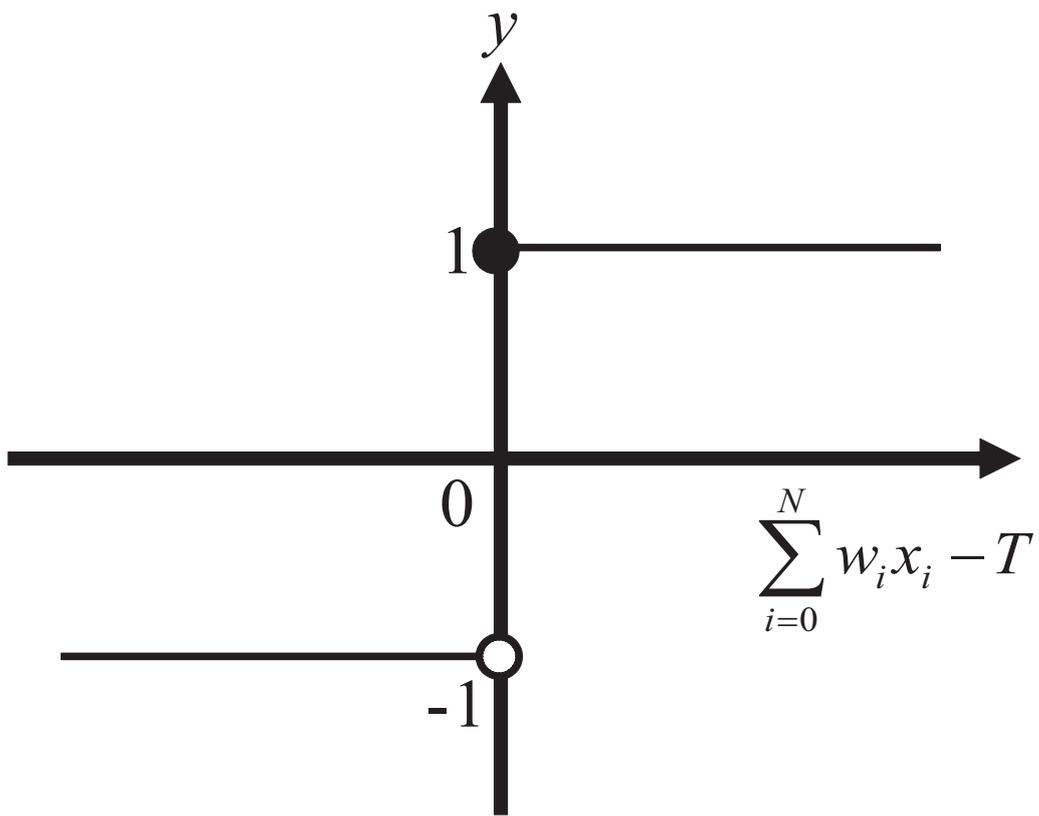


図 2.2: 単一ニューロンの動作図 (符号関数)

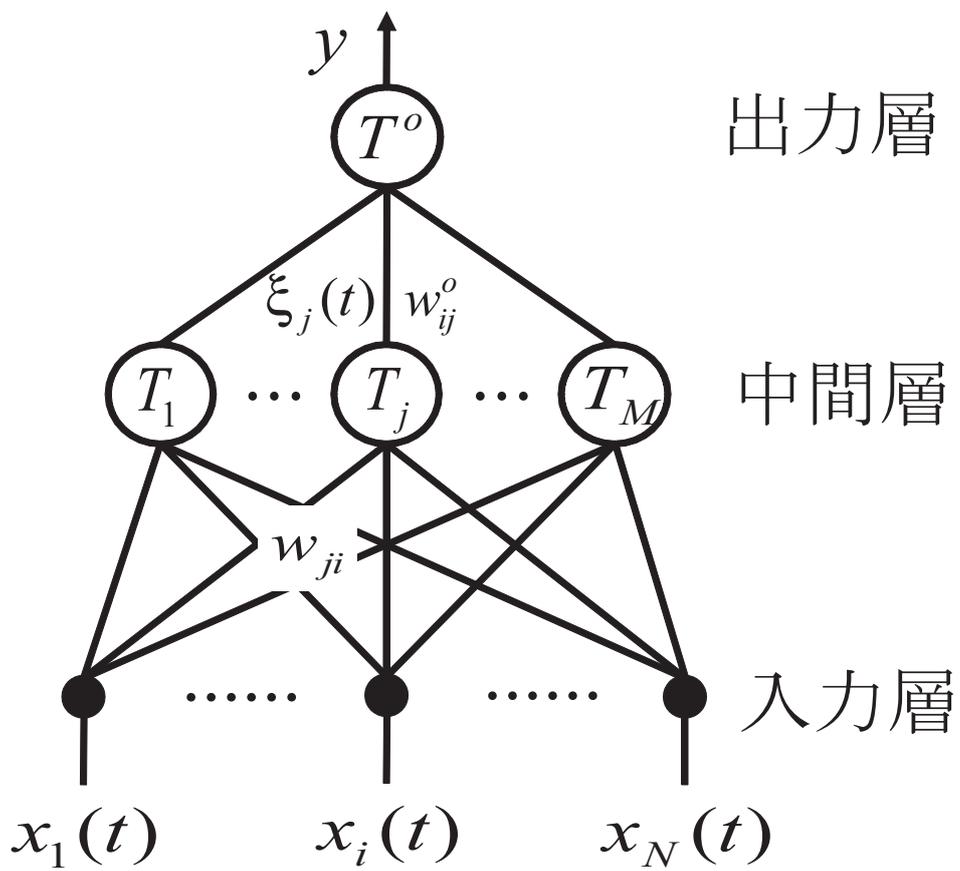


図 2.3: BNN の構造図

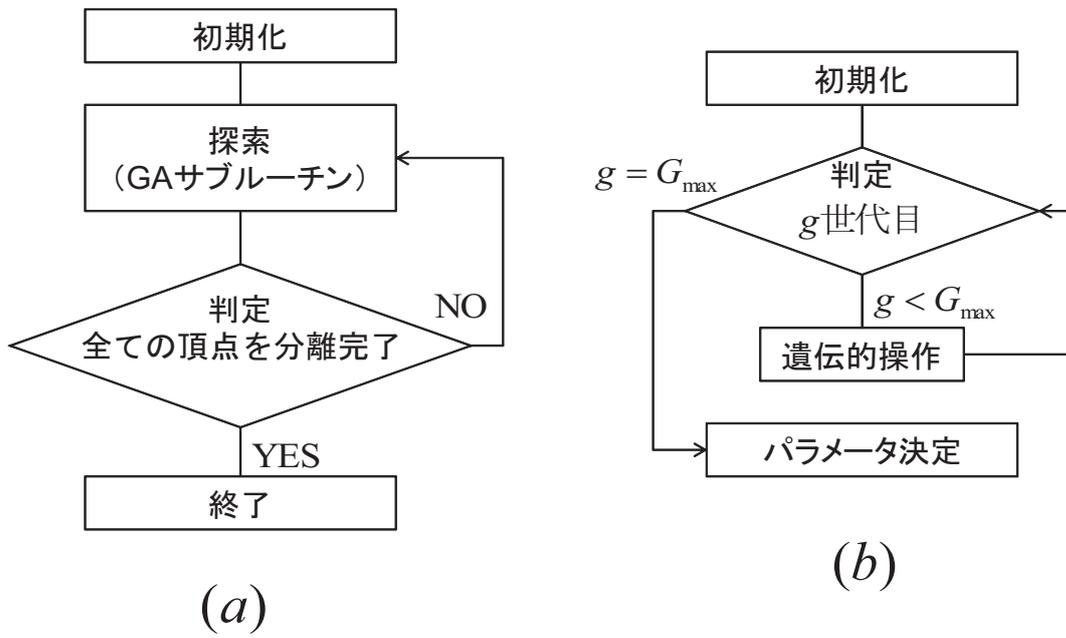


図 2.4: フローチャート (a) メインルーチン (b) GA サブルーチン

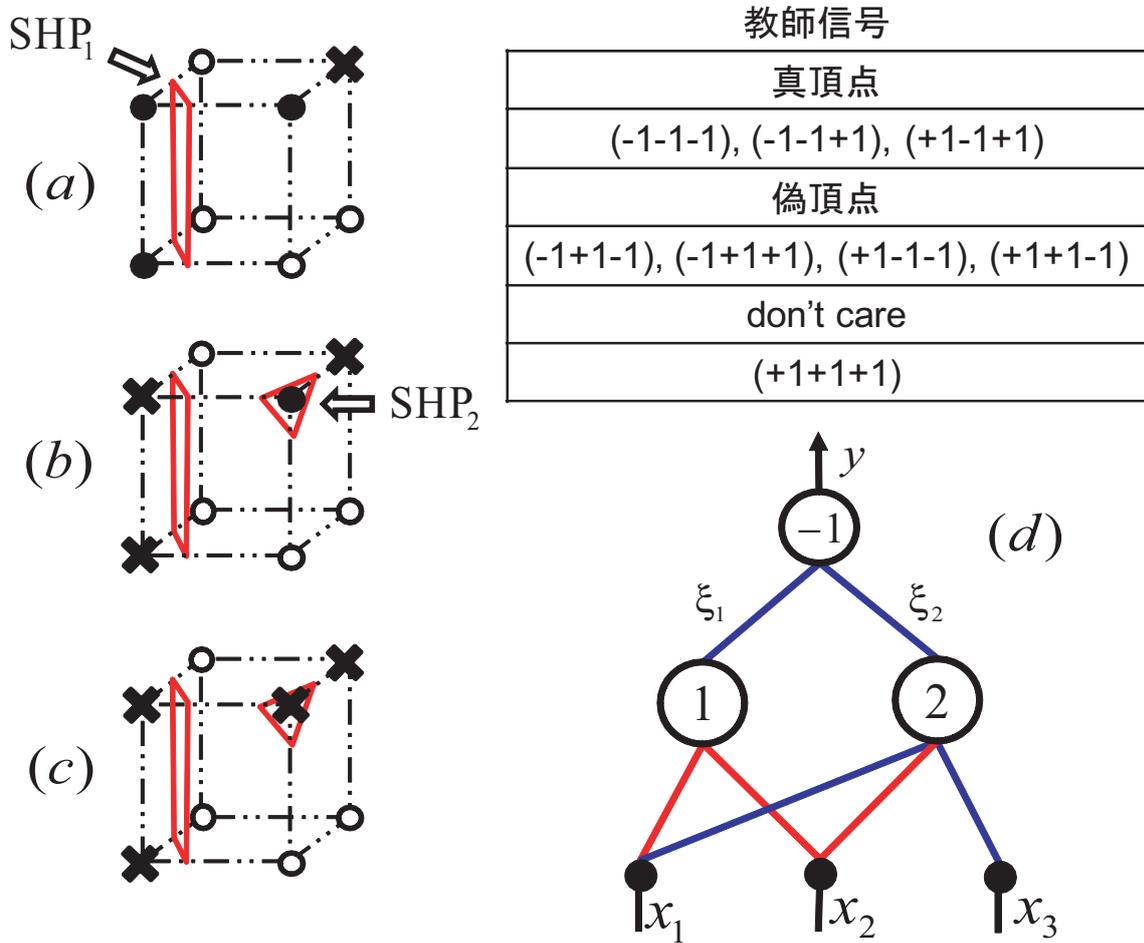


図 2.5: BNN の典型的な学習過程 ($N = 3$)
 (a) 1つ目の SHP である SHP_1 を決定する。(b) SHP_1 で分離された頂点を "don't care" と宣言し、2つ目の SHP である SHP_2 を決定する。(c) SHP_2 で分離された頂点を "don't care" と宣言する。 \bullet 、 \circ 、 \times はそれぞれ教師信号の出力 "1"、"-1"、"don't care" を意味する。(d) は典型例のブール関数とそれに対応する BNN の構造である。青色の線を $w_{ji} = 1$ とし、赤色の線を $w_{ji} = -1$ とする。

2.4 計算機実験

基本的な計算機実験を行い、学習方法の有効性とネットワークの構造を確認する。対象とするのは7次元のBNNである。この信号はパワーエレクトロニクスのDC/ACインバータのPWM制御信号に関する、7入力7出力のインバータ [14] のスイッチ制御についての信号である。このような制御信号についてのBNNの学習方法は考えられている [11]。この教師信号はインバータの入出力関係の一部を表している。GAのパラメータを以下のように設定する。

$$(P_c, P_m, G, M_g) = (0.2, 0.1, 30, 14) \quad (2.10)$$

また、GAの染色体の初期パラメータは教師信号の入力と一致したものをを用いる。図2.6は $N = 7$ とし、表2.1のような教師信号を学習ときのBNNを示したものである。実験結果より、この教師信号は1つの中間層ニューロンで構築できている。異なる教師信号の出力について、7入力1出力を7回繰り返すことで、BNNは7入力7出力のBNNを構築することができる。表2.2に出力が異なる複数の出力の教師信号配置した。上記の学習アルゴリズムを用い、学習した結果を図2.7に示す。このような信号を用いることで、インバータ回路などの学習も可能だと考える。次章では、このような N 入力1出力を N 回用いるのではなく、 N 入力 N 出力の動的バイナリニューラルネットワーク (DBNN) を効率良く学習するアルゴリズムについて述べる。

表 2.1: 教師信号 ($N = 7$)

t	$(x_1, x_2, x_3, x_4, x_5, x_6, x_7)$	y
1	$(+1, -1, -1, -1, +1, +1, +1)$	+1
2	$(+1, -1, -1, -1, -1, +1, +1)$	+1
3	$(+1, +1, -1, -1, -1, +1, +1)$	+1
4	$(+1, +1, -1, -1, -1, -1, +1)$	+1
5	$(+1, +1, +1, -1, -1, -1, +1)$	+1
6	$(+1, +1, +1, -1, -1, -1, -1)$	+1
7	$(+1, +1, +1, +1, -1, -1, -1)$	-1
8	$(-1, +1, +1, +1, -1, -1, -1)$	-1
9	$(-1, +1, +1, +1, +1, -1, -1)$	-1
10	$(-1, -1, +1, +1, +1, -1, -1)$	-1
11	$(-1, -1, +1, +1, +1, +1, -1)$	-1
12	$(-1, -1, -1, +1, +1, +1, -1)$	-1
13	$(-1, -1, -1, +1, +1, +1, +1)$	-1
14	$(-1, -1, -1, -1, +1, +1, +1)$	+1
	otherwise	don't care

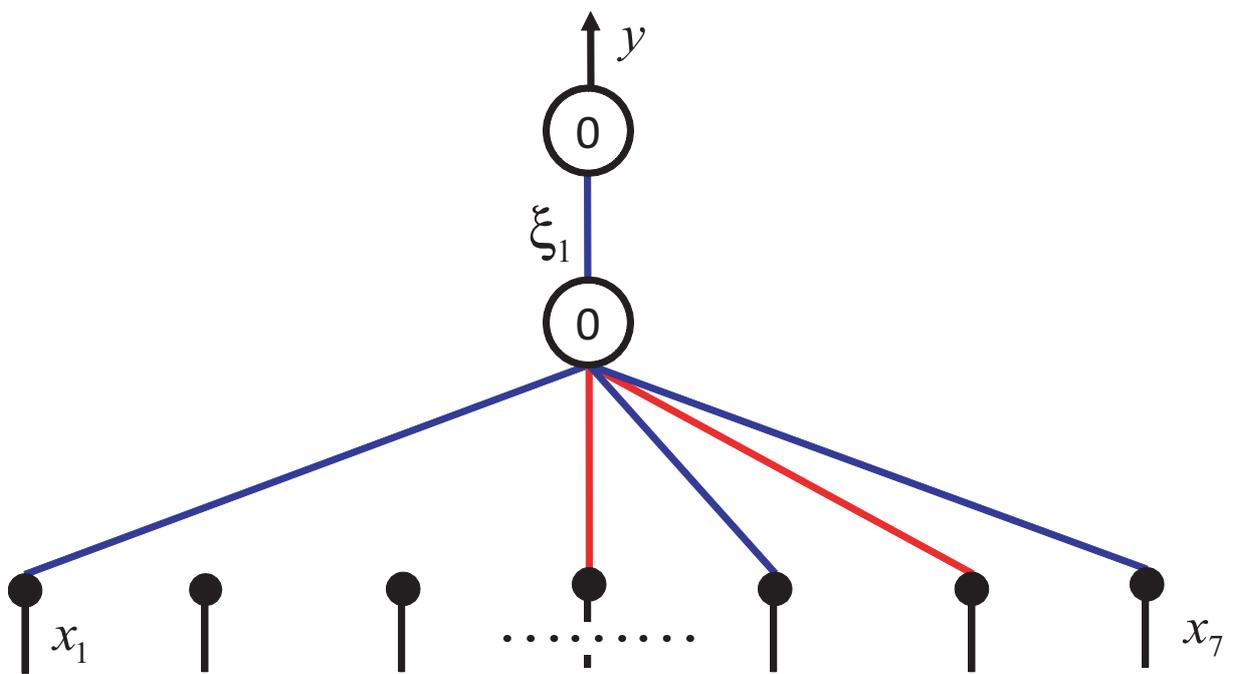


図 2.6: 表 2.1 に対応する BNN ($N = 7$)

表 2.2: 教師信号 ($N = 7$ を 7 回)

t	$(x_1, x_2, x_3, x_4, x_5, x_6, x_7)$	$(y_1, y_2, y_3, y_4, y_5, y_6, y_7)$
1	$(+1, -1, -1, -1, +1, +1, +1)$	$(+1, -1, -1, -1, -1, +1, +1)$
2	$(+1, -1, -1, -1, -1, +1, +1)$	$(+1, +1, -1, -1, -1, +1, +1)$
3	$(+1, +1, -1, -1, -1, +1, +1)$	$(+1, +1, -1, -1, -1, -1, +1)$
4	$(+1, +1, -1, -1, -1, -1, +1)$	$(+1, +1, +1, -1, -1, -1, +1)$
5	$(+1, +1, +1, -1, -1, -1, +1)$	$(+1, +1, +1, -1, -1, -1, -1)$
6	$(+1, +1, +1, -1, -1, -1, -1)$	$(+1, +1, +1, +1, -1, -1, -1)$
7	$(+1, +1, +1, +1, -1, -1, -1)$	$(-1, +1, +1, +1, -1, -1, -1)$
8	$(-1, +1, +1, +1, -1, -1, -1)$	$(-1, +1, +1, +1, +1, -1, -1)$
9	$(-1, +1, +1, +1, +1, -1, -1)$	$(-1, -1, +1, +1, +1, -1, -1)$
10	$(-1, -1, +1, +1, +1, -1, -1)$	$(-1, -1, +1, +1, +1, +1, -1)$
11	$(-1, -1, +1, +1, +1, +1, -1)$	$(-1, -1, -1, +1, +1, +1, -1)$
12	$(-1, -1, -1, +1, +1, +1, -1)$	$(-1, -1, -1, +1, +1, +1, +1)$
13	$(-1, -1, -1, +1, +1, +1, +1)$	$(-1, -1, -1, -1, +1, +1, +1)$
14	$(-1, -1, -1, -1, +1, +1, +1)$	$(+1, -1, -1, -1, +1, +1, +1)$
	otherwise	don't care

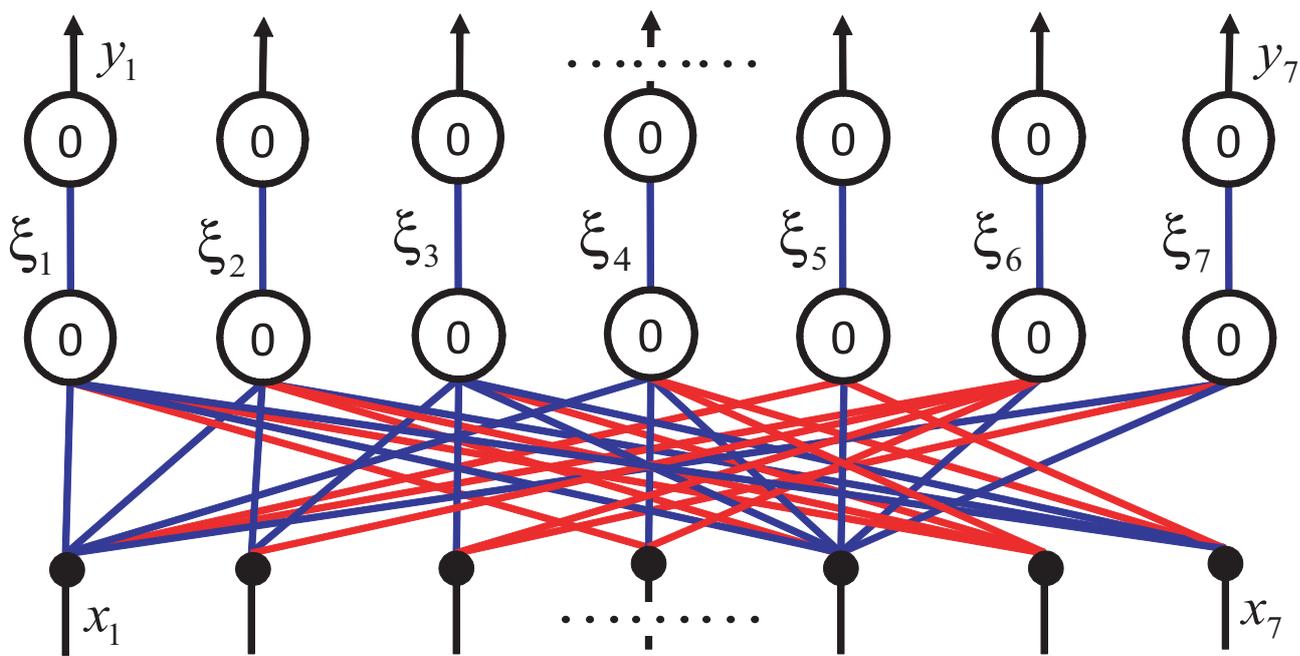


図 2.7: 表 2.2 に対応する BNN (7 入力 1 出力を 7 回)

第3章 動的バイナリニューラルネットワーク (DBNN)

3.1 動的バイナリニューラルネットワーク (DBNN)

DBNN は三層の遅れフィードバック型のネットワークである。DBNN は式 (2.8) の N 入力 1 出力 BNN: F_1 を N 入力 N 出力に拡張し、出力信号を入力信号へ遅れフィードバックすることによって構成される。出力信号を入力信号へフィードバックすることで、DBNN は様々な 2 値の周期的なパターンを生成することができる。図 3.1 に DBNN の構造を示す。それぞれのシグナム活性化関数と DBNN は以下の式によって定義される。

:

$$\mathbf{x}(t+1) = \mathbf{F}_D(\mathbf{x}(t)), \quad \mathbf{F}_D: \mathbf{B}^N \rightarrow \mathbf{B}^N \quad (3.1)$$

$$x_i(t+1) = \text{sgn} \left(\sum_{j=1}^M w_{ij}^o \xi_j(t) - T_i^o \right), \quad i = 1 \sim N \quad (3.2)$$

$$\xi_j(t) = \text{sgn} \left(\sum_{i=1}^N w_{ji} x_i(t) - T_j \right), \quad j = 1 \sim M \quad (3.3)$$

$$\text{sgn}(X) = \begin{cases} 1 & \text{for } X \geq 0 \\ -1 & \text{for } X < 0 \end{cases} \quad (3.4)$$

ただし、入力信号 $\mathbf{x}(t) = (x_1(t), \dots, x_N(t))$ であり、 $x_i(t) \in \{-1, 1\} \equiv \mathbf{B}$ である。また、入力信号は離散時間 t に対して連続であり、 N 次元の 2 値ベクトルである。中間層出力は $\boldsymbol{\xi}(t) \equiv (\xi_1(t), \dots, \xi_M(t))$ 、 $\xi_i(t) \in \mathbf{B}$ である。また、離散時間 t において中間層出力は M 次元の出力ベクトルである。入力信号 $\mathbf{x}(t)$ が与えられたとき、DBNN は中間層ニューロンによって次の出力信号 $\mathbf{x}(t+1)$ を出力する。DBNN によって表せる 2 値の信号パターンはとても簡素である。また、DBNN の中間層ニューロンは 3 値の結合

荷重パラメータと整数型のしきい値パラメータを有する。 :

$$w_{ji} \in \{-1, 0, 1\}, T_j = \sum_{i=1}^N |w_{ji}| - \beta_j, \beta_j \in \{1, 3, 5, \dots\} \quad (3.5)$$

ただし、 $i = 1 \sim N$ 、 $j = 1 \sim M$ であり、 β_j は中間層ニューロン M の数を調整することができる。出力層の結合パラメータ w_{ij}^o と出力層のしきい値パラメータ T_i^o は次式で定義される。 :

$$w_{ij}^o \in \{0, 1\}, T_i^o = 1 - M \quad (3.6)$$

このとき、出力信号は中間層ニューロンの出力の OR 演算によって所望の 2 値の信号パターンを実現あるいは近似する。DBNN は w_{ji} 、 β_j 、 w_{ij}^o 、 T_j^o の 4 つのパラメータによって構成される。

3.2 DBNN の学習アルゴリズム

まず、周期 T である 2 値の信号パターンで構成される教師信号を以下のように定義する。 :

$$\begin{aligned} z(t+1) &= F_{ui}(z(t)) \\ F_{ui} : B^N &\rightarrow B, i = 1 \sim N, t = 1 \sim T \end{aligned} \quad (3.7)$$

ただし、教師信号 $z(t)$ は、 $z(1), z(2), \dots, z(T), z(T+1) = z(1)$ であり、 $z(t_k) \neq z(1)$ for $1 < t_k \leq T$ を満たすものとする。また、 $F_{ui} \equiv (F_{u1}, \dots, F_{uN})$ であり、 N 次元で $z(t) \in B^N$ である。従って教師信号 $z(t+1)$ の一つは 2^N で表せる超立方体の一頂点とみなすことができる。例えば出力の値が”1”であるものを黒色の頂点（真頂点）、出力の値が -1 であるものを白色の頂点（偽頂点）とすると、教師信号 $z(t+1) = 1$ は真頂点を意味する（逆に $z(t+1) = -1$ は偽頂点を示す）。 i 番目教師信号に関して、 $T_u + T_v = T$ を満たすとき、真頂点と偽頂点は $U_i = \{u(1), \dots, u(T_u)\}$ と $V_i = \{v(1), \dots, v(T_v)\}$ に属すものとする。2 値の B^N を満たす N 次元の中で、もし U でも V でもない要素が存在するならば、それらの要素は”don't care”とする。 j 番目の中間層ニューロンは j 番目の分離超平面 (SHP_j) とみなす。典型的な DBNN と超立方体と超平面を図 3.2 に

示す。もし、式 (3.7) を満たすような教師信号について、図のように真頂点を分離できるような j 番目の超平面 (SHP_j) を決定したとき、 j 番目の中間層ニューロンも決定されたものとする。本論文で提案する GA を用いたアルゴリズムは中間層パラメータ (w_{ji}, β_j) を決定するためのものである。もし、すべての真頂点を分離するような中間層パラメータが決定されたならば、出力層のパラメータは式 (3.6) により、OR 演算を用いることで決定される。ここで、いくつかの定義を行う。まず、出力層ニューロンを $O_1 \sim O_N$ とする。中間層ニューロンと出力層ニューロンが結合している出力を $O_c = 1 (c = 1 \sim n)$ とする。中間層ニューロンと出力層ニューロンが結合していない出力を $O_{uc} = 0 (uc = 1 \sim m)$ とする。ただし、 $N = n + m$ である。

メインルーチン

Step 1: (初期化)

l を学習回数とし、 $l = 1$ とする。また、 j をある中間層ニューロンの番号とし、 $j = 1$ とする。

Step 2:

全ての出力層ニューロン $O_1 \sim O_N$ を O_{uc} とする。(全ての中間層ニューロンは出力層ニューロンと結合していないものとする。)

Step 3: (探索対象の決定)

O_{uc} の中で最も多く真頂点を含む出力 O を決定する。図 3.2 の場合、探索対象は真頂点の総数から $z_1(t + 1)$ となる。

Step 4: (SHP の構築)

j 番目の中間層ニューロンについて、後述の GA サブルーチンによって分離超平面 (SHP_j) を決定する。それぞれの重みに関して最も多く真頂点を分離することのできる β_j を決定する。 j 番目の中間層ニューロンが与えられたあと、 j 番目の SHP により分離された頂点を "don't care" とする。図 3.2 では、 SHP_1 が決定される。

Step 5: (SHP の共有)

j 番目の SHP を他の出力と共有する。共有された出力を O_c とする。これを O_{uc} かつ O 以外の全ての出力に対して行う。共有によって分離された真頂点を "don't care" とする。図 3.2 では、教師信号 $z_2(t+1)$ の立方体が SHP を共有できるものとし中間層ニューロンを共有する。

Step 6:

$j = j+1$ とし、全ての出力 $O_1 \sim O_N$ において $O_c = 1$ 、 $c = 1 \sim N$ となるまで STEP 3 ~ STEP 5 をくりかえす。

Step 7: (繰り返し)

全ての出力が O_c ($c = 1 \sim N$) となった場合、 $l = l+1$ とし、STEP 2 に戻る。全ての真頂点を分離し終えた場合学習を終了する。

出力層

出力層は式 (2.7) のように、中間層ニューロンの出力を OR 演算することにより決定される。

GA サブルーチン

GA について評価値は: $F_g(C_r) = \# \{ \text{分離した真頂点の数} \}$ によって与えられ、真頂点を出来るだけ多く含むものを採用する。まずはじめに、 M_g 個の染色体 (C_1, \dots, C_{M_g}) を用意する。それぞれの染色体は次式で構成される。

$$C_k = \{w_{j1}^k, \dots, w_{jN}^k\}, w_{ji} \in \{-1, 0, 1\} \quad (3.8)$$

ただし、 $k = 1 \sim M_g$ である。初期染色体の一つには教師信号のうち、出力信号 $x_i(t+1) = 1$ となる入力信号 $x(t)$ を用いる。初期染色体の一つを教師信号を用いることで、真頂点を分離することのできる SHP が少なくとも一つだけ決定する。それが出来るだけ多くの真頂点を分離できるように発展させる。それ以外の初期染色体はランダムに決定する。それぞれの染色体に対して出来るだけ多く真頂点を分離できる (評価値が高くなる) ように β_j を調整する。評価値の高い染色体についてランキング選択を用い、評価値が高い染色体同士を交叉確率 P_c で二点交叉させる。評価値の低い染色体を淘汰さ

せ、突然変異確率 P_m に従い次世代の染色体を生成する。最大世代数 G_{max} 回これをくりかえし、最も多く真頂点を分離することのできる染色体を j 番目の中間層パラメータとし、 SHP_j を決定する。本 GA は M_g 、 P_c 、 P_m 、 G_{max} の4つのパラメータによって特徴づけられる。

表 3.1 のような教師信号により本アルゴリズムは図 3.2 のようなネットワークを構築し、目的の信号パターンを近似あるいは実現する。また、青色の線を $w_{ji} = 1$ とし、赤色の線を $w_{ji} = -1$ とする。

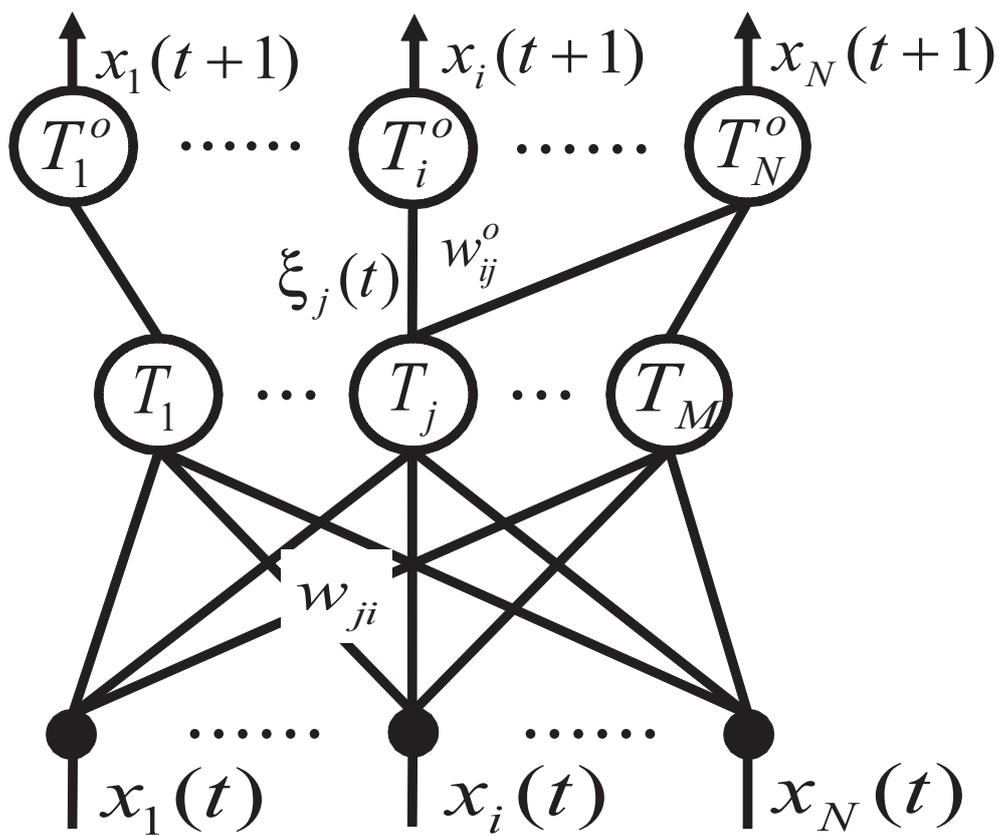


図 3.1: DBNN の構造図

表 3.1: DBNN の教師信号 ($N = 3$)

$z(1)$	$(-1, -1, -1)$
$z(2)$	$(+1, -1, -1)$
$z(3)$	$(-1, +1, +1)$
$z(4)$	$(+1, +1, -1)$
$z(5)$	$(-1, -1, +1)$
$z(6)$	$(+1, +1, +1)$
$z(7) = z(8)$	$(-1, -1, -1)$

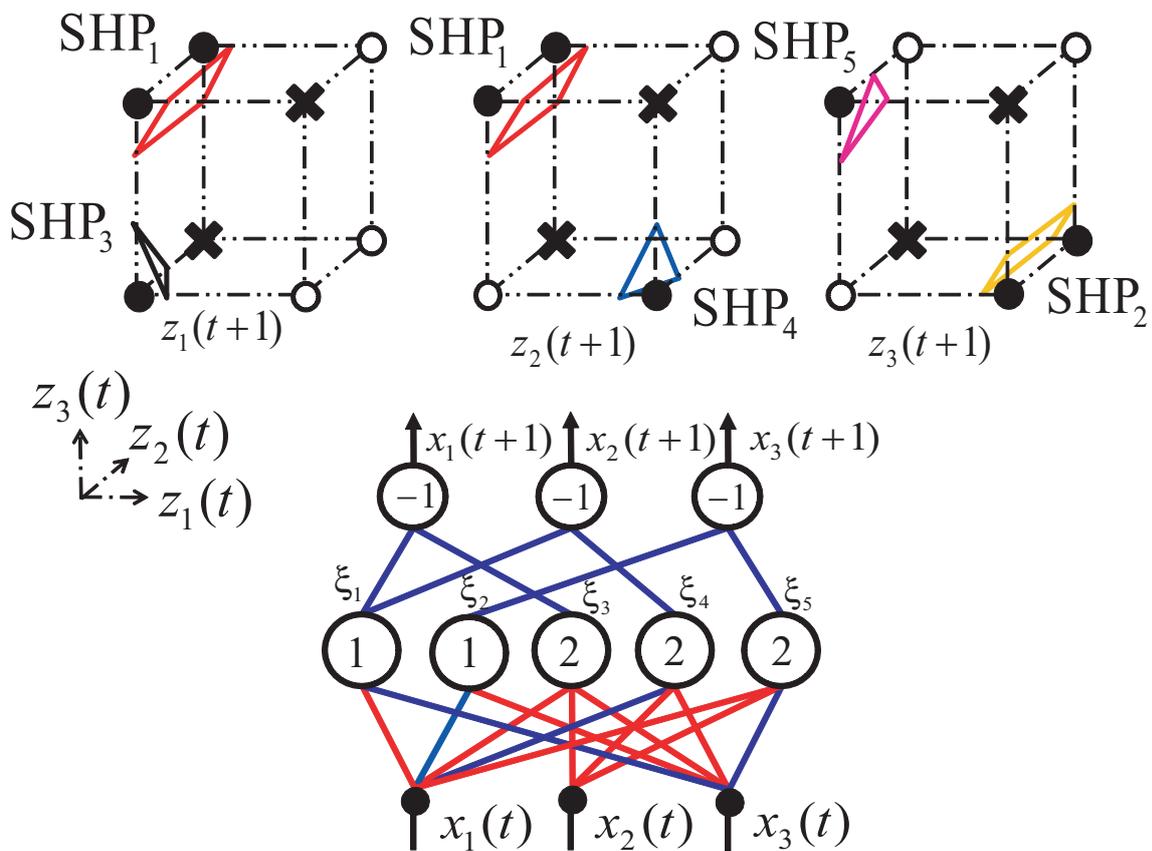


図 3.2: 表 3.1 に対する DBNN ($N = 3$) の構造図と分離超平面
 DBNN における分離超平面の学習過程を以下に示す。 $l = 1$ で SHP_1 、 SHP_2 が決定されたのち、 $l = 2$ で SHP_3 、 SHP_4 、 SHP_5 が決定される。教師信号は周期が 6 の周期的な信号パターンである。また、青色の線を $w_{ji} = 1$ とし、赤色の線を $w_{ji} = -1$ とする。

3.3 DBNNの解析手法 (Gmap)

3.1でも述べたとおり、DBNNは様々な2値の周期的な信号パターンを生成できる。その解析手法について、本稿ではグレーコードを基にしたリターンマップ (Gmap) を紹介する。DBNNが扱うところの N 次元の2値パターンを格子点上で表すことによって、DBNNでの信号パターンを簡単なマップで示すことができる。その定義域は、 $[0, 1)$ 区間 I 中の $2^M - 1$ 個の格子点の集合である。

$$I_N \equiv \{l_0, l_1, \dots, l_{2^N-1}\} \subset [0, 1), \quad l_i = i/2^N$$

ただし、 $i = 0 \sim 2^N - 1$ である。また、 N 次元の2値ベクトル B^N を満たすものとする。
:

$$G_N : I_N \rightarrow B^N$$

グレーコードによって変換された B^N を G_N マップの格子点上に配置する。例えば $N = 2$ のとき、 $G_N(0/4) = (-1, -1)$ 、 $G_N(1/4) = (-1, +1)$ 、 $G_N(2/4) = (+1, +1)$ 、 $G_N(3/4) = (+1, -1)$ となる。 G_N をDBNNの F_D に適応することによってグレーコードを基にしたリターンマップ (Gmap) を得ることができる。

$$F_g : I_N \rightarrow I_N, \quad F_g = G_N^{-1} \circ F_D \circ G_N$$

こうすることによってDBNNは以下の式のように組み込む事ができる。

$$\theta(t+1) = F_g(\theta(t)), \quad \theta(t) = G_N^{-1}(\mathbf{x}(t)) \in I_N$$

ただし、 $\theta(t)$ の格子点はグレーコードで表記した $\mathbf{x}(t)$ とみなす。図3.4は図3.3で示される出力信号パターンをGmapを用いて示した典型図である。図3.4において $2^4 = 16$ は格子点の数であり、4次元の2値ベクトル $\mathbf{x}(t) \in B^4$ をグレーコードに直してマップを描かせたものである。図3.4のGmapは4周期と2周期の二種類の信号パターンを有する。赤色の線は教師信号に収束した周期的な信号パターンであり、緑色の線はそれ以外の周期的な信号パターンである。黒い点は $\mathbf{x}(t)$ を入力した時の出力信号 $\mathbf{x}(t+1)$ をグレーコードに直してプロットしたものである。

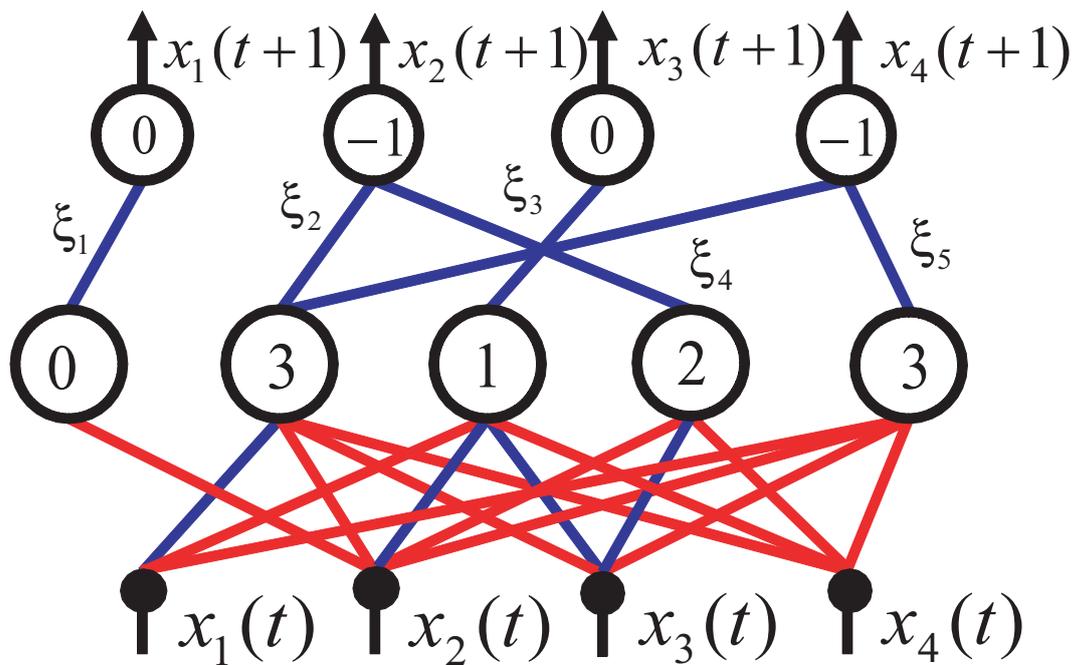


図 3.3: DBNN ($N = 4$) の典型例

青色の線は $w_{ji} = 1$ とし、赤色の線は $w_{ji} = -1$ とする。パラメータ β_j は $(\beta_1, \beta_2, \beta_3, \beta_4) = (1, 1, 3, 1, 1)$ である。図の DBNN は 4 周期の信号パターンをもつ：
 $(-1, -1, -1, -1) \rightarrow (+1, -1, -1, +1) \rightarrow (+1, -1, -1, -1) \rightarrow (+1, +1, -1, +1) \rightarrow (-1, -1, -1, -1)$

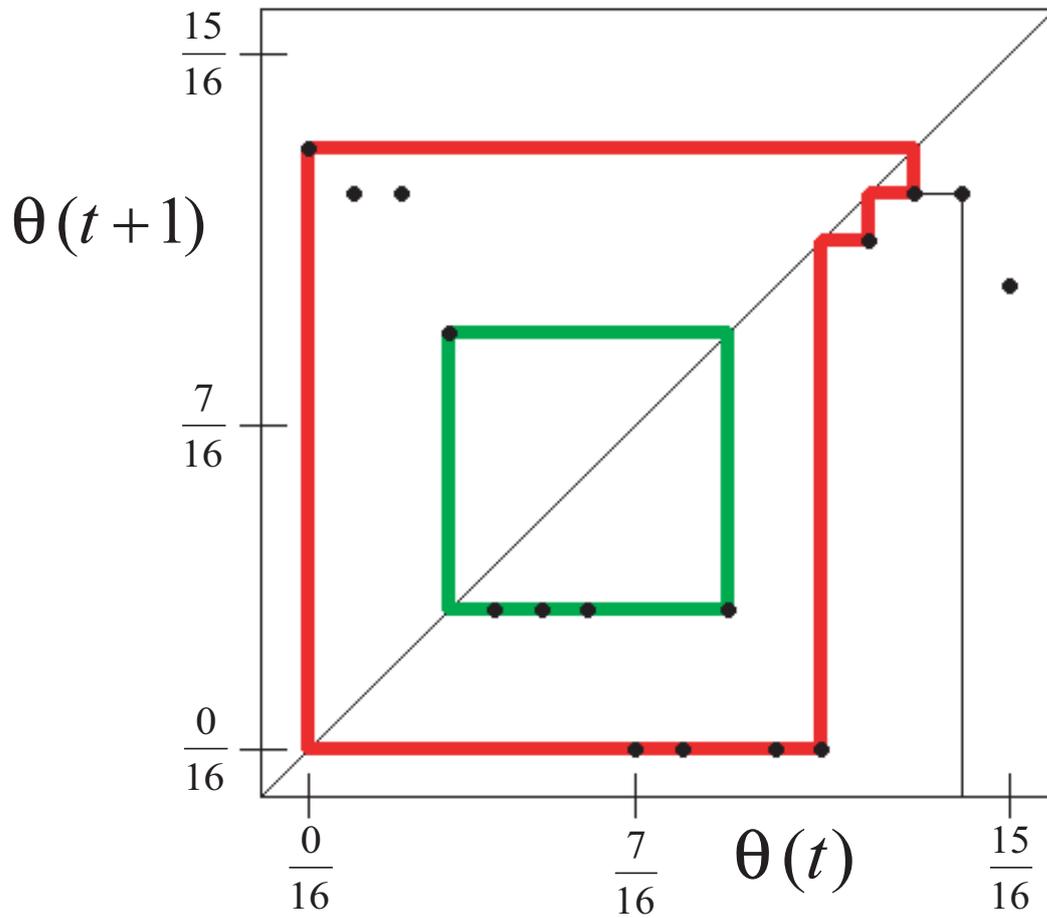


図 3.4: DBNN の $G_{\text{map}} (N = 4)$ の典型例
 二種類の周期パターンがあり、赤色は教師信号に収束した周期的な信号パターンを示し、緑色はそれ以外の周期的な信号パターンを示す。

3.4 計算機実験

DBNN においての本アルゴリズムの有効性を確認するために、いくつかの計算機実験を行う。ここで問題となるのは、アルゴリズムによって決定される DBNN のパラメータである。学習方法によって構築されていくネットワークの学習過程と G_{map} についても示していく。ただし、 G_{map} において赤色の線を教師信号に束したの周期的な信号パターンとし、緑色をそれ以外の周期的な信号パターンとする。

3.4.1 インバータのスイッチ制御信号

まず最初に対象とするのは 7 次元の周期的な信号パターンの教師信号である。この教師信号は 14 周期をもち、章 2 の 2.4 で示された信号パターンである。この周期的な信号パターンはパワーエレクトロニクスの DC/AC インバータの PWN 制御信号に関する、インバータ [14] のスイッチ制御についての周期的な信号パターンである。GA のパラメータを以下のように設定する。

$$(P_c, P_m, G, M_g) = (0.2, 0.1, 30, 10) \quad (3.9)$$

また、GA の染色体の初期パラメータの 1 つは教師信号の入力 $z(t)$ と一致したものをを用いる。本アルゴリズムを適応することにより図 3.5 の DBNN と表 3.3 を得る。教師信号は表 3.2 に示す。また、青色の線は $w_{ji} = 1$ であり、赤色の線は $w_{ji} = -1$ である。この DBNN はそれぞれの 1 つの出力に対して 1 つの中間層ニューロンしか結合していない、とても簡素なネットワークである。従って本アルゴリズムでの学習回数 $l = 1$ で学習を終了となる。図 3.6 に学習後の G_{map} を示す。赤色の線は教師信号に収束した周期的な信号パターンを表し、この図から全ての入力信号パターンは全て教師信号の周期的な信号パターンに収束あるいは安定していく結果になる。このような自動安定化するシステムは DBNN がもつ重要な汎化能力といえる。もし、この教師信号が現実的な回路で制御されるようになれば、DBNN はロバスト性に優れた信号を生成できると

考える。

3.4.2 DBNNの教師信号(2)

3.4.1を学習した結果は $l = 1$ で1つの出力に対し、1つの中間層ニューロンでしか結合していないDBNNについて解説した。次に示す教師信号パターンは1つの出力に対し、複数の中間層ニューロンが結合しているDBNNについてを扱う。この教師信号は15周期の周期的な信号パターンである。また、教師信号は7次元である。GAのパラメータを以下のように設定する。

$$(P_c, P_m, G, M_g) = (0.2, 0.1, 30, 10) \quad (3.10)$$

また、GAの染色体の初期パラメータの1つは教師信号の入力 $z(t)$ と一致したものをを用いる。本アルゴリズムを適応することにより図3.7のDBNNと表3.5を得る。教師信号は表3.4に示す。また、青色の線は $w_{ji} = 1$ であり、赤色の線は $w_{ji} = -1$ である。図3.8~図3.10にDBNNの学習回数 l ごとのネットワーク構造を示す。また、図3.11~図3.13に学習回数 l ごとのGmapを示す。 $l = 1$ のとき、中間層ニューロンはそれぞれの出力に対して1つずつ結合し、Gmapでの出力信号は1つの点に収束しているのがわかる。また、 $l = 2$ のGmapでは図3.12より4周期の信号パターンへ収束しているのがわかる。 $l = 3$ で学習終了となり、図3.13より15周期の信号パターンに収束している。3.4.1、3.4.2の二つの教師信号ともに、教師信号の信号パターン1つに収束した。しかしながら、これら教師信号の信号パターンだけに収束するのは稀である。次の教師信号からは複数の周期パターンが存在する信号に対してのDBNNを示す。

3.4.3 DBNNの教師信号(3)

3.4.3でも述べたが、DBNNにおいて学習後に生成される周期的な信号パターンが全て教師信号の信号パターンと一致するような例は稀である。ここではDBNNでも周期

的な信号パターンが複数存在する例について示していく。教師信号を表 3.4.3 に示す。この信号は 7 次元の 8 周期の信号パターンである。GA のパラメータを以下のように設定する。

$$(P_c, P_m, G, M_g) = (0.2, 0.1, 30, 10) \quad (3.11)$$

また、GA の染色体の初期パラメータの 1 つは教師信号の入力 $z(t)$ と一致したものを
用いる。本アルゴリズムを適応することにより図 3.16 の DBNN と表 3.7 を得る。また、
青色の線は $w_{ji} = 1$ であり、赤色の線は $w_{ji} = -1$ である。図 3.14 ~ 図 3.17 に DBNN の
学習回数 l ごとのネットワーク構造を示す。また、図 3.18 ~ 図 3.21 に学習回数 l ごとの
Gmap を示す。 $l = 1$ のとき、中間層ニューロンはそれぞれの出力に対して 1 つずつ結
合し、Gmap は 1 つの出力の点に収束しているのがわかる。また、図 3.14 より、ネット
ワークの中間層ニューロン数は、 $l = 1$ のとき 3 つであり、3.4.1 や 3.4.2 の教師信号を
学習したものより、他の出力への共有が多いことがわかる。 $l = 2$ の Gmap では $l = 1$
のときより、出力信号にばらつきが生じている。また、収束する点が $l = 1$ の位置とは
異なる点で収束していることがわかる。 $l = 3$ では二種類の周期的な信号パターンが確
認できるが、教師信号のパターンに似ている周期的なパターンも存在している。教師
信号に近い周期パターンは 8 周期の信号である。 $l = 4$ で学習終了となり、図 3.21 より
8 周期の信号パターンと異なる周期的な信号パターンに収束している。また学習後のパ
ラメータより中間層ニューロン数を抑制するのに β_j が大きい方が効果的である。中
間層ニューロンのパラメータが決定されたのち、出力層のパラメータが決定される。

3.4.4 DBNN の教師信号 (音声データ)

ここでは DBNN を実際の音声データについて適応する。対象となる音声データは
図 3.22 に示す。図 3.22 のような音声データは英単語 "Hello" を 2 値の数値データに直
し DBNN でも扱えるように加工したものを用いる。実際の音声データの全ての信号パ
ターンを DBNN に用いると、周期が 2770 もの膨大な教師信号パターンになってしまう
ので、ここでは教師信号を DBNN でも扱えるように簡素で短い周期に分割したものを

用いる。教師信号として用いる信号パターンは”Hello”のうち、10周期の信号パターンだけを抜き出し教師信号とする。適応する音声データは8次元の周期的な信号パターンである。表3.8に対象となる音声データの周期パターンを示す。表3.8のような教師信号に対し、本アルゴリズムを適応する。GAのパラメータを以下のように設定する。

$$(P_c, P_m, G, M_g) = (0.2, 0.1, 50, 10) \quad (3.12)$$

また、GAの染色体の初期パラメータの1つは教師信号 $z(t)$ の入力と一致したものを
用いる。本アルゴリズムを適応することにより図3.26のDBNNと表3.9を得る。また、
青色の線は $w_{ji} = 1$ であり、赤色の線は $w_{ji} = -1$ である。図3.23～図3.26にDBNNの
学習回数 l ごとのネットワーク構造を示す。また、図3.27～図3.30に学習回数 l ごとの
Gmapを示す。 $l = 1$ のとき、中間層ニューロンはそれぞれの出力に対して1つずつ結
合し、Gmapは1つの出力の点に収束してるのがわかる。また、図3.23より、ネット
ワークの中間層ニューロン数は、 $l = 1$ のとき7つである。 $l = 2$ のGmapでは $l = 1$ の
ときと比べても、出力信号にばらつきはあまり生じていない。 $l = 3$ では出力信号のば
らつきに少なからず変化が生じているが、1つの出力の点に収束している。 $l = 4$ で
学習終了となり、図3.30より、教師信号パターンに収束している信号パターンと、1
つの出力に収束している二種類が確認できる。学習中は中間層ニューロンのパラメー
タが決定されたのち、出力層のパラメータが決定される。学習結果から教師信号3.8を
学習した場合、DBNNの中間層ニューロン数は13個となる。

表 3.2: インバータのスイッチ制御の教師信号

$z(1)$	$(+1, -1, -1, -1, +1, +1, +1)$
$z(2)$	$(+1, -1, -1, -1, -1, +1, +1)$
$z(3)$	$(+1, +1, -1, -1, -1, +1, +1)$
$z(4)$	$(+1, +1, -1, -1, -1, -1, +1)$
$z(5)$	$(+1, +1, +1, -1, -1, -1, +1)$
$z(6)$	$(+1, +1, +1, -1, -1, -1, -1)$
$z(7)$	$(+1, +1, +1, +1, -1, -1, -1)$
$z(8)$	$(-1, +1, +1, +1, -1, -1, -1)$
$z(9)$	$(-1, +1, +1, +1, +1, -1, -1)$
$z(10)$	$(-1, -1, +1, +1, +1, -1, -1)$
$z(11)$	$(-1, -1, +1, +1, +1, +1, -1)$
$z(12)$	$(-1, -1, -1, +1, +1, +1, -1)$
$z(13)$	$(-1, -1, -1, +1, +1, +1, +1)$
$z(14)$	$(-1, -1, -1, -1, +1, +1, +1)$
$z(15) = z(1)$	$(+1, -1, -1, -1, +1, +1, +1)$

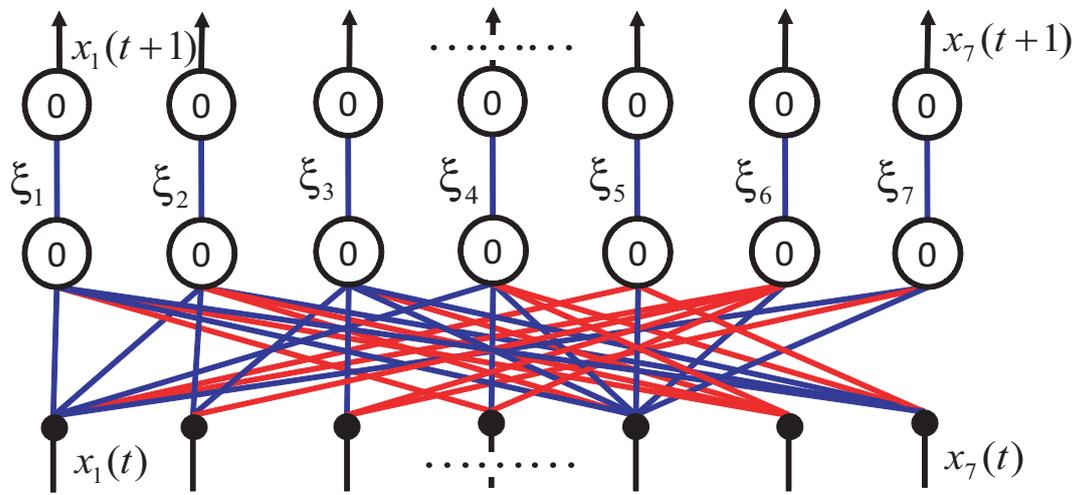


図 3.5: 表 3.2 に対する DBNN (インバータのスイッチ制御信号)

表 3.3: 表 3.2 に対する学習後のパラメータ (インバータのスイッチ制御信号)

j	w_{j1}	w_{j2}	w_{j3}	w_{j4}	w_{j5}	w_{j6}	w_{j7}	β_j
1	+1	0	0	-1	+1	-1	+1	5
2	+1	+1	0	0	-1	-1	+1	5
3	0	+1	+1	0	+1	-1	+1	5
4	+1	0	0	+1	+1	-1	-1	5
5	-1	0	0	0	+1	0	-1	3
6	-1	-1	-1	-1	+1	0	0	5
7	+1	0	-1	0	+1	0	0	3

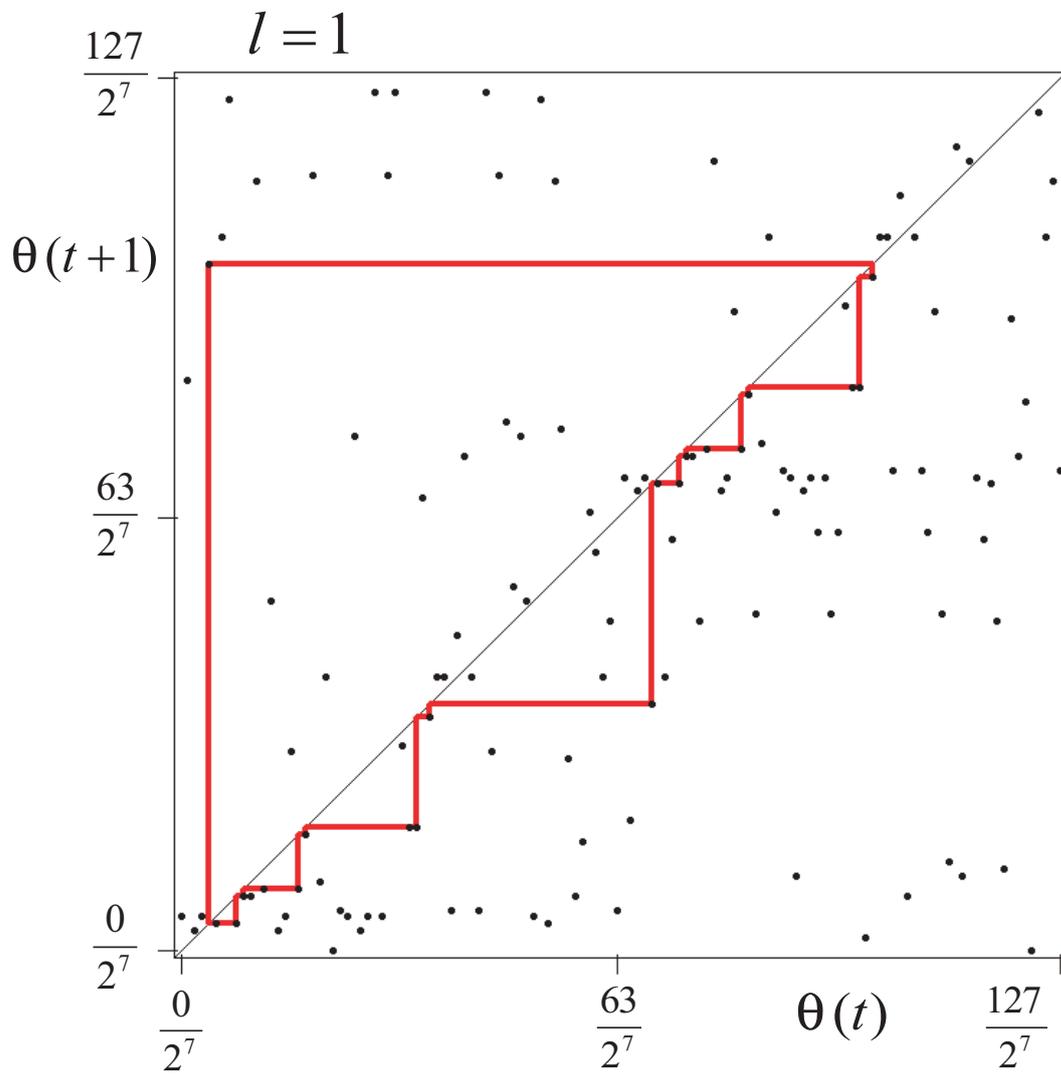


図 3.6: 図 3.5 対応する Gmap (インバータのスイッチ制御信号)

表 3.4: DBNN の教師信号 (2)

$z(1)$	$(-1, -1, -1, -1, +1, +1, +1)$
$z(2)$	$(-1, -1, -1, +1, +1, +1, -1)$
$z(3)$	$(-1, -1, +1, +1, +1, -1, -1)$
$z(4)$	$(-1, +1, +1, +1, -1, -1, -1)$
$z(5)$	$(+1, +1, +1, -1, -1, -1, -1)$
$z(6)$	$(+1, -1, -1, -1, +1, +1, +1)$
$z(7)$	$(+1, -1, -1, +1, +1, +1, -1)$
$z(8)$	$(+1, -1, +1, +1, +1, -1, -1)$
$z(9)$	$(+1, +1, +1, +1, -1, -1, -1)$
$z(10)$	$(+1, +1, -1, -1, +1, +1, +1)$
$z(11)$	$(+1, +1, -1, +1, +1, +1, -1)$
$z(12)$	$(+1, +1, +1, +1, +1, -1, -1)$
$z(13)$	$(+1, +1, +1, -1, +1, +1, +1)$
$z(14)$	$(+1, +1, +1, +1, +1, +1, -1)$
$z(15)$	$(+1, +1, +1, +1, +1, +1, +1)$
$z(16) = z(1)$	$(-1, -1, -1, -1, +1, +1, +1)$

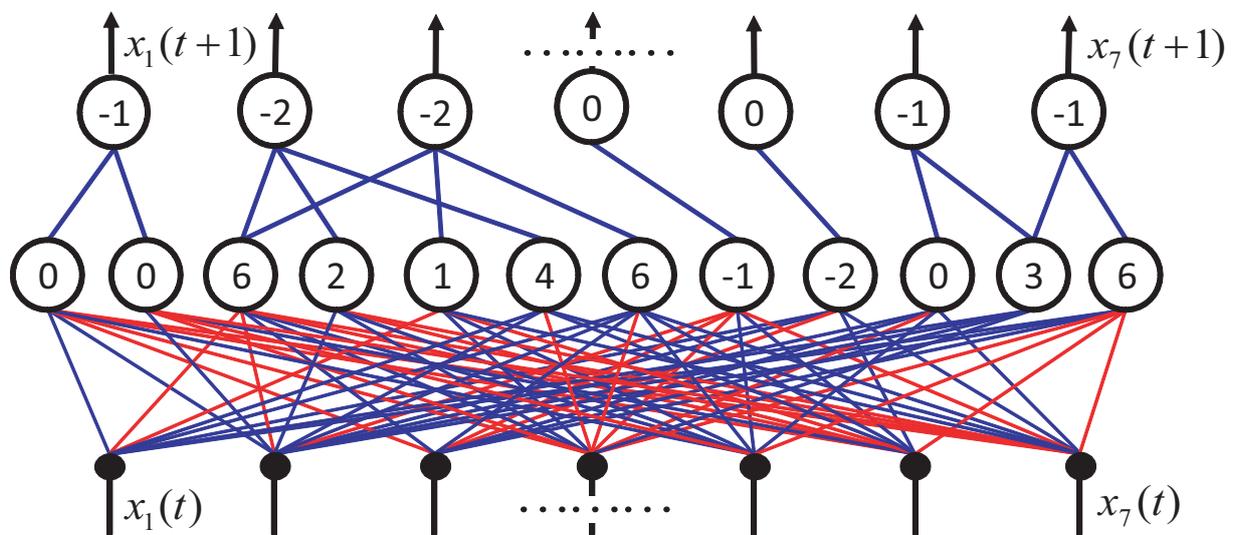


図 3.7: 表 3.4 (教師信号 (2)) に対応する DBNN

表 3.5: 表 3.4 に対応する学習後のパラメータ (教師信号 (2))

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

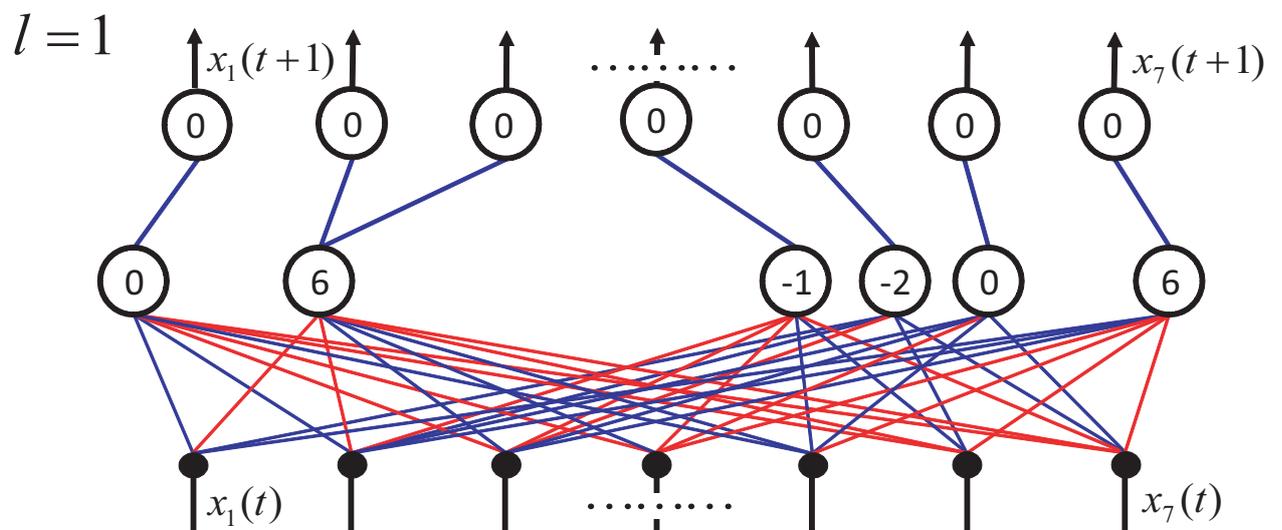


図 3.8: 表 3.4 (教師信号 (2)) に対応する DBNN ($l = 1$)

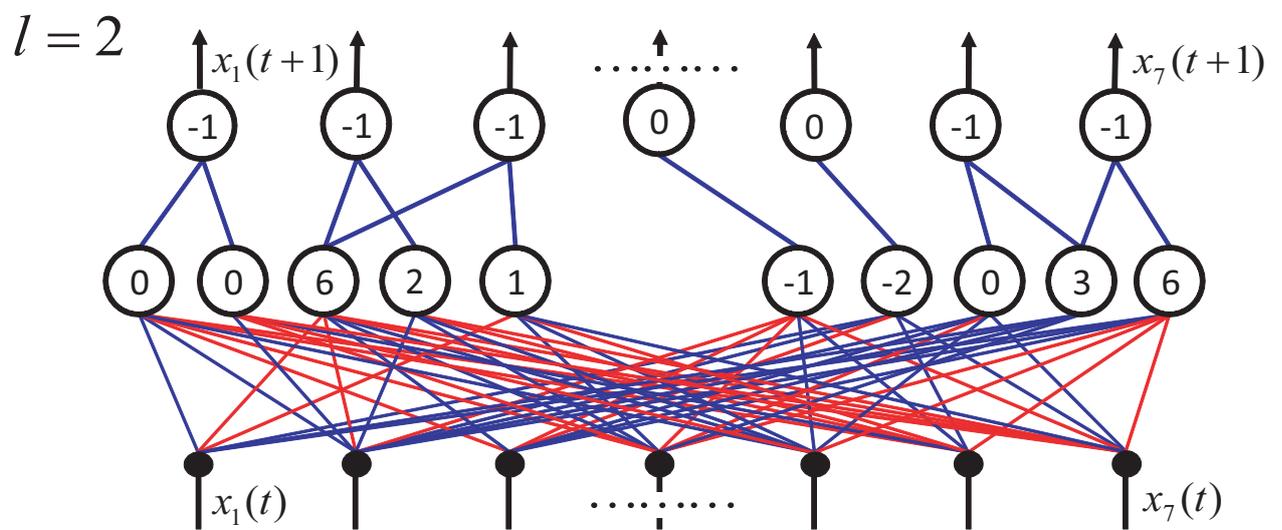


図 3.9: 表 3.4 (教師信号 (2)) に対応する DBNN ($l = 2$)

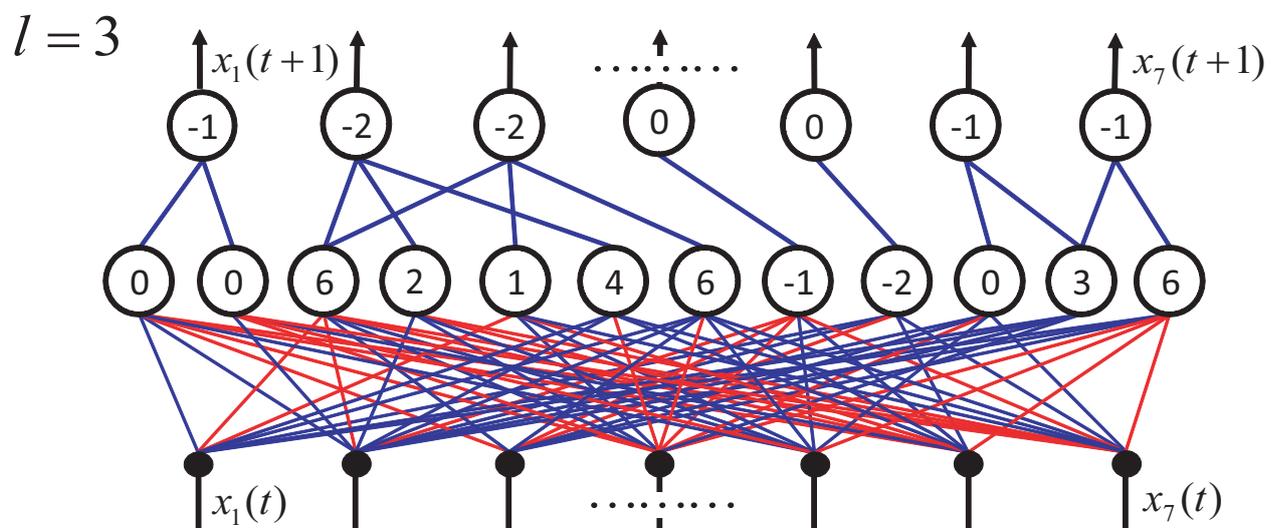


図 3.10: 表 3.4 (教師信号 (2)) に対応する DBNN ($l = 3$)

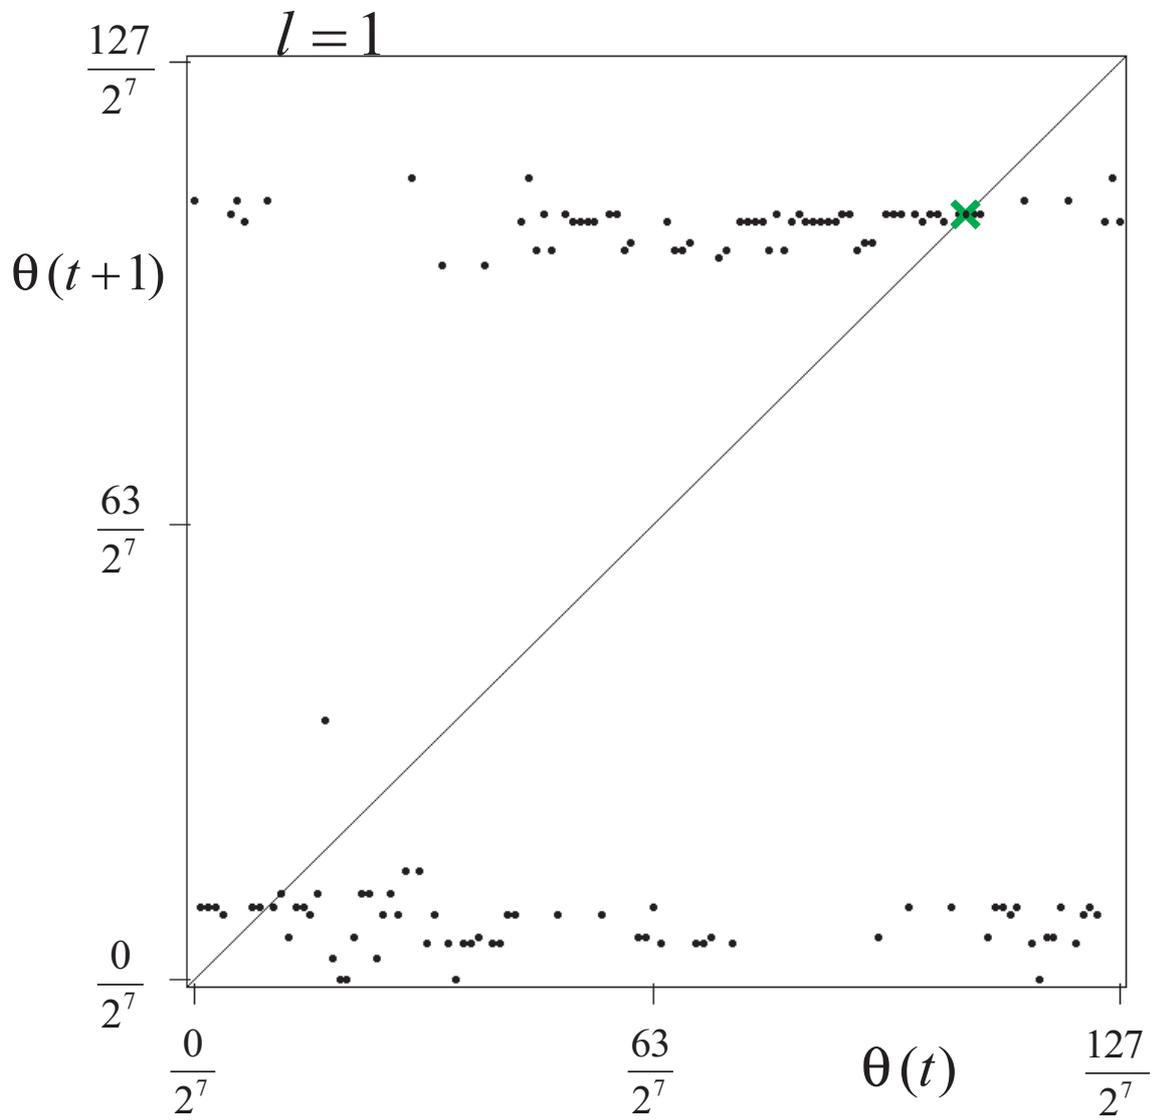


図 3.11: 図 3.8 に対応する $G_{\text{map}} (l = 1)$

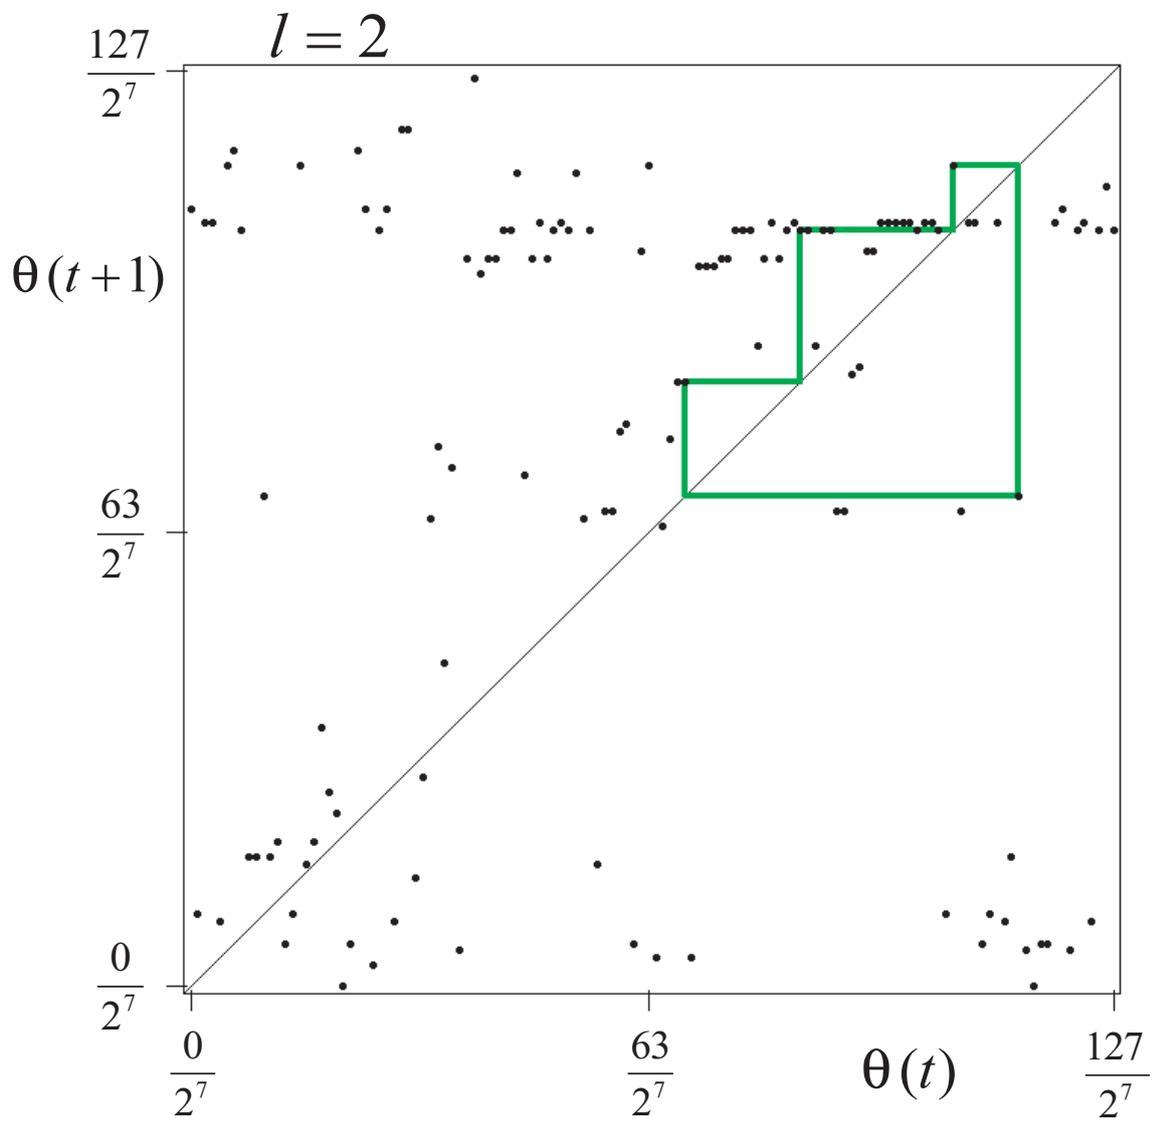


図 3.12: 図 3.9 に対応する $G_{\text{map}} (l = 2)$

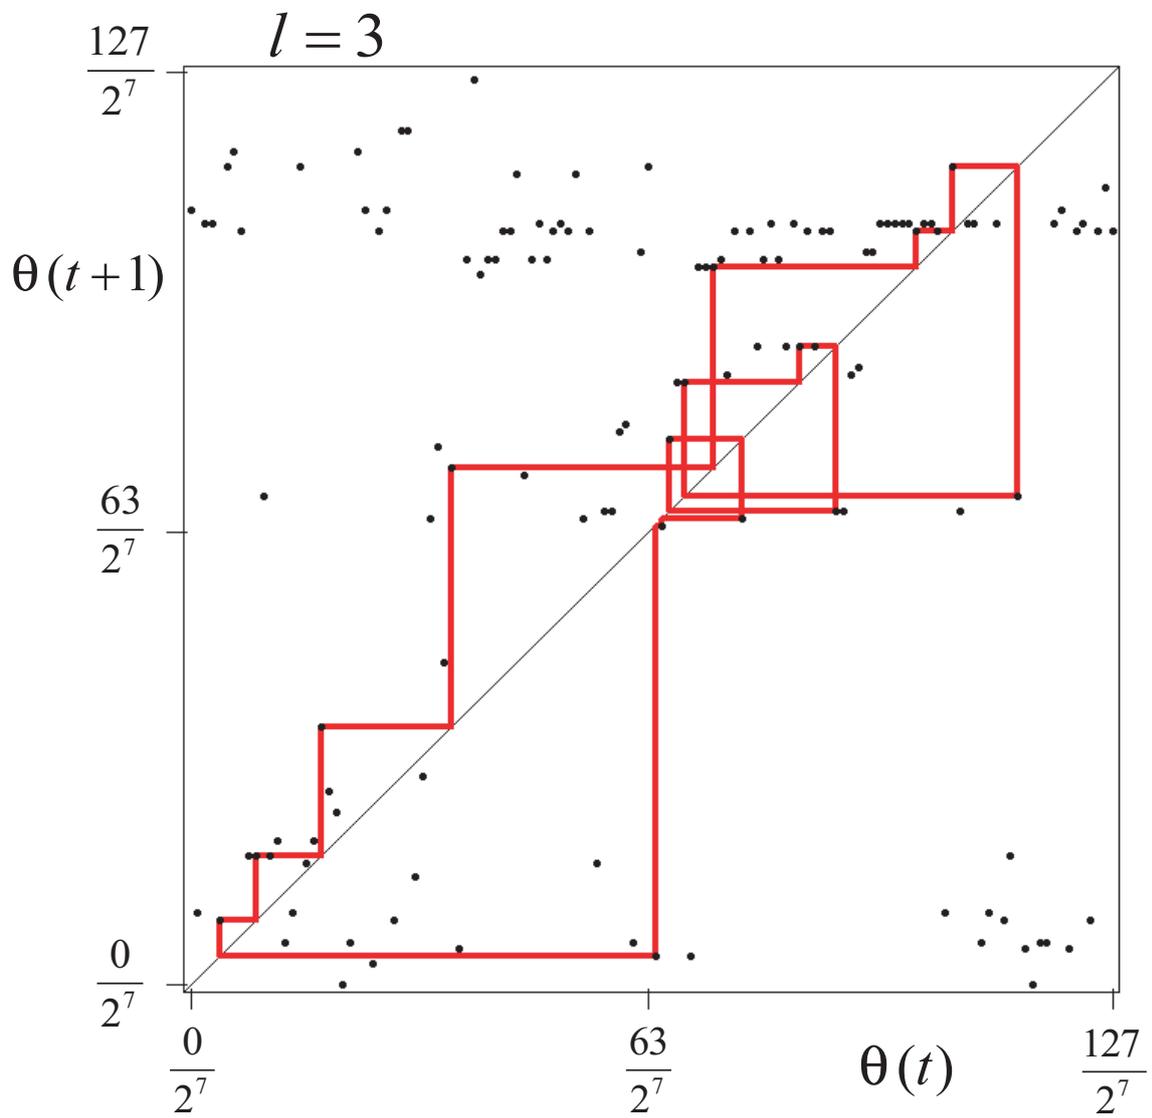


図 3.13: 図 3.10 に対応する Gmap ($l = 3$)

表 3.6: 教師信号 (3)

$z(1)$	$(-1, +1, -1, +1, -1, +1, +1)$
$z(2)$	$(-1, +1, -1, +1, +1, +1, +1)$
$z(3)$	$(-1, +1, -1, -1, +1, -1, +1)$
$z(4)$	$(-1, +1, +1, -1, -1, +1, +1)$
$z(5)$	$(-1, -1, +1, -1, -1, -1, +1)$
$z(6)$	$(+1, -1, +1, +1, +1, +1, -1)$
$z(7)$	$(+1, -1, -1, +1, -1, +1, -1)$
$z(8)$	$(+1, -1, -1, -1, -1, -1, -1)$
$z(9) = z(1)$	$(-1, +1, -1, +1, -1, +1, +1)$

表 3.7: 学習後のパラメータ (教師信号 (3))

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

$l = 1$

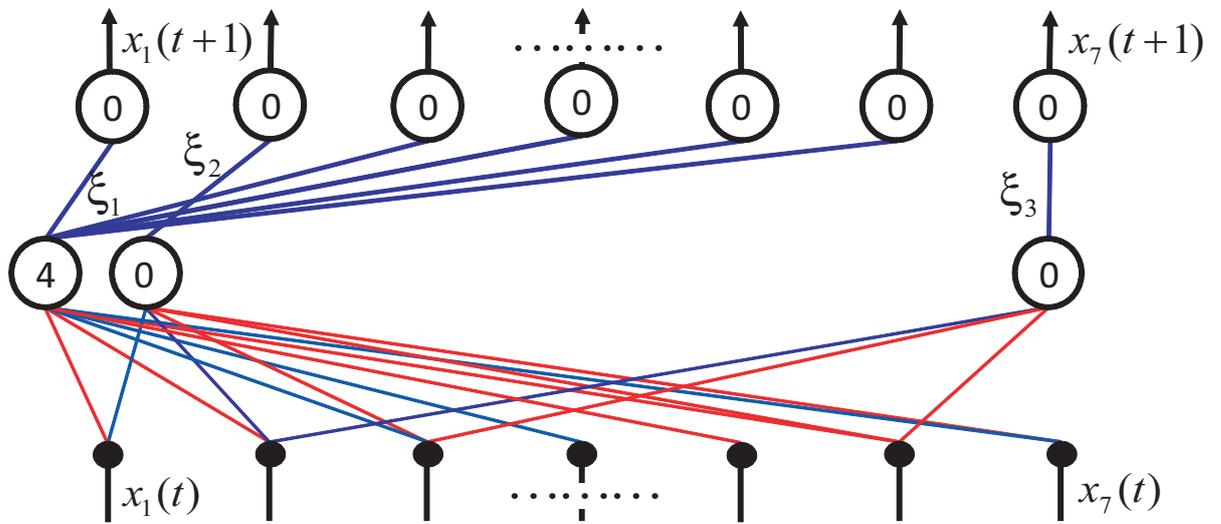


図 3.14: 表 3.6 (教師信号 (3)) に対応する DBNN ($l = 1$)

$l = 2$

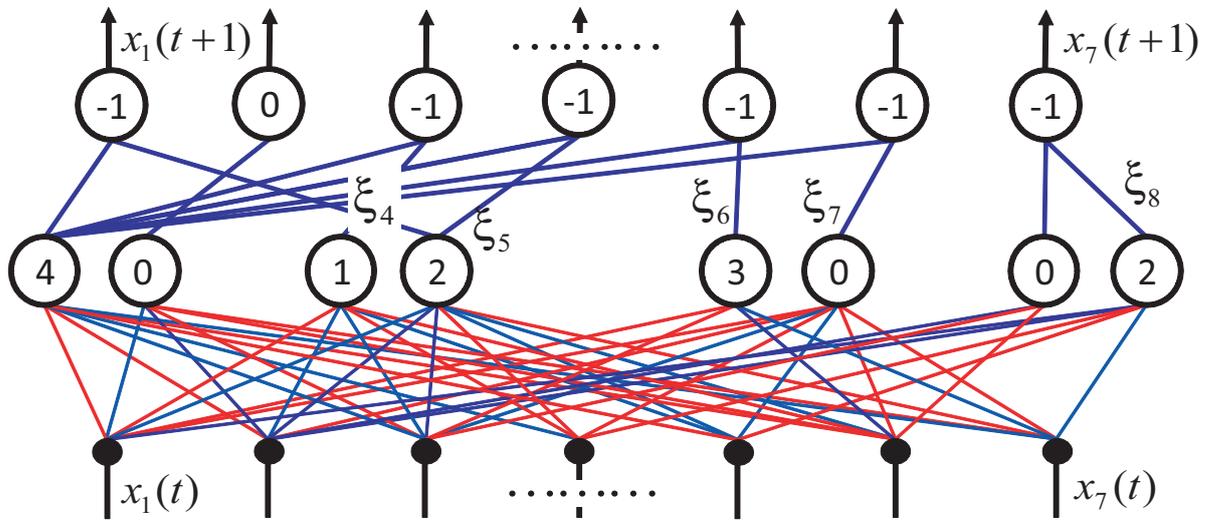


図 3.15: 表 3.6 (教師信号 (3)) に対応する DBNN ($l = 2$)

$l = 3$

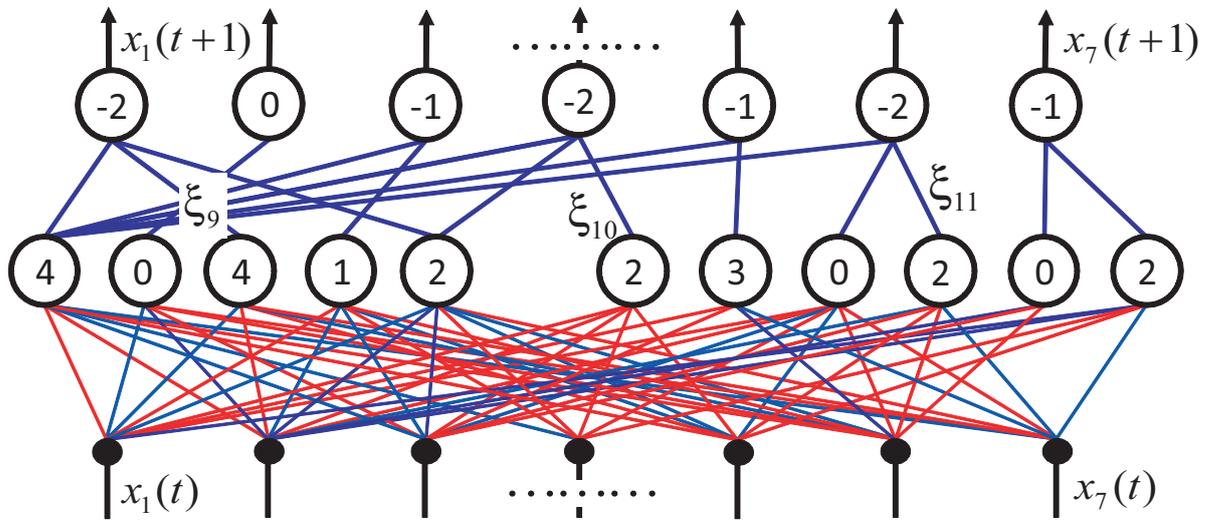


図 3.16: 表 3.6 (教師信号 (3)) に対応する DBNN ($l = 3$)

$l = 4$

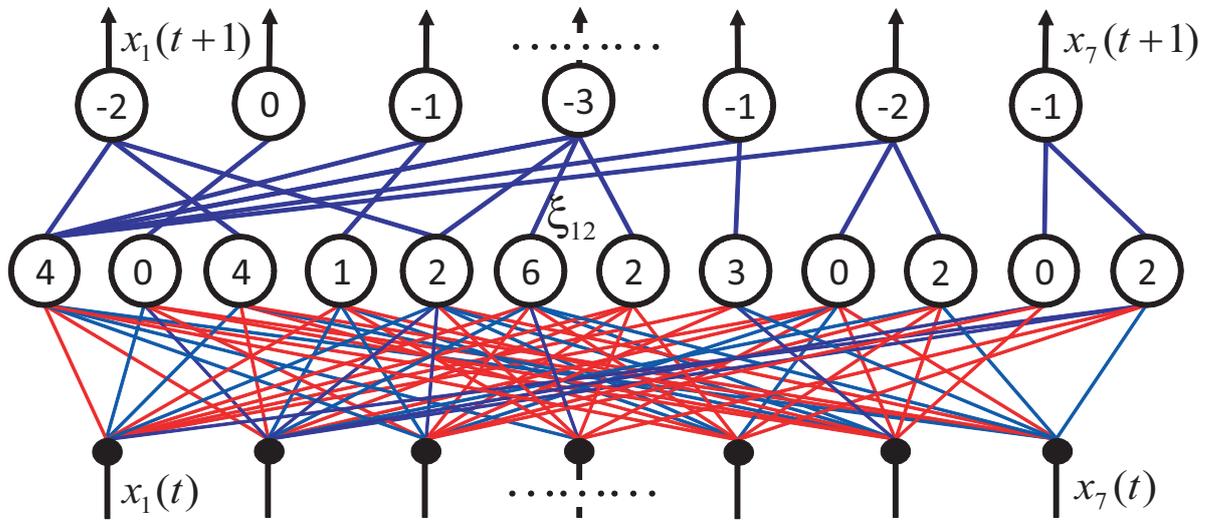


図 3.17: 表 3.6 (教師信号 (3)) に対応する DBNN ($l = 4$)

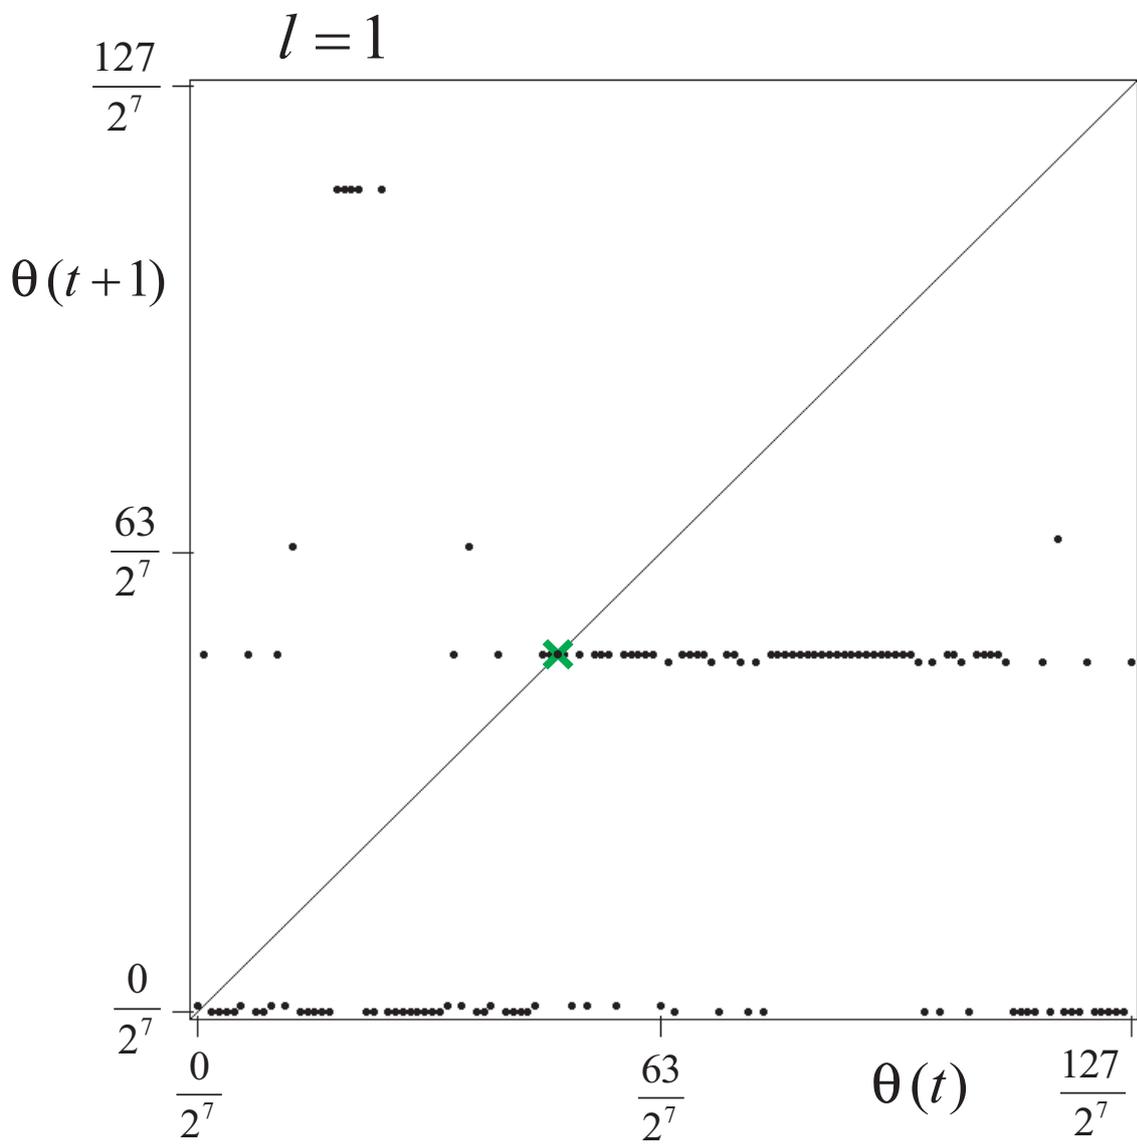


図 3.18: 図 3.14 に対応する $G_{\text{map}} (l = 1)$

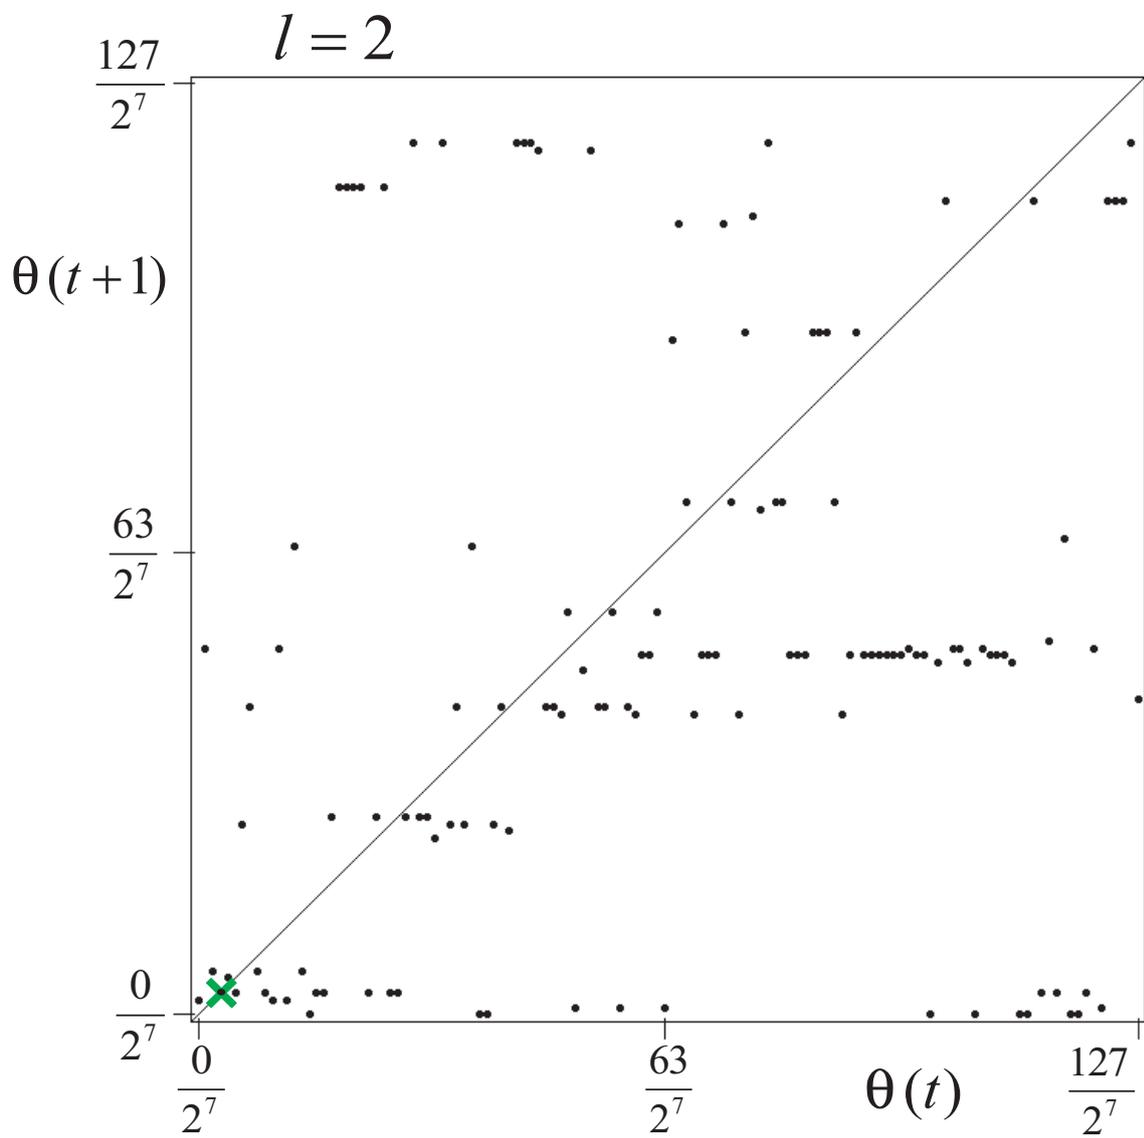


図 3.19: 図 3.15 に対応する $G_{\text{map}} (l = 2)$

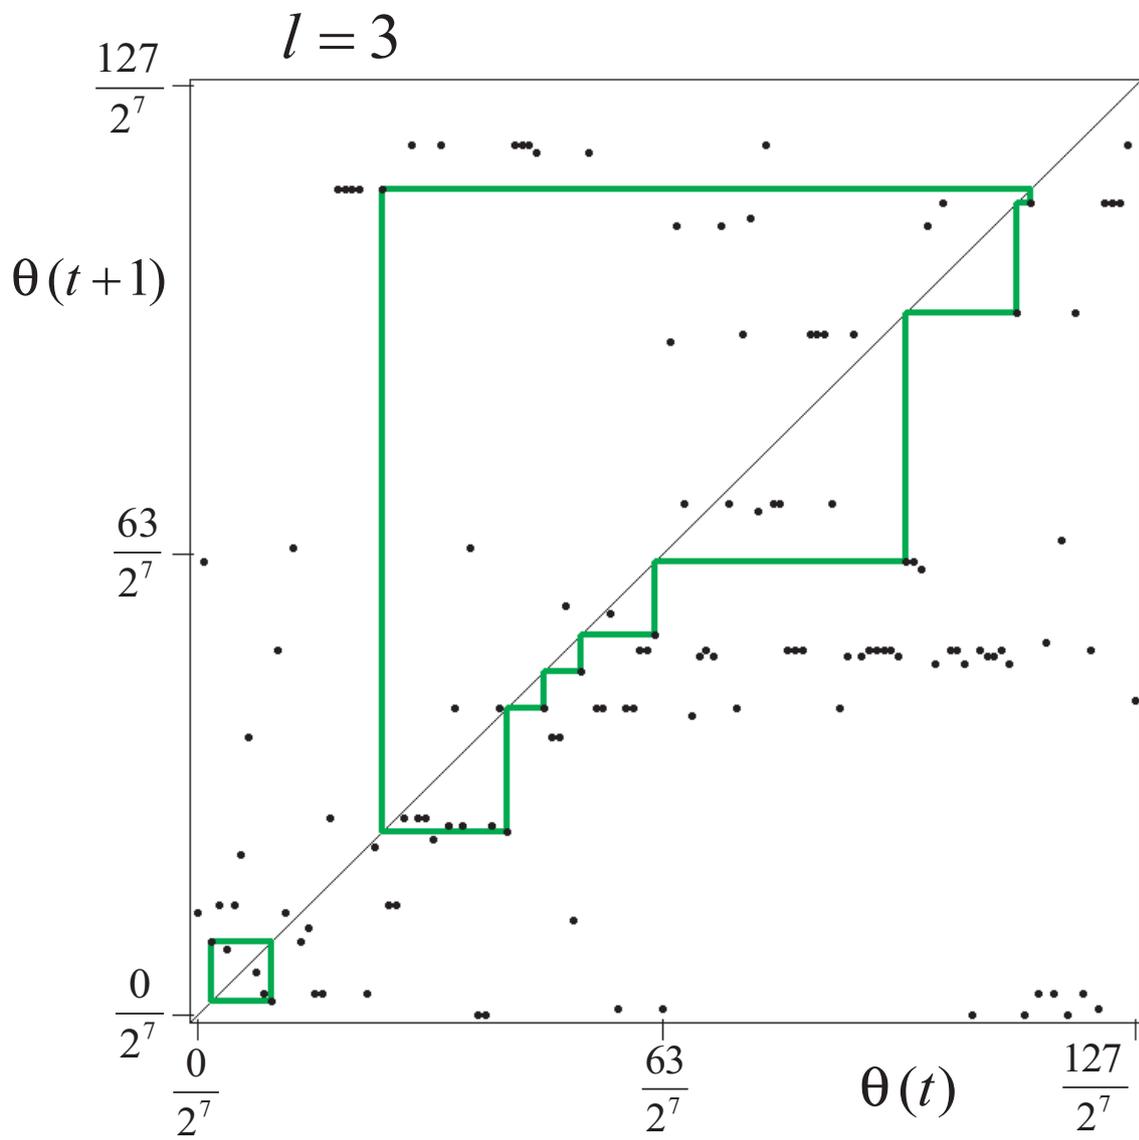


図 3.20: 図 3.16 に対応する $G_{\text{map}} (l = 3)$

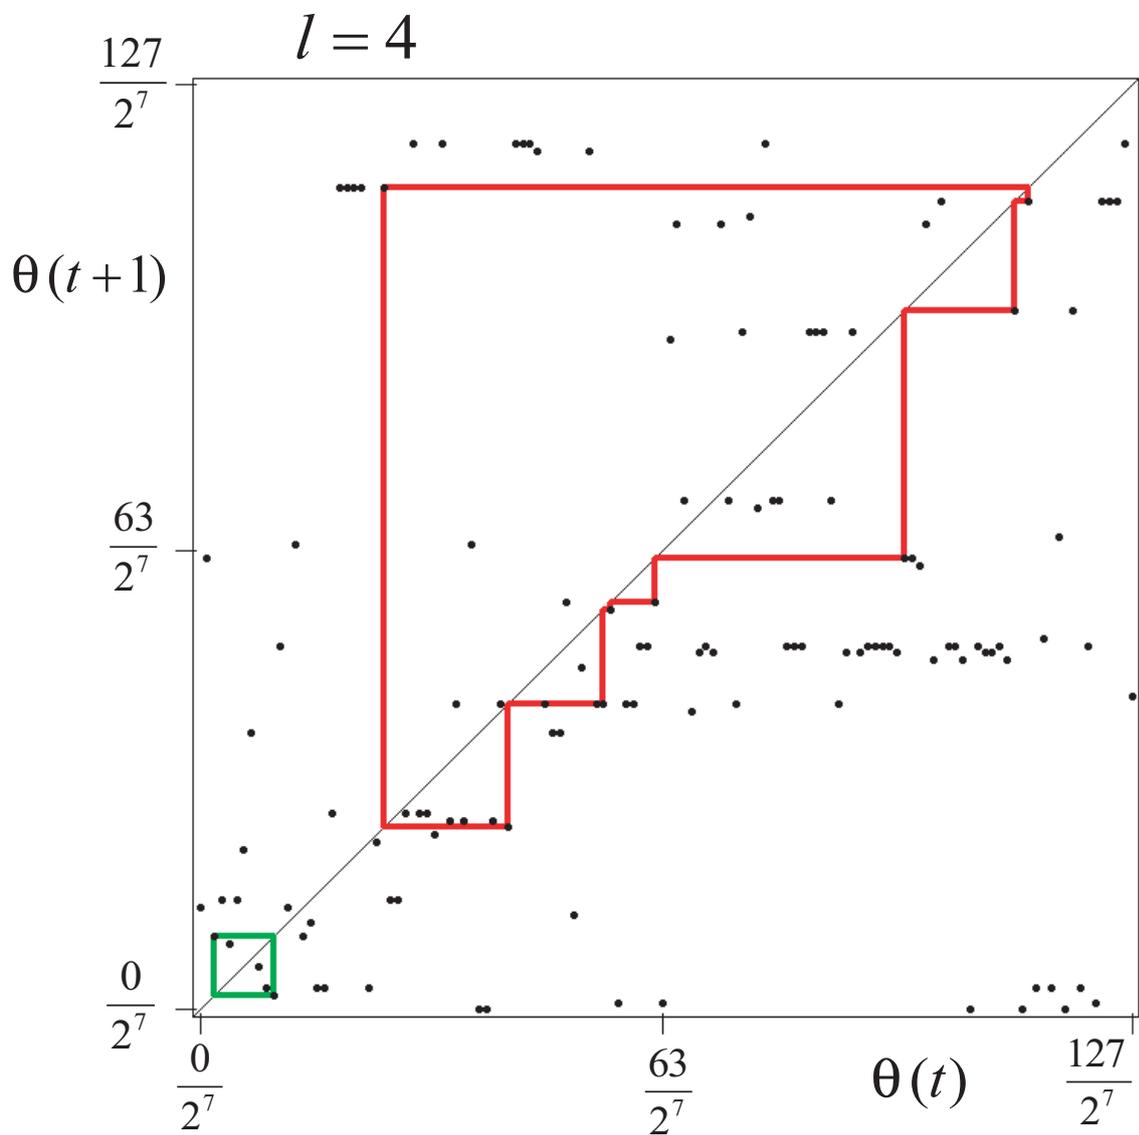


図 3.21: 図 3.17 に対応する $G_{\text{map}} (l = 4)$

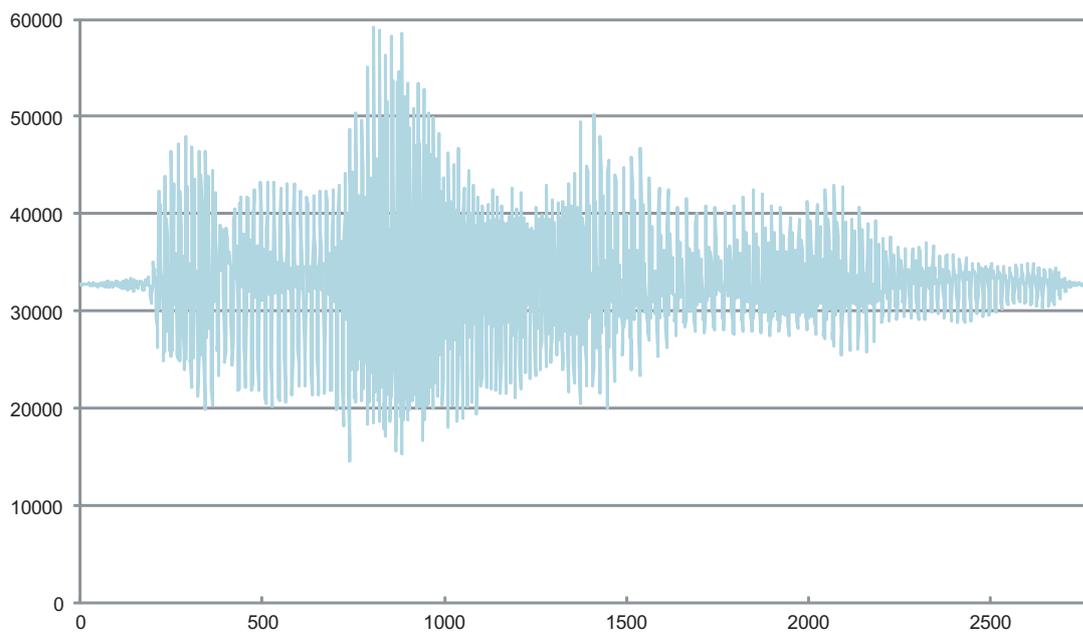


図 3.22: 音声データ

表 3.8: 教師信号 (音声データ)

$z(1)$	$(+1, -1, +1, -1, +1, -1, -1, -1)$
$z(2)$	$(-1, -1, +1, +1, -1, -1, -1, -1)$
$z(3)$	$(+1, +1, -1, +1, +1, -1, -1, -1)$
$z(4)$	$(+1, -1, -1, +1, -1, +1, +1, +1)$
$z(5)$	$(-1, +1, -1, +1, +1, -1, -1, -1)$
$z(6)$	$(+1, +1, +1, -1, +1, +1, +1, +1)$
$z(7)$	$(+1, +1, -1, -1, +1, +1, +1, +1)$
$z(8)$	$(-1, -1, -1, +1, -1, +1, -1, -1)$
$z(9)$	$(+1, +1, +1, +1, -1, -1, -1, -1)$
$z(10)$	$(-1, -1, +1, +1, +1, -1, -1, -1)$
$z(11) = z(1)$	$(+1, -1, +1, -1, +1, -1, -1, -1)$

表 3.9: 学習後のパラメータ (音声データ)

j	w_{j1}	w_{j2}	w_{j3}	w_{j4}	w_{j5}	w_{j6}	w_{j7}	w_{j8}	β_j
1	-1	-1	-1	+1	0	-1	-1	0	5
2	-1	0	+1	-1	+1	0	+1	0	3
3	-1	0	-1	0	-1	-1	+1	0	5
4	-1	+1	+1	+1	+1	0	-1	+1	5
5	+1	-1	+1	-1	+1	-1	-1	-1	1
6	+1	+1	+1	0	-1	0	-1	+1	3
7	0	0	-1	+1	0	+1	-1	-1	1
8	0	-1	-1	-1	-1	0	+1	-1	7
9	+1	+1	0	0	0	-1	0	0	1
10	-1	+1	+1	0	0	0	+1	-1	5
11	+1	-1	0	0	-1	0	+1	+1	1
12	-1	+1	-1	-1	+1	0	+1	-1	7
13	0	+1	0	+1	+1	-1	-1	0	1

$l = 1$

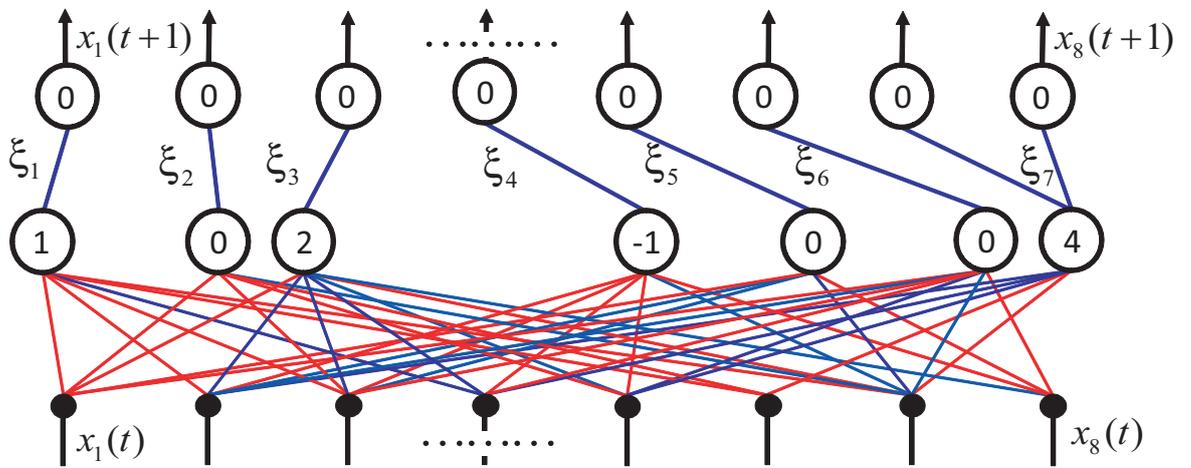


図 3.23: 表 3.8 に対応する音声データの DBNN ($l = 1$)

$l = 2$

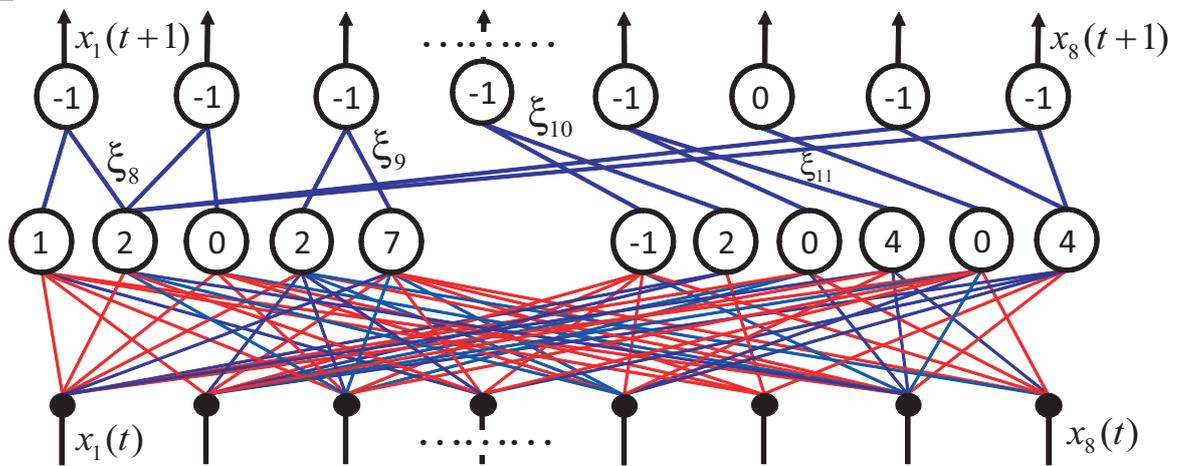


図 3.24: 表 3.8 に対応する音声データの DBNN ($l = 2$)

$l = 3$

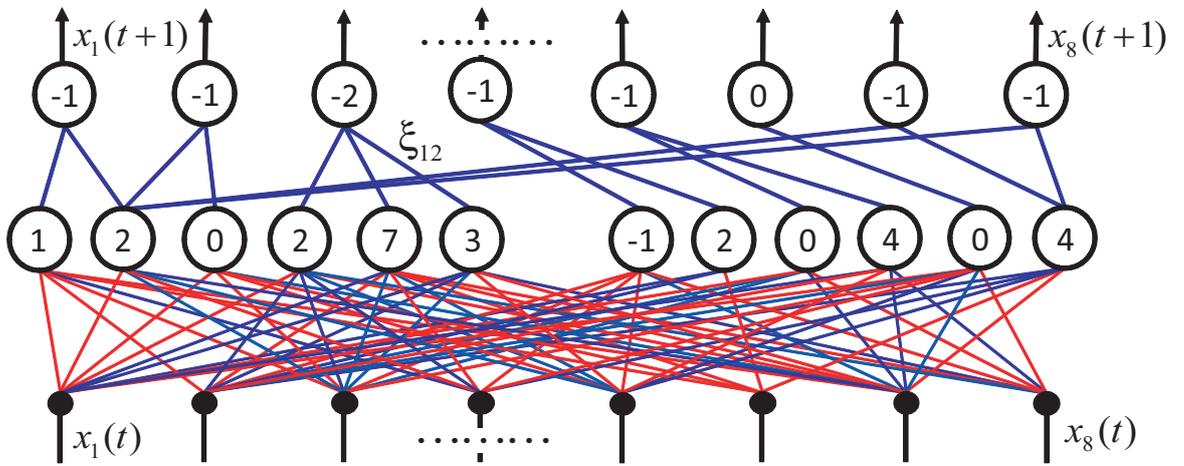


図 3.25: 表 3.8 に対応する音声データの DBNN ($l = 3$)

$l = 4$

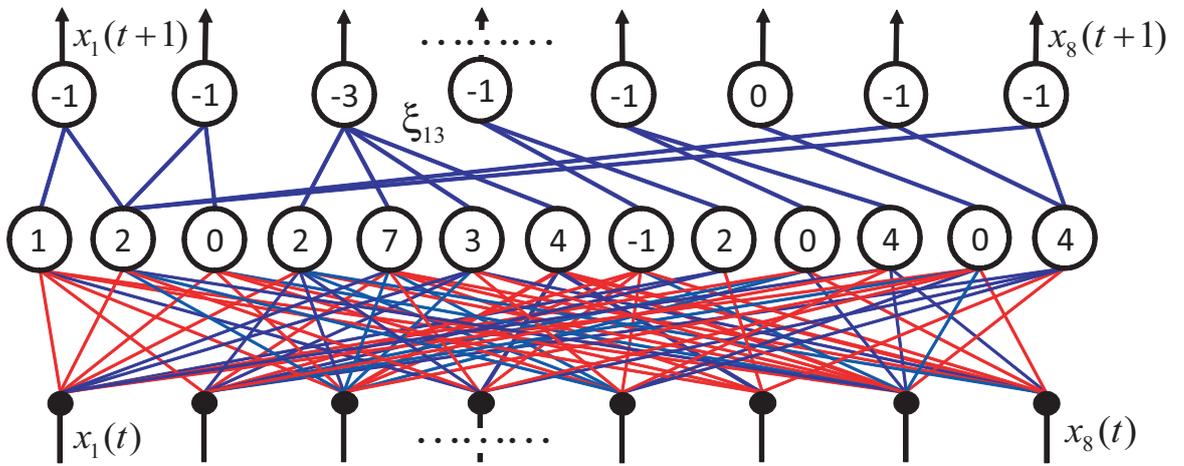


図 3.26: 表 3.8 に対応する音声データの DBNN ($l = 4$)

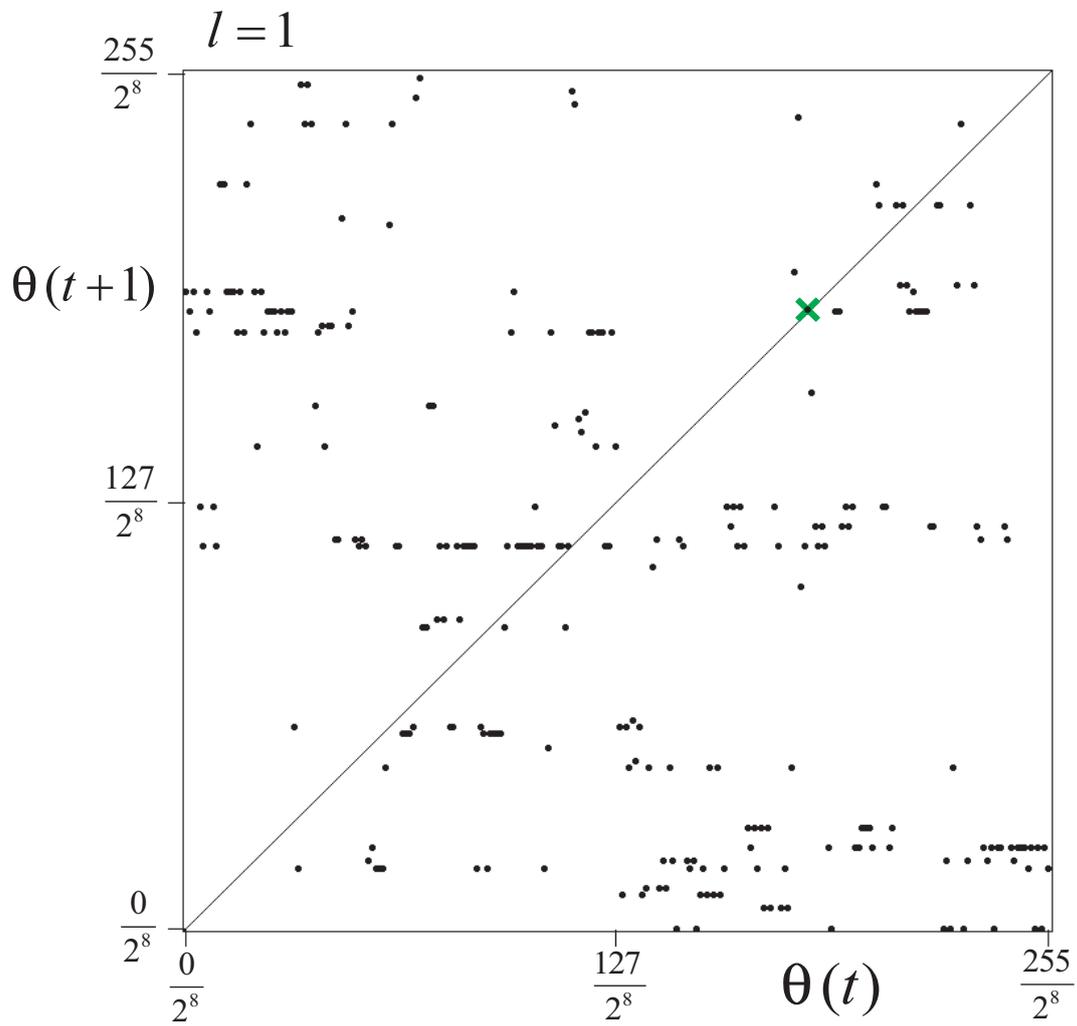


図 3.27: 図 3.23 に対応する音声データの Gmap ($l = 1$)

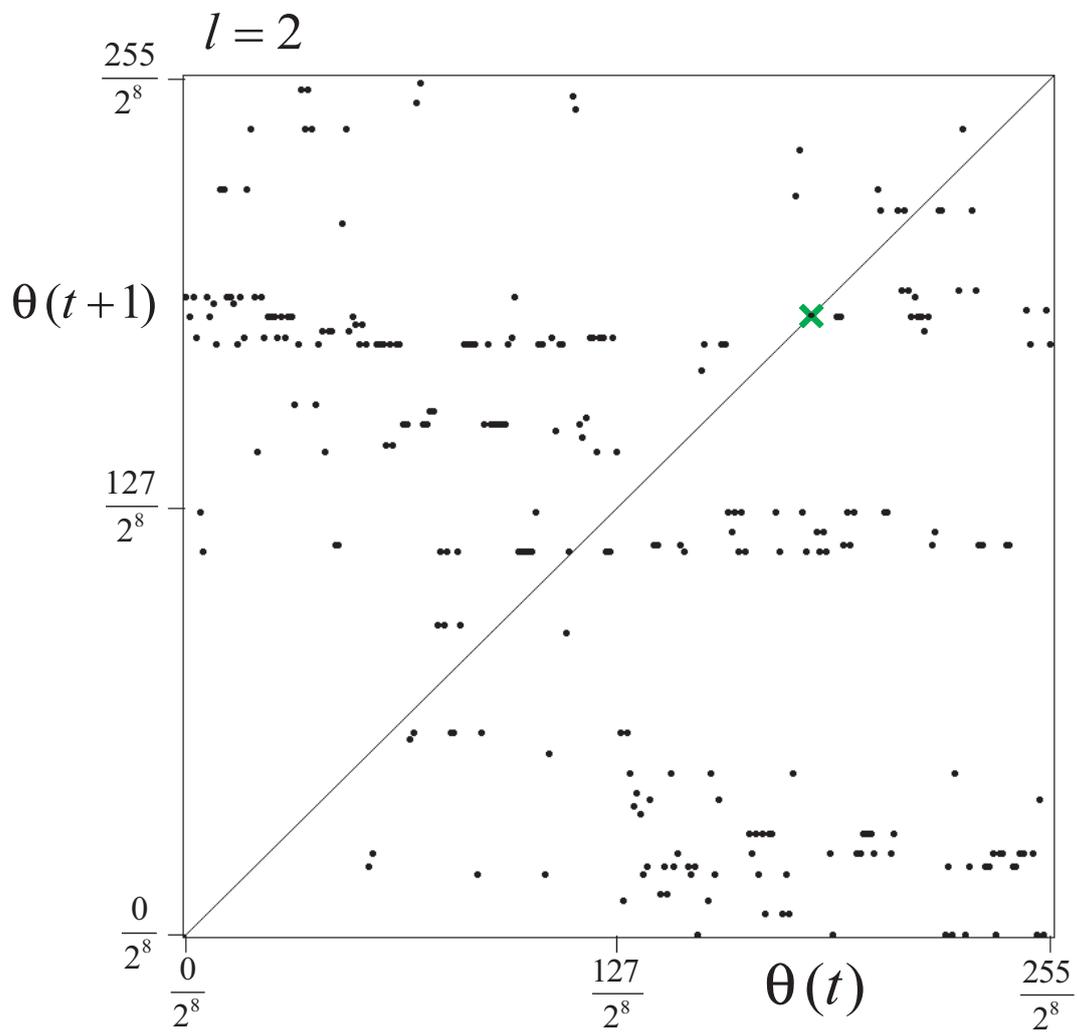


図 3.28: 図 3.24 に対応する音声データの Gmap ($l = 2$)

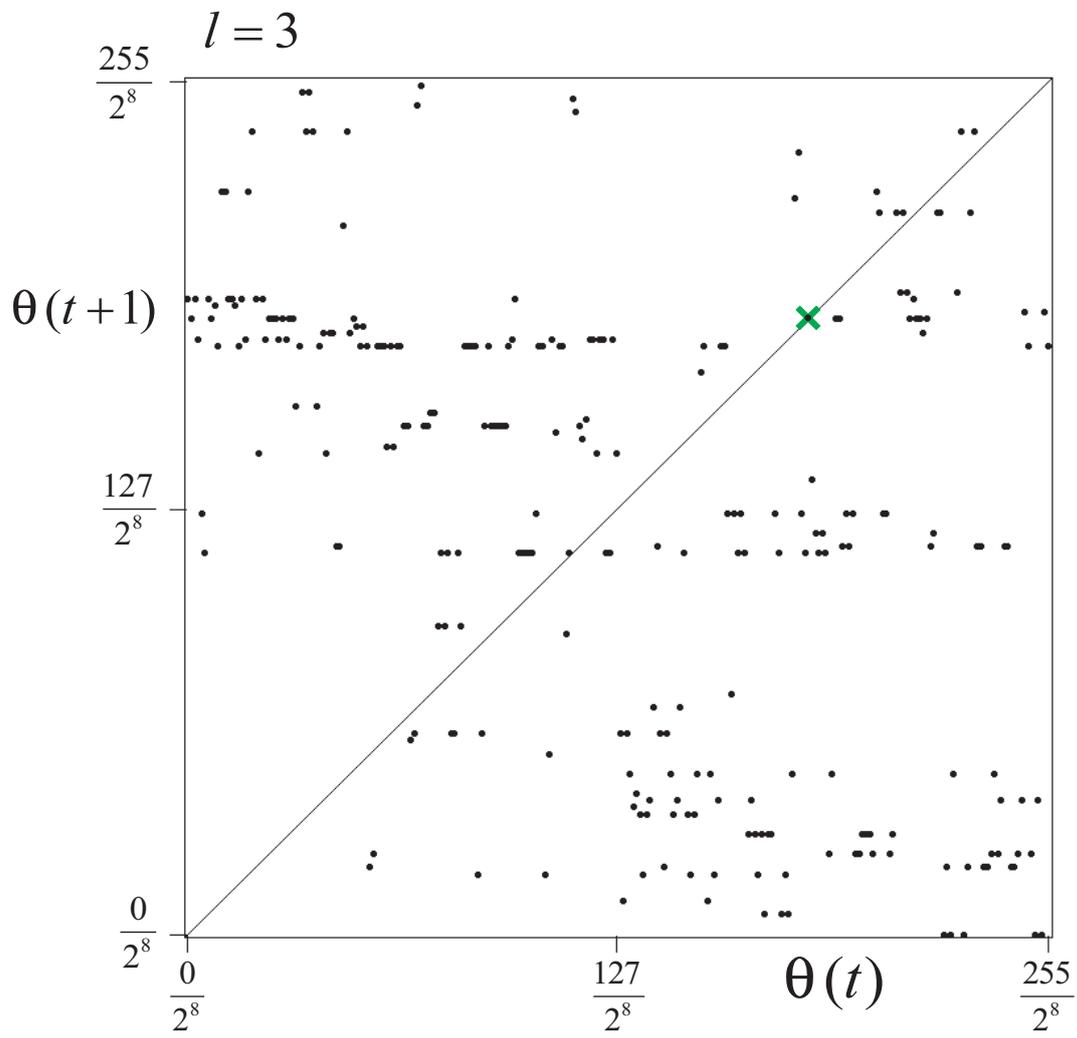


図 3.29: 図 3.25 に対応する音声データの Gmap ($l = 3$)

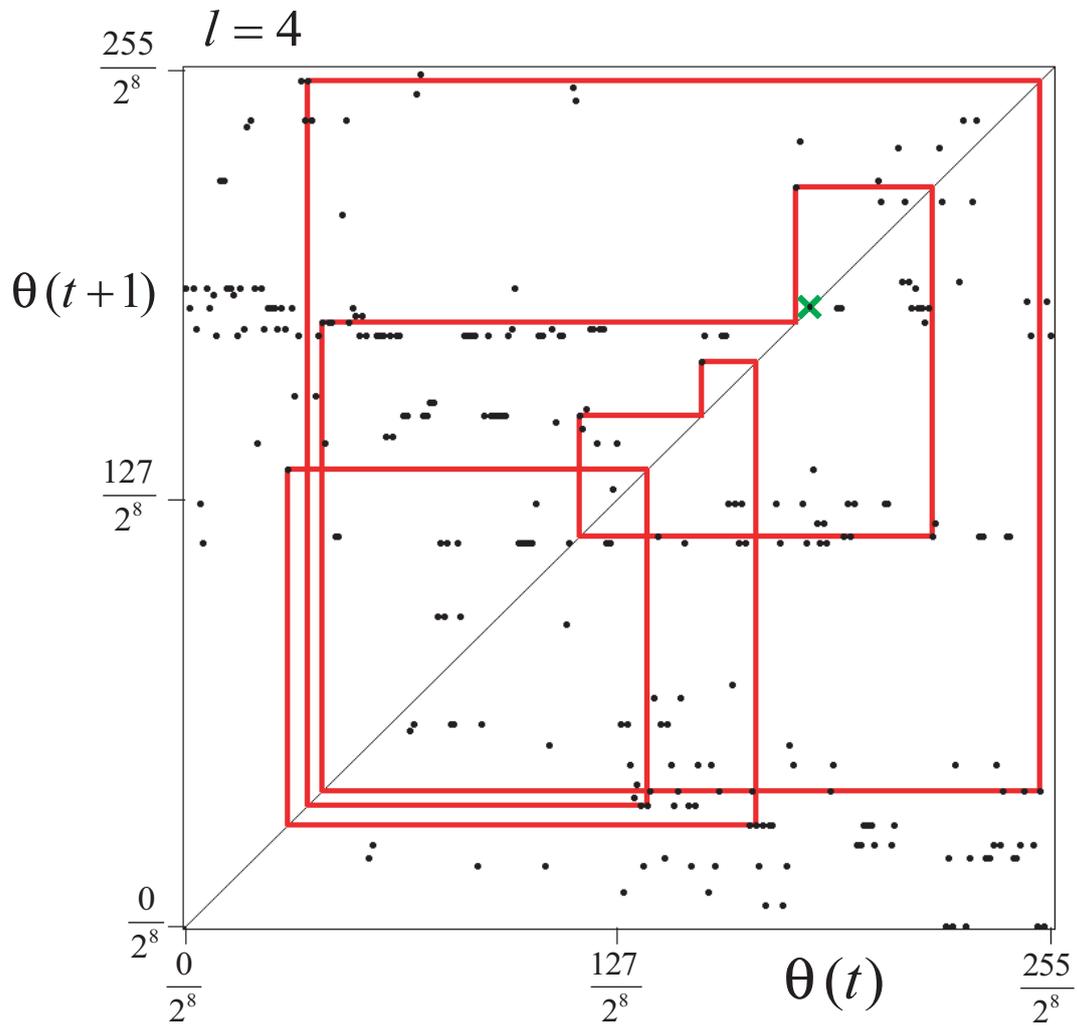


図 3.30: 図 3.26 に対応する音声データの Gmap ($l = 4$)

第4章 むすび

DBNN の GA を基にした学習方法を提案し基本的な計算機実験によって中間層ニューロン数や学習時間の増加を抑制できていることを確認した。また、DBNN を解析する解析手法 Gmap を紹介し、実際の計算機実験によって DBNN と Gmap の関係について確認した。多くの信号を動的な二値パターンとして生成することのできる DBNN は、簡素な周期信号パターンの生成や構築に適していると考ええる。また、DBNN は簡素な信号や特定の信号に対しては周期信号パターンを 1 つしかもたないことや、信号が教師信号へと収束、安定することから制御回路のスイッチ等の信号に DBNN を適応することが適していると考ええる。しかしながら、DBNN は大規模な計算機実験や高次元な問題に適応することを考えると、DBNN にはまだ学習アルゴリズムの改善が必要であると考える。今後の課題は、特に制御回路系の信号への DBNN の適応や解析、大規模な計算機実験に適応できる学習アルゴリズムの改善、GA パラメータの解析などが挙げられる。

参考文献

- [1] 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.
- [2] J. H. Kim and S. K. Park, The geometrical learning of binary neural networks. *IEEE Trans. Neural Networks*, 6, 1, pp. 237-247, 1995.
- [3] M. Muselli and D. Liberati, Training digital circuits with hamming clustering. *IEEE Trans. Circuits Syst. I*, 47, 4, pp. 513-527, 2000.
- [4] 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.
- [5] F. Chen, G. Chen, Q. He, G. He, and X. Xu, Universal perceptron and DNA-like learning algorithm for binary neural networks: LSBF and PBF implementations, *IEEE Trans. Neural Networks*, 20, 10, pp. 1645-1658, 2009
- [6] C. Zhang, J. Yang and W. Wu, Binary higher order neural networks for realizing boolean functions, *IEEE Trans. Neural Networks*, 22, 5, pp. 701-713, 2011
- [7] A. Yamamoto and T. Saito, A flexible learning algorithm for binary neural networks, *IEICE Trans. Fundamentals*, E81-A, 9, pp. 1925-1930, 1998.
- [8] M. Shimada and T. Saito, A simple learning of binary neural networks with virtual teacher signals, in *Proc. IEEE-INNS IJCNN*, pp. 2042-2047, 2001.

- [9] 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.
- [10] R. Ito and T. Saito, Dynamic binary neural networks and evolutionary learning. in *Proc. IEEE-INNS IJCNN*, pp. 1683-1687, 2010.
- [11] R. Ito, Y. Nakayama and T. Saito, Learning of dynamic BNN toward storing-and-stabilizing periodic patterns, in *Proc. ICONIP*, pp. 606-611, 2011.
- [12] E. Ott, *Chaos in dynamical systems*, Cambridge Univ. Press, 1993.
- [13] T. Saito, H. Torikai and W. Schwarz, Switched dynamical systems with double periodic inputs: an analysis tool and its application to the buck-boost converter, *IEEE Trans. Circuits Syst. I*, 47, 7, pp. 1038-1046, 2000.
- [14] 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.

研究業績

(論文)

Ryo Ito, Yuta Nakayama and Toshimichi Saito, “ Learning of Dynamic BNN toward Storing-and-Stabilizing Periodic Patterns, ”Proc. of International Conference On Neural Information Processing (ICONIP 2011),pp. 606-611, 2011.

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.

(国際会議)

Ryo Ito, Yuta Nakayama and Toshimichi Saito, “ Analysis and Learning of Periodic Orbits in Dynamic Binary Neural Networks, ”Proc. IJCNN 2012 Submitted.

Y. Nakayama, R. Ito and T. Saito, “ Evolutionary Learning of Binary Neural Networks and Its Application to Logical Synthesis, ”Proc. of International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC 2011), pp. 1036-1039, 2011.

Ryo Ito, Toshimichi Saito, “ Dynamic Binary Neural Networks and Evolutionary Learning, ”Proc. of IEEE- International Joint Conference on Neural Networks (IJCNN 2010), pp. 1683-1687, 2010.

(国内発表)

齋藤利通, 伊藤良, 中山雄太, “ 動的バイナリニューラルネットとその学習について, ” 電子情報通信学会ソサイエティ大会, AK-1-1, 2012年3月.

上月良太, 伊藤良, 齋藤利通 “ 混合ルールに基づくセルラ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, 会津, 2012年1月.

Yuta Nakayama, Ryo Ito, Toshimichi Saito, “ Sequential Learning of Binary Neural Networks based on Genetic Algorithm, ” Proc. IEEE Workshop on Nonlinear Circuit Networks, pp. 48-50, 徳島, 2011年12月.

上月良太, 伊藤良, 齋藤利通, “ 空間にルールを組み合わせたセルラ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年9月.

中山雄太, 伊藤良, 齋藤利通, “ 論理合成のためのバイナリニューラルネットの学習について, ” 電子情報通信学会技術研究報告 (NLP 研究会), vol. 111, no. 62, pp. 49-53, 香川, 2011年5月.

中山雄太, 伊藤良, 齋藤利通, “ バイナリニューラルネットと論理合成, ” 電子情報通信学会総合大会, A-2-8, 東京, 2011年3月.

伊藤良, 齋藤利通, “ GAに基づく、動的バイナリニューラルネットの学習, ” 電子情報通信学会技術研究報告 (NC 研究会), vol. 110, no. 461, NC2010-157, pp. 177-182, 東京, 2011年3月.

中山雄太, 伊藤良, 齋藤利通, “ バイナリニューラルネットによる論理合成へのアプローチ, ” 電子情報通信学会技術研究報告 (NLP 研究会), vol. 110, no. 299, pp. 43-47, 仙台, 2010年11月.

伊藤良, 齋藤利通, “ 動的バイナリニューラルネットワークの学習について, ” 電子情報通信学会技術研究報告 (NLP 研究会), vol. 110, no. 255, pp. 75-80, 大阪, 2010年10

月.

伊藤良, 斎藤利通, “ N-N バイナリーニューラルネットワークの進化的学習アルゴリズム, ”回路とシステム軽井沢ワークショップ, A1-2-2, pp. 7-10, 軽井沢, 2010年4月.

伊藤良, 斎藤利通, “ バイナリーニューラルネットのあいまい学習について, ”日本神経回路学会 (JNNS), 宮城, 2009年9月.

謝辞

本研究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に行ったものである。この研究は同大学理工学部電気電子工学科 斎藤利通教授の指導下で行ったもので、全ての研究活動を遂行するにあたり同教授から大変御参考になる御指導・御鞭撻を沢山賜りました。ここに心から深謝いたします。

また、研究活動中に貴重な御助言・御討論を賜りました日本工業大学工学部電気電子工学科 神野健哉 教授、株式会社日立メディコ 壁谷秀太郎氏には感謝の意を表明いたします。

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。ここに感謝の意を表します。