

# 遺伝的アルゴリズムに基づく 動的バイナリニューラルネットの学習

Learning of Dinamic Binary Neural Networks based on Genetic Algorithms

中山 雄太<sup>1</sup>  
Yuta Nakayama

斎藤 利通<sup>1</sup>  
Toshimichi Saito

法政大学 理工学部 電気電子工学科<sup>1</sup>  
Department of Electronics and Electrical Engineering, Faculty of Engineering and Science, Hosei University

あらまし

3 値結合パラメータとシグナム活性化関数で特徴づけられる動的バイナリニューラルネットワークを紹介する。また、所望の周期解を教師信号として学習する際に、遺伝的アルゴリズムに基づく学習アルゴリズムを用いる。さらに、マトリックスコンバータの制御信号に対応する教師信号に応用し、その銘記と自動安定化を確認する。

## 1 まえがき

本論文では、3 値の結合パラメータ、整数値をとるしきい値パラメータとシグナム活性化関数で特徴づけられる動的バイナリニューラルネットワーク (DBNN) について紹介する。この DBNN は、 $N$  次元の 2 値入力から  $N$  次元の 2 値出力となるネットワークで構成され、様々な 2 値の周期軌道を生成することができる。このことから、2 値パターンを伴うような現象やデジタル回路による実装の実現に適していると考えられている。しかしながら、DBNN 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、計算コストの上昇などの問題点がある [1]-[3]。

このような DBNN に所望の周期解を学習させるために、遺伝的アルゴリズム (GA) に基づく学習アルゴリズムを導入する。この学習アルゴリズムはオンライン学習を行い、入力された教師信号に対して逐次的に GA を適用してネットワークを構築していく。

また、交流電源から交流出力へ直接電力変換を行うマトリックスコンバータの制御信号に対応する教師信号に応用し、その銘記と自動安定化を確認する。これにより、マトリックスコンバータなどのスイッチング制御に DBNN を適用することができるのか検討を行う。

## 2 動的バイナリニューラルネットワーク

DBNN は図 1 に示す 3 層の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。各ニューロンはシグナム活性化関数を有し、DBNN のダイナミクスは次式で記述される [4]。

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

ただし、 $x(t) \equiv (x_1(t), \dots, x_N(t))$ ,  $x_i(t) \in \{-1, 1\} \equiv B$  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、 $\xi(t) \equiv (\xi_1(t), \dots, \xi_M(t)) \in B$  は  $t$  での  $M$  次元中間出力ベクトルである。また、現在の状態  $x(t)$  は入力ベクトルとして適用され、DBNN は中間層ニューロンを経由して次の状態  $x(t+1)$  を出力する。DBNN は  $N$  次元 2 値ベクトルの写像を実現し、その繰り返しにより様々な時空間パターンを生成することができる。

$$x(t+1) = F_D(x(t)), F_D : B^N \rightarrow B^N \quad (2)$$

中間層ニューロンの結合パラメータ  $w_{ji}$  ( $i = 1 \sim N, j = 1 \sim M$ ) は 3 値であり、これとニューロン数を調整する内部パラメータ  $\beta_j \in \{1, 3, 5, \dots\}$  によってしきい値  $T_j$  が決まる。出力ニューロンは、中間層出力が全て負のときのみ  $-1$  を出力し、その動作は OR 演算と同値である。




図 1 動的バイナリニューラルネットワーク。赤は負結合、青は正結合。

## 3 学習アルゴリズム

我々は教師信号がある周期をもつ 2 値周期軌道であると考え、ここで、教師信号を実現するために GA とオンライン学習を用いたアルゴリズムを説明する。この学習を行うことで、中間層ニューロンと等価となる分離超平面 (SHP):  $\sum_{i=1}^N w_{ji} x_i(t) - T_j = 0$  を決定する。与えられた教師信号に対して中間層ニューロンのパラメータは以下のように決定する。

Step 1: (初期化) 中間層ニューロンの番号  $j = 0$  とする。

Step 2: (SHP 構成) まず、教師信号を入力する。次に、その入力された教師信号と既に存在している各 SHP の距離を求める。これは、各 SHP に対してその教師信号が分離されるときのパラメータ  $\beta$  を求めることに対応す

る。これにより、入力された教師信号に最も近い SHP を選択することができる。この最も近い SHP のパラメータを基にして、GA を適用し、中間層ニューロンパラメータの再構築を行う。SHP が存在しない、または、既存 SHP による教師信号の分離が不可能な場合、入力された教師信号のみを分離するパラメータをもつ SHP を作成し、 $j = j + 1$  とする。

Step 3: (SHP 共有) 作成されたり、再構築された SHP は他の出力の分離に適用できるかを検討する。適用可能であれば他の出力の分離にも適用する。

Step 4: 全ての教師信号の入力が終了するまで繰り返す。

GA サブルーチン

GA パラメータは染色体数  $M_g$ , 交叉確率  $P_c$ , 突然変異確率  $P_m$ , 最大世代数  $G_{max}$  である。GA の  $M_g$  個の染色体  $\{C_1, \dots, C_{M_g}\}$  は、 $C_k = \{w_{j1}, \dots, w_{jN}\}, k = 1 \sim M_g$  で構成される。入力された教師信号のデータと既存 SHP のパラメータを基にして初期染色体を作成する。選択では、ランキング選択とエリート保存方式を併用する。SHP で分離した教師信号数を評価関数とする。この評価関数の適応度の高い順に順位付けし、適応度の高いものは次の世代に保存して、増殖・淘汰を行う。また、交叉確率  $P_c$  によって 2 点交叉を行い、突然変異確率  $P_m$  によって突然変異を行う。最大世代数  $G_{max}$  回学習を繰り返し、適応度の高いランキング 1 位の染色体で、 $j$  番目の SHP を構成する。

4 数値実験

ここで、表 1 に示すマトリックスコンバータ [5] のスイッチングパターンを 6 周期の周期解をもつ教師信号として DBNN に学習させる。この教師信号は上位 8 ビットがスイッチングパターン、下位 3 ビットはパターンの継続時間を決める予備ビットである。GA パラメータは  $(M_g, P_c, P_m, G_{max}) = (30, 0.8, 0.1, 30)$  と設定する。

図 2 と表 2 に、学習後の DBNN とそのパラメータを示す。この DBNN の動作を検討すると、6 周期の周期解をもつ教師信号を実現できている。また、教師信号で与えられた以外の信号を初期値として DBNN を適用しても、すべて教師信号の周期解へ収束することがわかった。このとき、学習時に教師信号の周期解以外の情報は用いていない。すなわち、銘記された教師信号は自動安定化されている。

表 1 教師信号

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

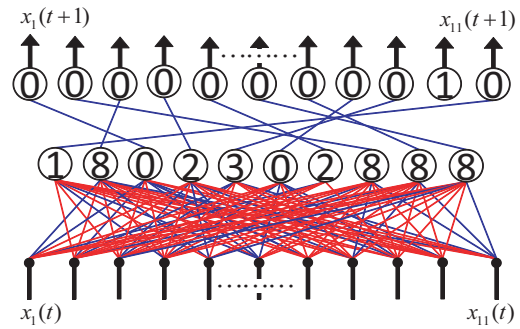


図 2 学習後の DBNN

表 2 学習後の中間層ニューロンパラメータ

$j$	$w_{j1}$	$w_{j2}$	$w_{j3}$	$w_{j4}$	$w_{j5}$	$w_{j6}$	$w_{j7}$	$w_{j8}$	$w_{j9}$	$w_{j10}$	$w_{j11}$	$\beta_j$
1	0	-1	-1	+1	-1	+1	-1	-1	-1	-1	-1	9
2	+1	-1	-1	-1	+1	-1	-1	-1	-1	-1	+1	3
3	+1	+1	-1	-1	0	+1	+1	+1	0	-1	-1	9
4	-1	-1	+1	-1	+1	+1	-1	-1	+1	-1	-1	9
5	0	+1	+1	-1	-1	0	0	-1	-1	-1	+1	5
6	-1	-1	-1	+1	0	+1	-1	-1	+1	+1	0	9
7	+1	-1	-1	-1	0	0	0	0	-1	0	0	3
8	-1	-1	-1	+1	-1	-1	-1	+1	-1	-1	+1	3
9	-1	+1	-1	-1	-1	-1	-1	+1	-1	-1	+1	3
10	-1	-1	+1	-1	+1	-1	-1	-1	-1	-1	+1	3

5 むすび

本論文では、DBNN の GA を適用した学習アルゴリズムを紹介し、その DBNN の基本的なダイナミクスの検討を行った。この DBNN のダイナミクスの検討を行う上で、スイッチング制御を用いているマトリックスコンバータのスイッチングパターンを学習し、実験をした。この実験から、DBNN で教師信号の周期解を実現できることを確認した。また、教師信号以外の信号が入力された場合でも自動安定化されることがわかった。この汎化能力はとても重要であると考えられる。

今後の課題として、DBNN の学習過程やダイナミクスの解析、回路制御への応用などが挙げられる。

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] 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
- [4] R. Ito, Y. Nakayama and T. Saito, Learning of dynamic BNN toward storing-and-stabilizing periodic patterns, in Proc. ICONIP, pp. 606-611, 2011.
- [5] N. Nguyen-Quang, D. A. Stone, C. M. Bingham and M. P. Foster, Comparison of single-phase matrix converter and H-bridge converter for radio frequency induction heating, in Proc. European Conference on Power Electronics and Applications, 2007.