

簡素な動的バイナリニューラルネットワークの基本学習機能

Basic learning function of simple dynamic binary neural networks

森安 淳吾¹
Jungo Moriyasu

上月 良太¹
Ryota Kouzuki

斎藤 利通¹
Toshimichi Saito

法政大学 理工学部 電気電子工学科¹ Faculty of Engineering and Science, Hosei University¹,

あらまし

簡素な動的バイナリニューラルネットワークの基本動的なダイナミクスと学習能力について述べる。同ネットワークの特徴は、3 値の結合パラメータとシグナム活性化関数である。学習アルゴリズムは相関学習に基づいており、あるクラスの周期解の記憶を保証するものである。典型的なスイッチング回路の制御信号に関係する教師信号を用いた数値実験を行い、教師信号の記憶と、記憶された教師信号の自動安定化について考察する。

1 まえがき

簡素な動的バイナリニューラルネットワーク (SDNN) は N 次元の 2 値入力から N 次元の 2 値出力への 2 層のフィードフォワード系に、遅れフィードバックを施して構成される。シグナム活性化関数を有し、結合パラメータは 3 値、しきい値パラメータは整数である [1]-[3]。この SDNN は、パラメータや初期値に依存して、様々な 2 値の周期軌道 (BPO) を生成できる。SDNN は様々なブール関数を実現できるバイナリニューラルネットワーク (BNN [4] [5]) に基づいている。

この SDNN に所望の BPO を学習させるために、相関学習 [6][7] に基づく簡素な学習アルゴリズムを導入する。この学習アルゴリズムは、教師信号の入力と各出力間の関係が線形分離可能であれば、その教師信号の記憶を保証する。この学習アルゴリズムの特徴として、3 層の DBNN や BNN の進化計算に基づく学習アルゴリズムよりもはるかに簡素で高速であるが、それらよりも記憶できる教師信号のクラスは狭い。

この学習アルゴリズムの機能を確認するために、dc/ac インバータの制御信号 [8][9] に関係する教師信号を用いて数値実験を行ったところ、教師信号の記憶が可能であることを確認した。さらに、注目すべき結果として、その教師信号が自動的に安定化されることを確認した。これはロバスト制御信号の生成のために重要である。SDNN




図 1 簡素な動的バイナリニューラルネットワークの例。 $w_{ij} = 1$ は赤い線, $w_{ij} = -1$ は青い線, $w_{ij} = 0$ は無結合。

は、セルラーオートマトン等に代表される簡素なデジタル力学系 [10]-[14] の一種である。本論文の結果は、基礎応用両面から同力学系の研究の発展に貢献することが期待される。

2 簡素な動的バイナリニューラルネットワーク

SDNN は図 1 に示す 2 層構造のネットワークで構成される。入出力間にはシグナム活性化関数を有し、ダイナミクスは以下で記述される。

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

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

$$\vec{x}^{t+1} = F_D(\vec{x}^t)$$

ただし $\vec{x}^t = (x_1^t, \dots, x_N^t)$, $x_i^t \in \{-1, 1\} \equiv \vec{B}$, は離散時間 t での N 次元状態ベクトルである。結合パラメータは 3 値 $w_{ij} \in \{-1, 0, 1\}$, しきい値パラメータは整数 $T_i \in \mathbb{Z}$ である。図 1 に $N = 3$ の場合の SDNN の例を示す。

3 SDNN の学習アルゴリズム

T 周期をもつ N 次元 BPO の教師信号を考える。

$$\vec{z}^1, \vec{z}^2, \dots, \vec{z}^T, \vec{z}^{T+1} = \vec{z}^1$$

$$\vec{z}^t = (z_1^t, \dots, z_N^t), \quad z_i^t \in \{-1, 1\} \quad (2)$$

$$\vec{z}^{t+T} = \vec{z}^t, \quad \vec{z}^{t+k} \neq \vec{z}^t \text{ for } 1 \leq k < T$$

相関学習を参考に、結合パラメータを次式で求める。

$$w_{ij} = \begin{cases} 1 & \text{for } w'_{ij} > 0 \\ 0 & \text{for } w'_{ij} = 0 \\ -1 & \text{for } w'_{ij} < 0 \end{cases} \quad w'_{ij} = \sum_{t=1}^T z_i^{t+1} z_j^t \quad (3)$$

ただし $i = 1 \sim N$, $j = 1 \sim N$, $t = 1 \sim T$ である。しきい値パラメータは以下で決定する。

$$T_i = \begin{cases} N + 1 & \text{if } z_i^{t+1} = -1 \text{ for all } t \\ -N - 1 & \text{if } z_i^{t+1} = 1 \text{ for all } t \\ \frac{R_i + L_i}{2} & \text{otherwise} \end{cases} \quad (4)$$

ただし

$$R_i = \min_t \sum_{j=1}^N w_{ij} z_j^t \quad \text{for } z_i^{t+1} = 1$$

$$L_i = \max_t \sum_{j=1}^N w_{ij} z_j^t \quad \text{for } z_i^{t+1} = -1,$$

ここで、 $R_i > L_i$ の場合に教師信号の学習が保証されることに注意する。これは入力と各出力の関係が、線形分離可能である場合に対応する。

4 数値実験

ここで、SDNN の学習アルゴリズムを用いて 7 相の dc/ac インパタの制御信号に関連する 14 周期をもつ 7 次元 BPO の数値実験を行う。この教師信号を表 1、学習後のネットワークを図 2 に示す。

表 1 教師信号

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

学習後の結合パラメータを表 2 に示す。全ての w_{ij} が +1 または -1 であることは全ての入力の要素と全ての出力の要素がつながっていることになる。学習後の SDNN には、教師信号 BPO が記憶されたことを確認した。さらに、全 128 個の初期値中、126 個の初期値から出発する解が、この記憶された BPO に落ち込むことも確認した。すなわち、この教師信号は自動的に安定化されている。教師信号には、安定化に関する情報が一切含まれていないことに、読者の注意を促したい。このような教師信号を実際の回路の制御信号に使用する場合、SDNN は外乱に対してロバストな信号の生成を可能にする。




図 2 学習後の SDNN

表 2 学習後の結合パラメータ

j	w_{1j}	w_{2j}	w_{3j}	w_{4j}	w_{5j}	w_{6j}	w_{7j}	T_j
1	+1	+1	-1	-1	-1	+1	+1	0
2	+1	+1	+1	-1	-1	-1	+1	0
3	+1	+1	+1	+1	-1	-1	-1	0
4	-1	+1	+1	+1	+1	-1	-1	0
5	-1	-1	+1	+1	+1	+1	-1	0
6	-1	-1	-1	+1	+1	+1	+1	0
7	+1	-1	-1	-1	+1	+1	+1	0

5 むすび

SDNN の基本的なダイナミクスと関連学習に基づく学習アルゴリズムを考察した。典型的な教師信号を用いて数値実験を行い、その記憶と自動安定化を確認した。自動安定化のメカニズムの解析、様々な教師信号への応用等が今後の課題である。

参考文献

- [1] R. Ito and T. Saito, Dynamic Binary Neural Networks and Evolutionary Learning, Proc. of IEEE-INNS/IJCNN, pp. 1683-1687, 2010.
- [2] R. Ito, Y. Nakayama and T. Saito, Analysis and Learning of Periodic Orbits in Dynamic Binary Neural Networks, Proc. IEEE-INNS/IJCNN, 2012, accepted.
- [3] R. Kouzuki, T. Suzuki and T. Saito, Learning of Periodic Attractors in Simple Dynamic Binary Neural Networks, Proc. NDES, 2012, accepted.
- [4] 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.
- [5] J. H. Kim and S. K. Park, The geometrical learning of binary neural networks. IEEE Trans. Neural Networks, 6, 1, pp. 237-247, 1995.
- [6] K. Araki and T. Saito, An associative memory including time-variant self-feedback, Neural Networks, 7, 8, pp. 1267-1271, 1994.
- [7] 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.
- [8] M. A. Boost and P. D. Zipgas, State-of-the-art carrier PWM techniques: a critical evaluation, IEEE Trans. Ind. Appl. cat., 24, pp. 271-280, 1988.
- [9] 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.
- [10] L. O. Chua, A nonlinear dynamics perspective of Wolfram's new kind of science, I, II, World Scientific, 2005.
- [11] P. L. Rosin, Training cellular automata for image processing, IEEE Trans. Image Process., 15, 7, pp. 2076-2087, 2006.
- [12] W. Wada, J. Kuroiwa, S. Nara, Completely reproducible description of digital sound data with cellular automata, Physics Letters A 306, pp. 110-115, 2002.
- [13] J. D. Lohn and J. A. Reggia, Automatic discovery of self-replicating structures in cellular automata, IEEE Trans. Evolutionary Computation, 1, 3, pp. 165-178, 1997.
- [14] M. Serebinski and P. Bouvry, Block cipher based on reversible cellular automata, Proc. of CEC, pp. 2138-2143, 2004