

## 動的バイナリーニューラルネットの軌道安定性と結合スパース性

著者	小山 誠太郎
出版者	法政大学大学院理工学研究科
雑誌名	法政大学大学院紀要. 理工学・工学研究科編
巻	61
ページ	1-2
発行年	2020-03-24
URL	<a href="http://doi.org/10.15002/00022834">http://doi.org/10.15002/00022834</a>

# 動的バイナリニューラルネットの軌道安定性と結合スパース性

CONNECTION SPARSITY AND ORBIT STABILITY  
IN DYNAMIC BINARY NEURAL NETWORKS

小山誠太郎

Seitaro KOYAMA

指導教員 齋藤利通

法政大学大学院理工学研究科電気電子工学専攻修士課程

Dynamic binary neural networks are recurrent type neural networks characterized by ternary connection parameters and signum activate function. Depending on the parameters, the network can generate various binary periodic orbits. The ternary connection parameters and signum activation function are suitable for precise analysis and hardware implementation. First, we investigate influence of connection sparsity on stability of a periodic orbit. As the sparsity increases, stability of a periodic orbit tends to be reinforced. As the sparsity increases further, stability tends to be weakened and various transient phenomena exist.

**Key Words** : *Dynamic binary neural networks, Periodic orbits, Stability*

## 1. 導入

動的バイナリニューラルネット (DBNN[1]-[3])は、2値ベクトル入力を2値ベクトル出力に変換するフィードフォワードネットワークに、遅延フィードバックを適用して構成される。DBNNはシグナム活性化関数と3値結合パラメータによって特徴づけられる。パラメータや初期値に依存して、様々な2値周期軌道(BPO)を生成することができる。工学的応用として、スイッチング回路の制御[2][4]、連想メモリ[5]-[7]、セントラルパターンジェネレータ[8][9]などがある。

本論文では、目的とする周期軌道(TBPO)の安定性に関する特徴量を導入し、DBNNの動作解析を行う。ネットワークにTBPOが銘記された場合を対象とし、ネットワークのスパース化が安定性に与える影響を調査する。

## 2. 動的バイナリニューラルネット

### (1) 動的バイナリニューラルネット

動的バイナリニューラルネット(DBNN)の動作は次式で記述される。

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

$$\text{sgn}(X_i) = \begin{cases} +1 & \text{if } X_i \geq 0 \\ -1 & \text{if } X_i < 0 \end{cases}$$

$$X_i \equiv \sum_{j=1}^N w_{ij} x_j^t - T_i$$

$$\text{ab. } \mathbf{x}^{t+1} = \mathbf{F}_D(\mathbf{x}^t), \mathbf{x}^t \equiv (x_1^t, \dots, x_N^t)^T \in \mathbf{B}^N \quad (2)$$

ただし、 $\mathbf{x}^t$ は離散時刻 $t$ における状態ベクトルであり、 $x_i^t \equiv B \in \{-1, +1\}$ はその $i$ 番目の要素である。 $N$ はセル数である。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値 $T_i \in \{0, \pm 1, \pm 2, \pm 3, \dots\}$ である。シグナム活性化関数 $\text{sgn}$ は $-1$ または $+1$ を出力する関数である。

### (2) デジタルリターンマップ

$\mathbf{B}^N$ は $2^N$ 個の点の集合 $L_N$ と等価である。したがって、DBNNの動作をデジタルリターンマップ(Dmap)で視覚化し、把握することができる。

$$\theta^{t+1} = f_D(\theta^t), \theta^t \in L_N \equiv \{C_1, \dots, C_{2^N}\} \quad (3)$$

ただし、 $C_i \equiv \frac{i}{2^N}, i = 1 \sim 2^N$ である。 $L_4 \equiv \{C_1, \dots, C_{16}\}$ は $(-1, -1, -1, -1)^T \sim (+1, +1, +1, +1)^T$ とそれぞれ対応する。

Dmapの周期点に関する定義を与える。ある点 $\theta_p$ が、 $f_D^p(\theta_p) = \theta_p$ を満たし、 $f_D(\theta_p)$ から $f_D^p(\theta_p)$ がすべて異なる点の場合、 $\theta_p$ を周期 $p$ の周期点(PEP)とよぶ。ただし、 $f_D^k$ は $f_D$ の $k$ 回合成写像である。PEPの系列 $\{f_D(\theta_p), \dots, f_D^p(\theta_p)\}$ を周期 $p$ の周期軌道(PEO)とよぶ。 $\theta_e$ がPEPではなく、 $q$ ステップ後にPEOに落ち込むとき、 $\theta_e$ をE周期点(EPP)と呼ぶ。Dmapの定義域は有限個の点からなるため、EPPは

必ずPEOに落ち込む。

DBNNにおけるBPOは、DmapにおけるPEOと同値であるため、BPOという表現に統一する。

### (3) 特徴量

目的とする周期軌道(TBPO)の安定性を評価する特徴量 $\alpha_s$ を定義する。

$$\alpha_s = \frac{\text{TBPOに1ステップで落ち込むEPPの数}}{2^N - p} \quad (4)$$

ただし $0 \leq \alpha_s \leq 1$ である。 $\alpha_s$ が増大するとき、TBPOの安定性が強化されるとみなす。

ネットワークのスパース性をSRで定義する。

$$SR = \frac{w_{ij} = 0 \text{の数}}{N \times N - N} \quad (5)$$

ただし $0 \leq SR \leq 1$ である。ネットワークをスパース化すると、SRは大きくなる。

## 3. 数値実験

簡素なDC/ACコンバータの制御信号に応用可能なTBPOを表1に示す。

表1 TBPOの例

$z^1$	(+1, -1, -1, -1, +1, +1)
$z^2$	(+1, +1, -1, -1, -1, +1)
$z^3$	(+1, +1, +1, -1, -1, -1)
$z^4$	(-1, +1, +1, +1, -1, -1)
$z^5$	(-1, -1, +1, +1, +1, -1)
$z^6$	(-1, -1, -1, +1, +1, +1)

表1のTBPOを銘記する64000000のネットワークについて $\alpha_s$ を計算した。各SRに対する $\alpha_s$ を図1に示す。

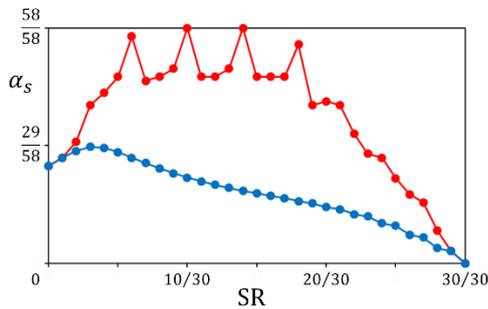


図1 SRに対する $\alpha_s$  赤線が最大値、青線が平均値

## 4. まとめ

ネットワークのスパース化がDBNNの動作に与える影響について考察した。動作を特徴づけるために、TBPOの安定性を評価する特徴量 $\alpha_s$ を導入した。

簡素なDC/ACコンバータの制御信号に応用可能なTBPOを対象に、TBPOを銘記するネットワークについてSRに対する $\alpha_s$ を計算した。スパース性が増大すると、安定性は強化される傾向がある。さらにスパース性が増大すると、安定性は弱くなる。

今後の課題は、パラメータの最適化と工学的応用である。

## 参考文献

- 1) R. Kouzuki and T. Saito, Learning of simple dynamic binary neural networks, IEICE Trans. Fundamentals, E96-A(8), 1775-1782, 2013.
- 2) R. Sato and T. Saito, Stabilization of desired periodic orbits in dynamic binary neural networks, Neurocomputing, 248, 19-27, 2017.
- 3) S. Aoki, S. Koyama, and T. Saito, Theoretical analysis of dynamic binary neural networks with simple sparse connection, Neurocomputing, 341, 149-155, 2019.
- 4) B. K. Bose, Neural network applications in power electronics and motor drives - an introduction and perspective, IEEE Trans. Industrial Electronics, 54(1), 14-33, 2007.
- 5) J. Hao and J. Vandewalle, A new model of associative memories, Proc. IJCNN II, 166-171, 1992.
- 6) K. Araki and T. Saito, An associative memory including time-variant self-feedback, IEEE Trans. Neural Networks, 7(8), 1267-1271, 1994.
- 7) X. Jiang, V. Gripon, C. Berrou, and M. Rabbat, Storing sequences in binary tournament-based neural networks, IEEE Trans. Neural Networks and Learning Systems, 27(5), 913-925, 2016.
- 8) P. Ramdya, R. Thandiackal, R. Cherney, R. Benton, T. Asselborn, A. J. Ljspeert, and D. Floreano, Climbing favours the tripod gait over alternative faster insect gaits, Nature Communications, 8, 14494, 2017.
- 9) T. Toizumil and K. Saeki, Central pattern generator based on interstitial cell models made from bursting neuron models, L. Cheng et al. (Eds.): ICONIP 2018, LNCS 11302, 321-329, 2018.