

離散 PSO を用いた動的ニューラルネットワークの学習法 A Learning Method for Dynamic Binary Neural Networks Using a Discrete PSO

長野 呂夢[†] 中野 秀洋[‡] 宮内 新[‡]
Nagano Romu Nakano Hidehiro Miyauchi Arata

1. はじめに

動的バイナリニューラルネットワーク(DBNN)は Nbit 入力 Nbit 出力の 3 層フィードフォワード型のバイナリニューラルネットワーク(BNN) に対して遅延フィードバック機能を付加したものである[1]. DBNN は適切な数の中間層ニューロンを用いることで任意の時系列パターンを再現することが可能である. 各ニューロンのパラメータは時系列パターンを教師データとして学習することによって得ることができる. また, DBNN において各ニューロン間の結合パラメータは 3 値で表されるため, デジタル回路への実装に対して極めて適している.

DBNN の学習方法には BNN で提案されている幾何学的学習法(Geometrical Learning : GL)[2]を用いる. 基本的な GL は N 入力 1 出力 BNN の学習法であるが, 本稿ではこれを N 入力 N 出力の DBNN 用に拡張させた並列 GL を用いて学習を行う. GL は教師信号間を分離する超平面(SHP)を逐次的に求めることが目的であり, DBNN に対する SHP 探索において従来では遺伝的アルゴリズム(GA)に基づく手法が提案されている[1]. しかしながら GA は制御パラメータが多く, その設定によっては探索領域が限定的になることがある[3]. そこで我々は最適化手法の分野で近年注目されている群知能の一つである粒子群最適化(PSO)[4]に基づく GL を提案する. さらに本稿では結合パラメータの結合数(リンク数)に対する評価基準を新たに追加し, パラメータの簡素化を図る. いくつかの 2 値時系列パターンを教師信号として学習を行い, 中間層ニューロン数, リンク数を比較することで学習性能を評価し, 提案手法の有効性を示す.

2. 動的バイナリニューラルネットワーク

DBNN のモデルを図 1 に示す. DBNN は 3 つのニューロン層から構成され, 出力層から入力層への全遅延フィードバックを持つ. また, 各ニューロンはシグナム活性化関数を用いている. DBNN の動作は式(1)~(3)のように表される.

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

$$\xi_j(t) = S\left(\sum_{i=1}^N w_{ji} x_i(t) - T_j\right), \quad j = 1 \sim M \quad (2)$$

$$S(X) = \begin{cases} 1, & X \geq 0 \\ 0, & X < 0 \end{cases} \quad (3)$$

ただし

$\vec{x}(t) = [x_1(t), x_2(t), \dots, x_i(t), \dots, x_N(t)]$ $x_i(t) \in \{0,1\}$
は離散時間 t での Nbit 入力,




図 1 DBNN モデル

$\vec{\xi}(t) = [\xi_1(t), \xi_2(t), \dots, \xi_i(t), \dots, \xi_M(t)]$ $\xi_j(t) \in \{0,1\}$

は時刻 t における M 個の中間層出力を表す. なお, M は学習過程に依存して変化する. DBNN は中間層を経由し次状態 $\vec{x}(t+1)$ を出力する. 入力(現状態)から出力(次状態)への写像を繰り返すことで DBNN は様々な時系列パターンを生成することができる.

中間層, および(後述の TV 分離の場合)の出力層のニューロンの結合荷重と閾値の関係を以下に示す.

$$w_{ji} \in \{-1, 0, 1\}, \quad T_j = \sum_{i=1}^N |w_{ji}| - \beta_j, \quad (4)$$

$$\beta_j \in \{1, 2, 3, \dots\}$$

$$w_{ij}^o \in \{0, 1\}, \quad T_j^o = 1 - \sum_{i=1}^M w_{ij}^o \quad (5)$$

DBNN は w_{ji} , $T_j(\beta_j)$, w_{ij}^o の 3 種類のパラメータによって特徴づけられる

3. 幾何学的学習法

本稿では多 bit 出力用に対応した並列 GL について説明する. ここでは例として 3 入出力教師信号を用いて説明する. ある 2 値の信号を図 2 のように幾何学的空間上の頂点として配置する. 図 2 の 3 つの立方体は入力パターンに対応する各出力の応答を表している. 各点の座標は入力パターンと対応している. また \times は Don't Care を表し, 教師データが存在しない, あるいは考慮しないことを意味する. GL ではこれらの教師信号を分離する超平面(Separate Hyper Plane : 以下 SHP) を逐次的に求める. ここで SHP と各パラメータの関係について説明する. SHP の傾きは結合パラメータ, 切片は閾値に対応している. よってすべての信号を完全分離する SHP の組合せを求めることで DBNN 全体のパラメータを決定することができる. 並列 GL ではニューロン数を抑制するため, 出力の数だけ存在する幾何学的空間の間で出来る限り SHP を共有しながら学習を行う. SHP のパラメータ(結合荷重, 閾値)の組み合わせは入出力数に応じて指数関数的に増加するため SHP を効率的に探索するアルゴリズムが必要となる. そこで本稿では近年注目されている群知能アルゴリズムに基づく学習法を提案する.

[†] 東京都市大学大学院

Graduate School of Engineering, Tokyo City University

[‡] 東京都市大学 知識工学部情報科学科

Department of Computer Science, Faculty of Knowledge Engineering, Tokyo City University




図2 幾何学的学習法による教師信号分離

3.1 群知能に基づく GL

3.1.1 PSO 概要

PSO は粒子と呼ばれる多数の探索点が互いに情報共有しながら多次元空間内を探索する最適化アルゴリズムである。粒子全体の過去の探索点の中で最も良い評価の位置を $gbest$ とし、各粒子の過去の探索における最適な位置を $pbest_i$ とする。各粒子は現在の速度と群れ全体の最良位置と各粒子の最良位置に基づいて速度の更新を行う。その速度に基づいて各粒子の位置を更新する。

$$v_{ij}^{t+1} = W \cdot v_{ij}^t + C_1 \cdot R_1 \cdot (pbest_{ij}^t - x_{ij}^t) + C_2 \cdot R_2 \cdot (gbest^t - x_{ij}^t) \quad (6)$$

$$x_{ij}^{t+1} = x_{ij}^t + v_{ij}^{t+1} \quad (7)$$

ただし、 W は慣性定数、 C_1, C_2 はそれぞれ学習定数である。また R_1, R_2 は $[0, 1]$ の一様乱数である。

3.1.2 離散化

提案手法では結合パラメータを各粒子の位置情報として表現する。そこで 3 値離散情報である結合パラメータに対する離散化方法を提案する。位置の更新の際に現在の位置に基づいて以下のように離散化を行う。

$$u_i^{k+1} = \begin{cases} 1 & \rho_1 < sig(v_i^{k+1}) \\ -1 & otherwise \end{cases} \quad (8)$$

$$x_i^{k+1} = \begin{cases} u_i^{k+1} & \rho_2 < sig(v_i^{k+1}) \\ 0 & otherwise \end{cases} \quad (9)$$

$$sig(v_i^{k+1}) = \frac{1}{1 + exp(-v_i^{k+1})} \quad (10)$$

ただし、 ρ_1 は $[\rho_2, 1]$ の一様乱数、 ρ_2 は $[0, 1]$ の一様乱数である。各粒子の評価値は分離成功信号数とする。ただし、同評価値だった場合はリンク数 ($\sum_{i=1}^N |w_{ji}|$) の少ない方を高く評価する。

4. 実験 1

提案手法の有効性を示すため 2 つの教師信号を用いて実験を行う。実験環境を表 1 に示す。なお、通常の PSO では慣性定数 w は正の値を用いるが、事前実験で性能が良かった負の慣性定数[5]を用いた。教師信号はランダムに生成し、表中の $pattern$ は 2 値時系列パターン数を意味する。実験では学習後の中間層ニューロン数、およびリンク数を比較する。

4.1 実験結果 1

表 2 より提案手法ではリンク数評価を行わなかった場合と比べ、行う場合はリンク数を約 30~40%削減することが出来る。

表 1 実験環境

パラメータ	PSO	
リンク数評価	無	有
粒子数	300	
エピソード数	1000	
学習試行回数	100	
教師信号 1	16 bit 10 pattern (random)	
教師信号 2	16 bit 20 pattern (random)	
慣性定数(w)	-0.51	
学習係数 1(C1)	1.0	
学習係数 2(C2)	1.0	

表 2 実験 1 結果

	16 bit 10 pattern		16 bit 20 pattern	
	無	有	無	有
リンク数評価	無	有	無	有
中間層パラメータ数	13.173	13.372	23.012	24.132
リンク数/ニューロン	7.099	3.867	7.456	5.177
総リンク数	99.542	57.728	183.106	121.393

5. 実験 2

実験 2 では GL の分離方法による中間層ニューロン数の比較を行う。実験に用いる分離方法は真の信号のみを分離する TV 分離と偽の信号のみを分離する FV 分離、さらに真と偽の信号を交互に分離する交互分離で比較を行った。PSO のパラメータは実験 1 と同様とし、教師信号にはランダムに生成した 16 bit 400 pattern のものを用いる。

5.1 実験結果 2

表 3 実験 2 結果

	TV	FV	交互
中間層ニューロン数	384.19	383.00	330.20
リンク数/ニューロン	7.4494	7.4511	7.9188
総リンク数	2861.93	2853.65	2614.84
総譜リンク数	1310.76	1298.50	1085.44

表 3 より交互分離が最も中間層ニューロン数を削減することが出来る。

6. むすび

本稿では PSO を用いた DBNN の学習アルゴリズムを提案した。また分離方法による中間層ニューロン数の変化についても検証した。今後の課題として学習方法の改良とパラメータの簡素化及びデータ圧縮器への応用などが挙げられる。

参考文献

[1] Yuta Nakayama et al “Analysis of Learning Process of Dynamic Binary Neural Network” IEICE NC2011-148 2012-03
 [2] J.H.KIM et al “The geometrical learning of binary neural networks” IEEE Trans. Neural Net- works, vol.6, no.1, pp.237-247, 1995.
 [3] Yu Akedo, Hidehiro Nakano, Arata Miyauchi “A Learning Algorithm of Binary Neural Networks Base on Real-Coded GA”
 [4] J. Kennedy et al .; Particle Swarm Op- timization, Proc of IEEE International Conference on Neural Network, pp. 1942-1948 (1995).
 [5] 渡邊 恭成, 中野 秀洋, 宮内 新 “負の慣性項を有する 粒子群最適化の基本性能について” Vol.2012-MPS-90 No.29