

## ディジタル型リカレントネットの学習特性 Learning Characteristic of the Digital Type Recurrent Neural Network

長沼 秀典 †  
Hidenori Naganuma

大堀 隆文 ‡  
Takafumi Oohori

渡辺 一央 §  
Kazuhisa Watanabe

### 1. まえがき

フィードバック結合を含むリカレントニューラルネットワーク (RNN と略す) は、時系列データなどの動的な問題を解くことが可能である。Williams と Zipser は可微分な素子で構成された RNN の学習法として、通時誤差逆伝搬法 (error back propagation through time: BPTT と略す) を提案した [1]。しかし、内部状態が連続値を取るために、オートマトンの内部状態推定などのディジタル課題を直接解くことが困難であった [2]。

このように本質的にディジタルであることが要求される課題に対して、バイナリニューラルネットを適用する研究が行われ、いくつかの学習法が提案されている。大堀らにより提案されたディジタル型誤差逆伝搬法 (以下 DBP と略す) もその一つである [3]。DBP は中間層に教師信号を設定することで下層の結合係数が修正でき、階層型のバイナリニューラルネットの学習が可能である。DBP はディジタル型の論理課題の学習において、従来の誤差逆伝搬法と同程度の性能を示した。

著者らは、BPTT で用いられる時間展開と DBP による誤差の伝搬を組合せ、ディジタル素子で構成された RNN に対して適用が可能なディジタル型通時誤差逆伝搬法 (以下 DBPTT) を提案した [4]。

本論文では、DBPTT により入力を持たない RNN がディジタル型周期波形を学習できることを報告する。また、全ての構成素子が 2 値出力であり、離散的な状態の表現が容易であることから有限状態オートマトンに対して適用可能であることを実験的に示す。

また、これらの課題を通してディジタル型リカレントネットの学習特性について実験的に検証する。

### 2. ディジタル型 BP 法

すべての層に不可微分な 2 値出力素子を用いたディジタル型 3 層パーセプトロンに対する誤差逆伝搬法 (DBP) は、出力層の誤差を減少させるために、中間層にも教師信号を与えるので、下層の結合係数の修正も可能になる。したがって DBP における結合係数は、上層では (1) 式、下層では中間層教師信号  $T_j^{(p)}$  を与えることが可能であり、上層と同様に (2) 式の非常に簡単なデルタ則に従い修正することができる。

$$w_{kj} = w_{kj} - \alpha(O_k^{(p)} - T_k^{(p)})O_j^{(p)} \quad (1)$$

$$w_{ji} = w_{ji} - \alpha(O_j^{(p)} - T_j^{(p)})O_i^{(p)} \quad (2)$$

ここで中間層教師信号  $T_j^{(p)}$  は、上層の誤差を減少させるように式 (3) の教師決定因子  $S_j^{(p)}$  の符号に基づき 0 か

† 北海道工業大学大学院工学研究科電気工学専攻

‡ 北海道工業大学情報デザイン学科

§ 北海道工業大学情報ネットワーク工学科

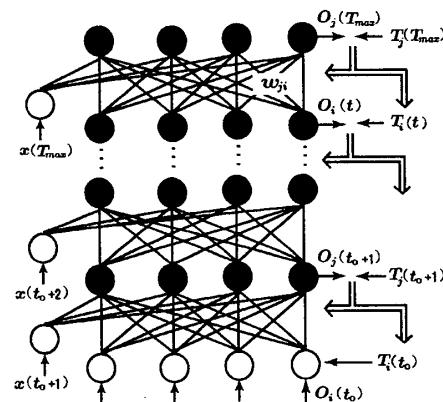


図 1: DRNN の時間展開と DBPTT 学習

1 にセットする。

$$S_j^{(p)} = \sum_k (O_k^{(p)} - T_k^{(p)}) w_{kj} \quad (3)$$

### 3. ディジタル型通時誤差逆伝搬法

DBP によって階層型ディジタルネットワークの学習が可能であることから、ディジタル素子で構成された RNN (Digital type Recurrent Neural Network:DRNN) を時間展開することで DBP により学習が可能である。

本章では、アナログ素子で構成されたりカレントネットワークの学習法である通時誤差逆伝搬法 (BPTT) と DBP から、DRNN に対する学習法としてディジタル型通時誤差逆伝搬法 (DBPTT) の学習式を導出し、学習アルゴリズムについて説明する。

#### 3.1 時間順方向伝搬

DRNN は図 1 のように時間展開することができる。時刻  $t$  における素子  $j$  の出力値は、次式で定義される。

$$O_j(t) = f(U_j(t)) = f(\sum_i w_{ji}^H O_i(t-1) + w_{ji}^I x(t)) \quad (4)$$

ここで、 $w_{ji}^H$  は第  $i$  隠れ素子から第  $j$  隠れ素子への結合係数を表わし、 $w_{ji}^I$  は第  $i$  入力素子から第  $j$  隠れ素子への結合係数を表わす。また、 $O_j(t)$ 、 $U_j(t)$  はそれぞれ、時刻  $t$  での第  $j$  素子の出力と活性値、 $O_i(t-1)$  は時刻  $t-1$  での第  $i$  素子の出力を表す。また、 $f$  は各素子の出力関数であり、ステップ関数を用いる。

#### 3.2 時間逆方向伝搬

図 1 に示した時間展開による階層型ネットワークに対し、離散時刻  $t_0 \leq t \leq T_{max}$  において、ある時刻  $t$  に対して入力信号  $x(t)$  と教師信号  $T(t)$  を与える。ここで、教師信号は全ての時刻で与えられる。このとき DBPTT は以下のアルゴリズムにより学習を行う。

**手順(1) 時刻  $t = T_{max}$  (終端時刻)**

各素子に対する教師信号  $T_j(T_{max})$  をもとに各素子の結合係数修正量  $\Delta w_{ji}(t)$  をデルタ則に従って算出する。

$$\Delta w_{ji}^H(t) = -\alpha(O_j(t) - T_j(t))O_i(t-1) \quad (5)$$

$$\Delta w_j^I(t) = -\alpha(O_j(t) - T_j(t))x(t) \quad (6)$$

$t = T_{max}$  のとき、可視素子では教師信号  $T(T_{max})$  を与え、隠れ素子には誤差が0となるように形式的に素子の出力を教師信号として与える：

$$T_j(T_{max}) = \begin{cases} T(T_{max}) & (j \text{ is visible}) \\ O_j(T_{max}) & \text{otherwise} \end{cases} \quad (7)$$

**手順(2) 時刻  $t_0 < t < T_{max}$** 

DBPでは2章で述べたように教師決定因子  $S_j$  により上層の誤差を減少させるように教師信号を設定した。DBPTTではこれを応用し、時刻  $t+1$  での誤差が減少するように隠れ素子に教師信号を与えるため教師決定因子を求める。

時刻  $t$  において、結合係数  $w_{kj}^H$  を固定して考えるならば、出力  $O_j(t)$  を時刻  $t+1$  での誤差が減少する値に設定するのが望ましい。したがって、教師決定因子  $S_j(t)$  を、

$$S_j(t) = \sum_k (O_k(t+1) - T_k(t+1))w_{kj}^H \quad (8)$$

とおき、次式により教師信号を設定する。ただし、 $k, j$  は隠れ素子である。

$$\text{if } S_j(t) > 0 \text{ then } T_j(t) = 0 \quad (9)$$

$$\text{if } S_j(t) < 0 \text{ then } T_j(t) = 1 \quad (10)$$

$S_j(t) = 0$  のときは、修正する必要がないので

$$\text{if } S_j(t) = 0 \text{ then } T_j(t) = O_j(t) \quad (11)$$

とおく。(8)～(11)式より、すべての素子に対して教師信号の設定が可能となる。しかし、これとは別に可視素子に対して教師  $T(t)$  も与えられており、これが教師決定因子より作成された教師信号と異なる場合を考えられる。DBPTTでは、可視素子に対する教師信号として  $T(t)$  を用いる。すなわち  $T_j(t) = T(t)$  とする。

上記より求められた教師信号を用いることで、時刻  $t$  における結合係数修正量も(5)式、(6)式で求めることができる。

手順(1)(2)で求めた結合係数修正量を時刻で総和して一括修正を行う。すなわち、

$$w_{ji}^H = w_{ji}^H + \sum_t \Delta w_{ji}^H(t) \quad (12)$$

$$w_j^I = w_j^I + \sum_t \Delta w_j^I(t) \quad (13)$$

とする。

**4. 学習特性の検証**

DRNNは全ての素子出力が2値であり、ディジタル型の課題を学習させるのに有効であると考えられる。本論文ではディジタル型課題として、ディジタル型周期波形と有限状態オートマトン(Finite State Automaton:FSA)を用いる。DBPTTを用いてこれらの課題をDRNNに学習させ、その学習特性を実験的に検証する。

**4.1 周期波形の学習と汎化**

DBPTTにより学習されたDRNNの学習特性を見るために、ディジタル型周期波形の学習を行った。学習波形として、{01110111…} (周期4) と {0101011101010111…} (周期8) を用いた。DRNNは入力を持たず、素子数を4とした。またDBPTTにおいて周期の2倍を学習時刻  $T_{max}$  とし、学習は出力波形が教師波形と一致するか最大学習回数  $10^8$  まで行った。

学習終了後のDRNNを十分長い時間再生し、学習に用いた  $T_{max}$  以降も再生波形が教師波形と一致する場合、周期波形の汎化が成功したと見なす。結合係数初期値として乱数100種を用い、 $\alpha$  を  $10^{-4} \sim 10^2$  と変化させたときの学習・汎化成功率を図2、図4に、そのときの平均学習回数を図3に示す。

図2より、DBPTTは学習係数によらず高い精度で学習が成功した。また、図4より汎化成功率は4周期波形では学習係数が小さいほど低下し、8周期波形では常に成功した。一方、図3より、4周期波形では、 $\alpha$  が小さいほど収束に時間を要したが、複雑な8周期波形の場合  $\alpha$  によらずほぼ一定で、収束にはさらに長い時間を必要とした。より複雑な課題を学習させる場合、収束を加速させるようなアルゴリズムの改良を考える必要がある。

**4.2 有限状態オートマトン(FSA)**

有限状態オートマトン(Finite State Automaton:FSA)は過去の時系列入力から出力を決定する順序機械であり、状態数が有限で、入力と自身の状態から出力と状態が遷移する。本節では、入力と状態から出力が決定するMealy型FSAをDRNNに学習させることで入力を持つDRNNの学習特性を検証する[5]。

学習対象のFSAとしてTomitaにより提案され、Gilesらにより同定実験に使用されたTomita Grammar(TG)を用いた[6]。Mealy型TGの状態遷移図を図5に示す。TGは7種提案されているが、今回は簡単な課題であるTG1及びTG2を用いた。

状態数が  $n$  であるFSAは、長さ  $2n-1$  の全ての入力時系列に対する出力時系列によって同定できることが知られているため、長さ  $2n-1$  の全ての0,1の組合せを入力時系列とした。TG1は入力素子数1、構成素子数2個であるDRNNを、TG2は入力素子数1、構成素子数3個であるDRNNを用いた。学習係数  $\alpha = 0.1$  とし、全系列での出力がTGと一致するか最大学習回数  $T_{max} = 10^7$  になるまで学習を行った。また、結合係数の初期値を一律乱数で定め、各素子の初期値は1とした。

全入力時系列に対して正しく応答できたものを学習成功とし、乱数系列100種を用いたときの学習成功率を観測した。また、学習が成功したものについて、学習終了後のDRNNに長さ  $2(2n-1)$  の全ての0,1の組合せを入力時系列とし、正しく応答できている割合を同定(汎化)能力とした。実験結果を表1に示す。

実験の結果、DRNNは簡単なオートマトンの学習について学習精度が高いとはいえないが学習が可能だった。また、学習に成功したものは必ず同定ができていた。

オートマトンの内部状態を表すため、構成素子の出力を2進数とみなし、ある時点での内部状態に番号をつける。このとき、TG1では2状態、3状態を遷移し、TG2

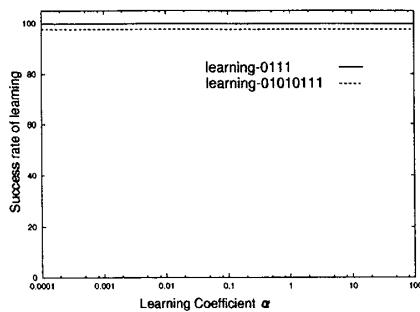


図 2: 周期波形課題の学習成功率

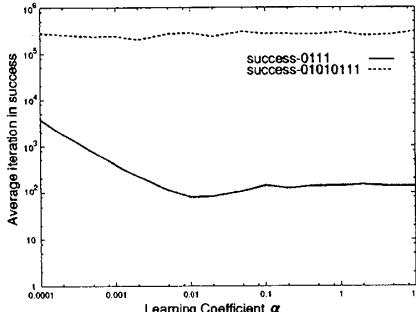


図 3: 周期波形課題の平均学習回数

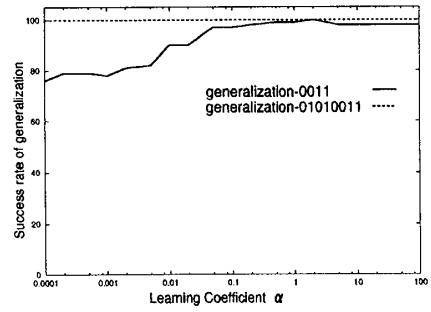


図 4: 周期波形課題の汎化成功率

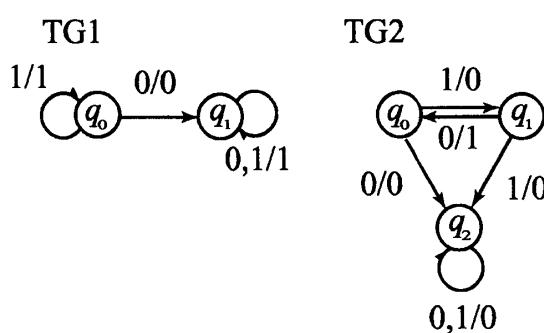


図 5: TomitaGrammar の状態遷移図

表 1: FSA の実験結果

	成功率	同定(汎化)能力
TG1	46 %	100 %
TG2	50 %	100 %

では 3 状態、4 状態を遷移していた。DRNN により獲得された TG2 の状態遷移図を図 6 に示す。状態数が 3 である DRNN は学習により TG2 の理想的な状態遷移図を獲得できていた。

他の TG に関する実験と考察は今後の課題とするが、実験から DRNN による FSA の同定と状態遷移図の獲得に関してその可能性が確認できた。

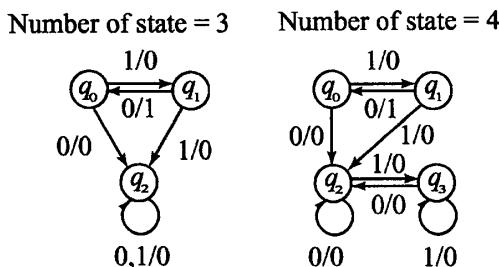


図 6: 学習成功時の DRNN 内部状態遷移図 (TG2)

## 5. おわりに

本論文では、DBPTT を用いることで、DRNN がデジタル型周期波形と有限状態オートマトン (FSA) を学習できることを実験的に示した。数値実験から、DBPTT は周期波形の学習を高い精度で実現可能であった。また単純な FSA の学習・同定が可能であり、離散状態の表現も容易に実現できた。

今後の課題として、以下のことが挙げられる。

1. 複雑な課題 (8 周期波形の学習など) に対しての収束速度の改善
2. FSA の学習精度の向上
3. より複雑な内部状態を持つ FSA の学習と同定
4. 状態遷移図獲得のメカニズムの解明

## 参考文献

- [1] R.J.Williams and D. Zipser: "A learning algorithm for continually running fully recurrent neural networks", Neural Computation, 1, No.2, pp.270-280, 1989
- [2] Z.Zeng, R.M.Goodman and P.Smyth, "Learning finite state machines with self-clustering networks," Neural Computation, Vol.5, pp.976-990, 1993
- [3] 長沼秀典, 大堀隆文, 渡辺一央, "微分不能素子を持つ階層型ニューラルネットに対する誤差逆伝搬法の提案," 電子情報通信学会論文誌, Vol.J88-D-II, No.10, pp.2125-2133, pp.399-406, 2005
- [4] 長沼秀典, 大堀隆文, 渡辺一央, "デジタル型リカレントネットに対する DBP 学習法," 電子情報通信学会総合大会講演集 CD-ROM, D-2-7, 2006
- [5] 森海太郎, 岩本英樹, 大堀隆文, 渡辺一央, "揺らぎ駆動学習ニューラルネットワークによる有限状態オートマトンの同定," 信学技報, NC2000-88, pp.23-30, 2001
- [6] Giles C., Miller C., Chen D., Sun G., Lee Y., "Learning and Extractiong Finite State Automata with Second-Order Recurrent Neural Networks," Neural Computation, 4(4), pp.393-405, 1992