

G-018

デジタル型通時誤差逆伝搬法による有限状態オートマトンの学習 Learning of the Finite State Automaton with Digital Type Back Propagation Through Time

長沼 秀典[†]
Hidenori Naganuma

丸山 勇介[†]
Yusuke Maruyama

大堀 隆文[‡]
Takafumi Oohori

渡辺 一央[§]
Kazuhiisa Watanabe

1. まえがき

非対称なフィードバック結合を含む再帰型ニューラルネットは、時系列データなどの動的な問題を解くことが可能であり、また、隠れ素子を持たせることで複雑な内部状態を表現することができる。Rumelhartらは、誤差逆伝搬法を時間方向に展開することで再帰型への適用が可能であることを示唆し、通時誤差逆伝搬法 (BPTT と略す) を提案した [1]。

しかし、出力素子が連続値をとるため内部状態も連続で複雑になり、オートマトンの内部状態推定などのデ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ジタルであることが要求される課題に対しては、不可微分なデジタル素子からなるニューラルネットを適用することが自然であると考えられ、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, 4]。

本論文では、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たデジタル型 BPTT [5] によって有限状態オートマトンの同定が可能であり、離散的な出力を状態とみなすことで状態遷移図が獲得できることを実験的に示す。

2. デジタル型通時誤差逆伝搬法

デジタル型通時誤差逆伝搬法 (以下、DBPTT) は、階層型デジタルネットワークの学習法である DBP を再帰型ニューラルネットに適用した学習法である。DBPTT によって周期波形の学習が可能であり、離散的な内部状態の表現が容易であるという特徴を持つ。

入力素子数 1 の再帰型ニューラルネットにおいて、時刻 t における素子 j の出力値は次式で定義される。

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

ここで、 w_{ji}^H は第 i 素子から第 j 素子への結合係数を表わし、 w_j^I は入力素子から第 j 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、 $O_j(t-1)$ は時刻 $t-1$ での第 j 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。

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、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。以下、便宜的に時刻 $t-1, t, t+1$ での素子に対

[†]北海道工業大学大学院工学研究科電気工学専攻

[‡]北海道工業大学工学部情報デザイン学科

[§]北海道工業大学工学部情報ネットワーク工学科




図 1: 再帰型リカレントネットと時間展開

する添え字を i, j, k とした。時刻 t での結合係数修正量は次式のデルタ則に従う。

$$\Delta w_{ji}^H(t) = -\alpha(O_j(t) - T_j(t))O_i(t-1) \quad (2)$$

$$\Delta w_j^I(t) = -\alpha(O_j(t) - T_j(t))x(t) \quad (3)$$

ここで、 j が可視素子であるならば、 $T_j(t) = T(t)$ とし、隠れ素子ならば、時刻 $t+1$ での誤差が減少するような教師信号を与える。そのために、教師決定因子 $S_j(t)$ を、

$$S_j(t) = \sum_k (O_k(t+1) - T_k(t+1))w_{kj}^H \quad (4)$$

とおき、次式により教師信号を設定する。

$$\text{if } S_j(t) > 0 \quad \text{then } T_j(t) = 0 \quad (5)$$

$$\text{if } S_j(t) < 0 \quad \text{then } T_j(t) = 1 \quad (6)$$

$$\text{if } S_j(t) = 0 \quad \text{then } T_j(t) = O_j(t) \quad (7)$$

各素子での結合係数修正量を教師信号を与えた時刻分で総和し、結合係数を修正する。すなわち、

$$w^H = w^H + \sum_t \Delta w^H(t) \quad (8)$$

$$w^I = w^I + \sum_t \Delta w^I(t) \quad (9)$$

とする。

3. 有限状態オートマトン

有限状態オートマトンは、離散的な入出力と有限個の内部状態を持つシステムで、その出力方式の違いによっていくつかのタイプに分類できる。こ

ここで、有限状態オートマトン A を次式で定義する。

$$A = (Q, \Sigma, \Delta, \delta, \varphi, q_0) \quad (10)$$

- Q : 状態の集合 $Q \neq \phi$
- Σ : 入力文字 $\Sigma = \{0, 1\}$
- Δ : 出力文字 $\Delta = \{0, 1\}$
- δ : 状態遷移関数 $\delta: Q \times \Sigma \rightarrow Q$
- φ : 出力関数
- q_0 : 初期状態 $q_0 \in Q$

出力関数が状態と入力文字の関数 ($\varphi: Q \times \Sigma \rightarrow \Delta$) の場合をミーリ型、出力関数が状態のみに依存する ($\varphi: Q \rightarrow \Delta$) 場合をムーア型とよぶ。

3.1 再帰型ネットワークとの比較

デジタル素子で構成された再帰型ネットワークは、ある時刻における各素子出力の組み合わせを状態とみなすと、素子数 n では 2^n 個の有限な状態空間 \bar{Q} を持つ。また、ある結合係数を定めると、各素子の出力がステップ関数で定義されていることから、状態遷移関数 ($\bar{\delta}: \bar{Q} \times \Sigma \rightarrow \bar{Q}$) が一意に定まる。よって、再帰型ネットワークは (11) 式のように定義することができ、有限状態オートマトンを直接表現することができる。

また、入力を持たないネットワークの場合、出力関数が状態から決定するムーア型、入力を持つネットワークの場合、ミーリ型の有限状態オートマトンに一致する。

$$B = (\bar{Q}, \Sigma, \Delta, \bar{\delta}, \bar{\varphi}, q_0) \quad (11)$$

- \bar{Q} : 状態の集合 $\bar{Q} = \{q_i | i \in 2^n\}$
- Σ : 入力文字 $\Sigma = \{0, 1\}$
- Δ : 出力文字 $\Delta = \{0, 1\}$
- $\bar{\delta}$: 状態遷移関数 $\bar{\delta}: \bar{Q} \times \Sigma \rightarrow \bar{Q}$
- $\bar{\varphi}$: 出力関数
- q_0 : 初期状態 $q_0 \in \bar{Q}$

DBPTT アルゴリズムでは、結合係数の修正によって出力関数、状態遷移関数を調整することが可能であり有限状態オートマトンを直接的に解くことが可能であると考えられる。

4. 数値実験

4.1 入力を持つ有限状態オートマトンの学習

数値実験として、入力と状態から出力が決定するミーリ型オートマトンをデジタル型リカレントネットに学習させ、適切な内部状態を獲得できること実験的に検証する。

学習対象のオートマトン課題として、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]。TG は 7 種提案されているが、この実験では状態数が 2 である TG1、状態数が 3 である TG2、状態数が 4 である TG4 を用いた (図 2)。学習係数 $\alpha = 0.1$ とし、結合係数の初期値を一様乱数で定めた。また各素子の時刻 0 における初期値 $O_j(0)$ は 1 とした。各課題の学習に用いたネットワークの構成素子数、実験条件を表 1 に示す。

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定義する。また、乱数系列 100 種を用いて結合係数を初期化し学習成功率を観測した。また、学習が成功したネットワークについて、学習終了後、長さ 16 の全ての

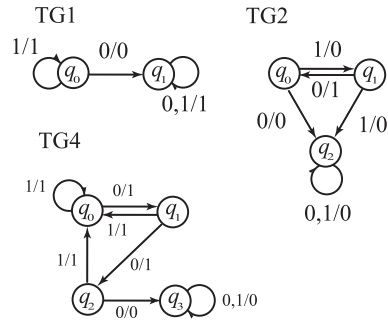


図 2: Tomita Grammar の状態遷移図

0, 1 の組合せ (2^{16} パターン) を入力時系列として与え、正しく応答できるかどうかを同定 (汎化) 能力とした。本実験では入力時系列すべてに正しく応答できたものを汎化成功とみなす。実験結果を表 2 に示す。

表 2 より、TG1, TG2 は入力時系列に対して高い精度で学習できていたが、汎化性能が若干低下していた。実験で用いた再帰型ネットワークは素子数が 5 であり、内部状態が最適化されていない場合でも入力時系列の学習が可能なのである。なお、学習に用いる時刻を延ばすことで、構成素子数が多い場合でも高い汎化性能を持たせることができた。これは、学習に用いることのできる状態が増加し、内部状態がより適切に学習されるためである。また、提案手法は TG4 の学習精度が低いが、学習が成功した場合、適切な内部状態の獲得に成功し、高い汎化能力を持っていた。

同課題を微分可能素子からなる再帰型ネットワークに学習させた場合、学習に非常に時間がかかり、学習に改良を加えなければ汎化性能が獲得できないことが報告されている [7]。

以上の結果から、提案手法により学習された再帰型ネットワークは、十分な長さの入力時系列に対する応答を学習させることで、内部状態が本質的に有限であることから、有限状態オートマトンの適切な内部状態の遷移を獲得することが可能であることがわかった。

4.2 状態遷移図の獲得

素子出力が連続値である再帰型ネットワークでは、内部状態を表現する場合に出力からなるベクトル空間をクラスタリングするなどの工夫が必要であった。素子出力が離散値である再帰型ネットワークでは、構成素子の出力の組み合わせを状態とみなすことで、オートマトンの内部状態を容易に表すことができる。

図 3 に、前節の実験によって獲得できた状態遷移図を示す。図中で状態の番号を便宜的に q_n と表記したが、出力の組み合わせがどの状態に当たるかは結合係数初期値により変化する。

学習後、汎化に成功した場合には (a) のように最適化された状態遷移図のほか (b), (c) のような冗長な遷移図が多く見られた。これは、一つの状態が複数の状態間の遷移に置き換わったことで、最適化された状態遷移図の獲得ができなかったためである。

また、汎化に失敗した場合、(d) のように多くの状態を

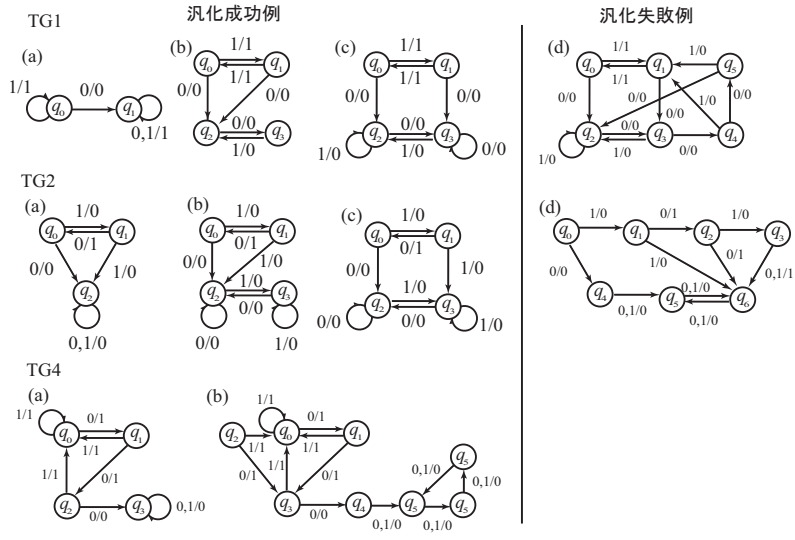


図 3: 獲得された Tomita Grammar の状態遷移図

表 1: Tomita Grammar の実験条件

	TG1	TG2	TG4
学習係数	0.1		
構成素子数	5		
最大学習回数	10 ⁵		
入力時系列長	3	5	7
汎化時系列長	16		

表 2: Tomita Grammar の実験結果

	成功率	収束回数	汎化能力
TG1	100	141.5	58
TG2	100	419.3	74
TG4	14	3906.5	100

持つ状態遷移図となる傾向があった。このことから、入力時系列に対して閉じた遷移を獲得できず、不完全な状態遷移に対して汎化時系列を入力したために正しい応答ができなかったことがわかる。

5. おわりに

本論文では、デジタル型通時誤差逆伝搬法を用いることで、デジタル素子で構成された再帰型ネットワークが有限状態オートマトンを直接的に解くことが可能であることを実験的に示した。数値実験から、提案手法は状態数の少ないオートマトンの学習・同定が可能であり、離散である内部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. 有限状態オートマトンの学習・汎化精度の向上
2. より複雑な内部状態を持つ有限状態オートマトンの

学習と同定

3. 状態遷移図獲得のメカニズムの解明

参考文献

- [1] D.E.Rumelhart, G.E.Hinton and R.J.Williams : "Learning internal representations by error propagation", Parallel Distributed Processing Vol.1, The MIT Press, pp.318-362,1986
- [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] 大堀 隆文, 鎌田 修平, 小林 靖宏, 小西 儀紀, 渡辺 一央: "微分不能素子をも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", 信学技報告, NC99-85, pp41-48, 2000.
- [4] 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.2125-21332, pp.399-406, 2005
- [5] Hidenori Naganuma, Takahumi Oohori and Kazuhisa Watanabe, "Learning Cyclic Oscillation By Digital Type Recurrent Neural Network", 2006 IEEE World Congress on Computational Intelligence, 2006
- [6] Giles C., Miller C., Chen D., Sun G., Lee Y., "Learning and Extracting Finite State Automata with Second-Order Recurrent Neural Networks," Neural Computation, 4(4), pp.393-405, 1992
- [7] 小西儀紀, 大堀隆文, 渡辺一央, "再帰型ニューラルネットとクラスタリングによるオートマトンの同定," 電子情報通信学会技術報告, NC99-84, pp.33-39, 2000