

2N-2

自己相関関数を規範としたリカレントニューラルネットワークの学習による有限状態機械の模倣

並松 祐子¹ ピトヨ ハルトノ² 鈴木 健嗣³ 三枝 亮³ 橋本 周司³

早稲田大学大学院理工学研究科物理学及应用物理学専攻¹

早稲田大学 WABOT-HOUSE 研究所²

早稲田大学理工学部応用物理学科³

1. はじめに

学習システムとして知られるニューラルネットワーク(以下 NN)は理論、応用共に盛んに研究されている[1][2]。その中でリカレントニューラルネットワーク(以下 RNN)は、内部状態を保持する構造を持つことから、システムの故障診断[3]、自然言語理解[4]など動的システムの学習という課題に用いられる。また、RNN の学習により有限状態機械(FSM)を模倣する試みもあるが、RNN と FSM の初期状態を一致させて学習を始める必要がある。そこで、本研究では出力の自己相関関数を規範として、初期状態を知ることなしに RNN を学習することにより FSM の模倣を試みた。

2. 有限状態機械(FSM)

2-1 FSM

対象とする FSM \mathcal{A} は、入力 I 、出力 O 、状態 S 、出力則 f と状態遷移則 g により定義される。出力則 f は、時刻 t の入力信号 i_t と状態信号 s_t に対し、時刻 t の出力信号 o_t を対応させ、状態遷移則 g は、時刻 t の入力信号 i_t と状態信号 s_t に対し時刻 $t+1$ の状態信号 s_{t+1} を対応させる。ここでは簡単のために I, O, S を $\{0, 1\}$ のバイナリ信号の集合とし、出力則 f に AND、状態遷移則 g に NAND を用いた(表 1、式 1)。

$$A = \{I, O, S, f, g\}$$

$$o_t = f(i_t, s_t) \quad \dots(1)$$

$$s_{t+1} = g(i_t, s_t)$$

表1 状態遷移Nandと出力And

入力(i_t) \ 状態(s_t)	次の状態(s_{t+1})		出力(o_t)	
	0	1	0	1
0	1	1	0	0
1	1	0	0	1

Emulating FSM using RNN based on Autocorrelation.
 1. Graduate School of science and engineering, Waseda Univ.
 2. WABOT-HOUSE Laboratory, Waseda Univ.
 3. Department of Applied Physics, Waseda Univ.

2-2 FSM 出力の自己相関値

2-1 で示した FSM の出力の自己相関関数を理論的に算出した。時刻 t の入力信号 i_t 、出力信号 o_t 、状態信号 s_t が 1 である確率をそれぞれ、 $P_i(t)$ 、 $P_o(t)$ 、 $P_s(t)$ とすると、式(1)は式(2)、式(3)のように表現できる。

$$P_s(t) = 1 - P_i(t-1)P_s(t-1) \quad \dots(2)$$

$$P_o(t) = P_i(t) \cdot P_s(t) \quad \dots(3)$$

また、自己相関関数は、式(4)で定義される。


$$R(\tau) = \frac{1}{N} \sum_{\tau=0}^{N-1} o_t o_{t-\tau} \quad \dots(4)$$

定常性を仮定して状態の定常確率を求め、これを用いてそれぞれの $P_i(t)$ に関する自己相関値を計算した。表 2 に $P_i(t)=1/2$ の場合の自己相関関数値 $R_{FSM}(\tau)$ を示す。

表 2 自己相関関数値 $R_{FSM}(\tau)$

$R_{FSM}(\tau)$	0	1	2	3	4	5	6	7
	0.333	0.00	0.16	0.08	0.12	0.10	0.11	0.10
		0	7	3	5	4	5	9

(注) $P_i(t)=1/2$ 、出力則 AND



3. ニューラルネットワーク(NN)の学習

3-1 RNN モデル

RNN(図 1 (a))を出力の自己相関関数が FSM と同じになるように学習させる。第二層のニューロンの出力関数にシグモイド関数を用い、第一層の出力関数は線形関数とした。第一層の 2 番目のニューロンの入力に常に -1 とした。学習アルゴリズムの説明のため NN モデル(図 1 (b))について説明する。図 1(b)は RNN でのフィードバ

ック処理を展開したものである。各層間の結合荷重は同じ値である。各層は左端から順に時刻 t , $t+1$, $t+2$, ... を表し、自己相関関数の学習に必要な数の層を持つ。各層のニューロンについて上端から識別番号 i を付す。時刻 t での i 番目のニューロンの入力を x_t^i 、出力を y_t^i とし、 j 番目のニューロンから k 番目のニューロンへの結合荷重は w_{jk} と表す。ここで、 $i \in \{1, 2, 3, 4, 5\}$ 、 $j \in \{1, 2, 3, 4\}$ 、 $k \in \{3, 4, 5\}$ である。3', 4' は、内部状態を表すニューロン 3、4 の 1 時刻前を表す。

3 - 2 学習アルゴリズム

モデル図 1 (b) について時刻 t では $i=5$ 、それ以外の層では $i=3, 4, 5$ でのニューロンについて、出力関数 $f(x)$ を式 (6) に示すシグモイド関数である。評価関数 E を式 (7) とし学習を行う。

$$f(x) = \frac{1}{1 + \exp\left(-\frac{x}{A}\right)} \quad \dots(6)$$

$$E = \frac{1}{2} \sum_{\tau} (R_{nn}(\tau) - R_{fsm}(\tau))^2 \quad \dots(7)$$

$$R_{nn}(\tau) = y_t \cdot y_{t+\tau}$$

y_t は t 時間での RNN の出力とする。

RNN の重みベクトル W は誤差逆伝播法 [5] により更新し、以下の式に示す。

$$W(t+1) = W(t) - \eta \frac{\partial E}{\partial W(t)} \quad \dots(8)$$

$$\begin{aligned} \frac{\partial E}{\partial W(t)} &= \sum_{\tau=1}^T \frac{\partial}{\partial W(t)} (R_{nn}(\tau) - R_{fsm}(\tau))^2 \\ &= \sum_{\tau=1}^T (R_{nn}(\tau) - R_{fsm}(\tau)) \left\{ y_t \frac{\partial y_{t+\tau}}{\partial W(t)} + y_{t+\tau} \frac{\partial y_t}{\partial W(t)} \right\} \end{aligned} \quad \dots(9)$$

ここで、 η は学習率であり、0.01 とした。

内部状態の初期値としては、理論計算から求めた定常確率 P_s を与える。E が充分小さくなるまで、学習用ランダム入力系列の識別番号を a として、以下の手順を繰り返して学習を行った。

- Step 0: w_{jk} をランダムに $[0, 1]$ で設定し、 $a=0$ とする。
- Step 1: $t=a$ とし、 $x_t^3=x_t^4=P_s$ とする。
- Step 2: x_t^1 に確率 1/2 で i_t を加え、 y_t^5 を計算する。 t に 1 を加える。
- Step 3: $T+1$ 回 Step 2 を繰り返し、式 (7) により E を計算する。
- Step 4: 誤差逆伝播法を用いて結合荷重 w_{jk} を更新する。
- Step 5: a に 1 を加え、Step 1 にもどる。

4 . 結果と考察

学習時と同様に確率 1/2 でバイナリ入力を加えてテストし、RNN の内部状態 y_t^3 、 y_t^4 を観察した。図 2 について横軸は y_t^3 、縦軸は y_t^4 を表す。同じ入力を与えた FSM の内部状態と RNN の内部状態に対応するそれぞれの値を対応づけ、FSM の状態 $s=0$ に対応する RNN の状態を $s=0$ 、 $s=1$ のそれを $s=1$ で表示している。2500 ステップの中から 250 個のデータを定期的に 50 個ずつ取り出した値で、破線のように 2 つの領域に分割されることが観察できた。これより、RNN モデルが NAND 遷移を持つ FSM の状態遷移を内部構造として保有したので、有限状態機械が模倣できたことが判る。図 3 はテスト系列の一部を取り出し状態遷移を線で示したものである。

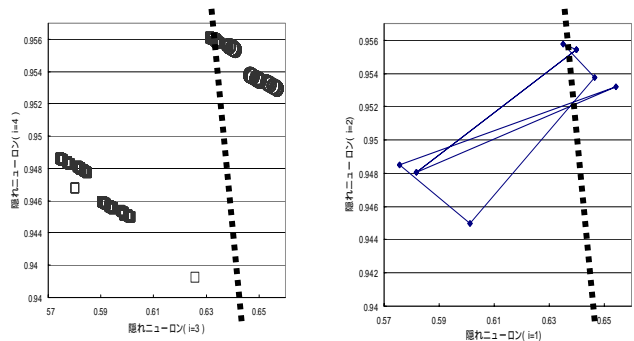


図 2 内部状態ニューロン出力 図 3 内部状態ニューロン出力遷移

5 . まとめ

論理型有限状態機械のニューラルネットワークモデルによる模倣学習について、自己相関関数を規範として学習し状態遷移則を獲得できることを示した。今後、有限状態機械の出力値についても検討したい。

参考文献

- [1]新井, 中野, 内部状態制約を考慮したリカレントニューラルネットワークの学習, 信学論, Vol. J82-D-II, No.11, pp.2101-2110, 1999
- [2]S.C.Kremer, On the Computational Power of Elman-Style Recurrent Networks, IEEE trans. on NNs, Vol.6, No.4 JULY, 1995
- [3]S.Ohteru, T.Kato, S.Hashimoto, K.Watabe, D.Minegishi, Digital circuit test system using statistical method, The 10th International Symposium on Fault-Tolerant Computing, 1980
- [4]J.L.Elman, Finding Structure in Time, Cognitive Science, 14, 179-211, 1990
- [5]D. Rumelhart and J. McClelland, Learning Internal Representation by Error Propagation, Parallel Distributed Processing1, pp. 318-362, 1986.