

S-CTRNN を用いた複数時系列パターンの記憶学習

村田 真悟* 有江 浩明† 尾形 哲也† 谷 淳‡ 菅野 重樹†

* 早稲田大学理工学術院 創造理工学研究科 総合機械工学専攻 † 早稲田大学理工学術院

‡ Korea Advanced Institute of Science and Technology

1. はじめに

これまで時系列パターンの記憶学習に、現状態と文脈情報から次状態を予測することが可能な再帰結合神経回路 (recurrent neural network: RNN) が広く用いられてきた [1–3]. しかし、決定論モデルであるという特性から教示時系列に潜む確率的な構造を獲得することができないという問題がある. また、複数パターン間でノイズの程度 (分散) が異なると、小さな分散のパターンが大きな分散のパターンに埋もれてしまい、全パターンを安定的に学習することができないという問題もある.

本研究では、従来の学習方法である二乗誤差最小化に基づく点予測の枠組みを拡張し、尤度最大化に基づき確率分布の予測学習が可能な stochastic continuous time RNN (S-CTRNN) [4,5] を用いることで、前述の問題が解決可能であることを示す.

2. 学習モデル

これまで用いられてきた CTRNN は、次式で表されるように現時刻 t における学習対象の状態 s_t を入力 x_t とし、それから次時刻 $t+1$ の状態 s_{t+1} を予測し、 y_t として出力する予測モデルである.

$$(y_t, c_t) = f(x_t, c_{t-1}; \theta). \quad (1)$$

ここで、 c_t はフィードバックによる文脈情報 (過去の状態の記憶)、 $f(\cdot)$ は活性化関数、 θ はモデルのパラメータである. すなわち CTRNN の学習とは、ある I 次元の時刻 ($t = 1, 2, \dots, T$) の入力時系列 $X_I = (x_t)_{t=1}^T$ と、その予測状態に対応する、ある O 次元の時刻 ($t = 1, 2, \dots, T$) の教示時系列 $\hat{Y}_O = (\hat{y}_t)_{t=1}^T$ (入出力が同次元 $I = O$ の場合、 $(\hat{y}_t)_{t=1}^T = (x_{t+1})_{t=1}^T$ となる) のペアの集合 (X_I, \hat{Y}_O) を学習用データとして、正解を出力するようなモデルのパラメータ θ を求める問題である. また、今回用いる S-CTRNN は式 (1) に加えて、次式で表されるように次状態の分散 v_t も予測学習する.

$$v_t = g(x_t, c_{t-1}; \theta). \quad (2)$$

ここで、 $g(\cdot)$ は活性化関数である.

S-CTRNN の学習では、教示時系列 (観測時系列) \hat{Y}_O があるとき、このデータが未知の生成モデルからある確率分布に従って生成されたと仮定する. そして、この未知の生成モデルを学習モデル S-CTRNN によって再現することで、教示時系列と同じ確率的構造をもったデータの生成を目指す.

本研究では、教示時系列 \hat{Y}_O に対応する入力時系列 X_I があるとき、時刻 t における i 番目の要素 ($i \in I_O: I_O$ は添字集合) の教示データ $\hat{y}_{t,i}$ の確率密度 $p(\hat{y}_{t,i} | (x_{t'})_{t'=1}^t, \theta)$ とし、平均 $y_{t,i}$ 、分散 $v_{t,i}$ の正規分布 $\mathcal{N}(y_{t,i}, v_{t,i})$ を仮定する. ここで、 θ は S-CTRNN のパラメータで、結合

係数、バイアス、コンテキストニューロンの初期値を示す. S-CTRNN はこれらのパラメータ θ を学習によって調整することで、これまでに受けた入力時系列 $(x_{t'})_{t'=1}^t$ から次状態の平均 $y_{t,i}$ と分散 $v_{t,i}$ の予測が可能となる.

学習は最急降下法を用いた最尤法によって行われ、用いられる尤度関数 L は次式で表されるように、前述の確率密度 $p(\hat{y}_{t,i} | (x_{t'})_{t'=1}^t, \theta)$ の時刻 ($t = 1, 2, \dots, T$)、要素 $i \in I_O$ に関する積である.

$$L = \prod_{t=1}^T \prod_{i \in I_O} p(\hat{y}_{t,i} | (x_{t'})_{t'=1}^t, \theta). \quad (3)$$

3. 数値実験

教示時系列群として、次式で表される 2 次元から成る 72 個の時系列パターンを用いた.

$$\begin{cases} \hat{y}_{t,1}^{(s)} = 0.8 \sin\left(\frac{a\pi}{25}t\right) \cos\left(\frac{b\pi}{25}t\right) + \epsilon\{(\hat{\sigma}^{(s)})^2\}, \\ \hat{y}_{t,2}^{(s)} = 0.8 \sin\left(\frac{c\pi}{25}t\right) \cos\left(\frac{d\pi}{25}t\right) + \epsilon\{(\hat{\sigma}^{(s)})^2\}. \end{cases} \quad (4)$$

ここで、 s は s 番目の時系列パターンを意味し、それに応じてパターンを特徴づけるパラメータ a, b, c, d が $a \in \{1, 2\}$, $b \in \{1, 2, 3, 4\}$, $c \in \{1, 2, 3\}$, $d \in \{1, 2, 3\}$ から選択された. また、パターン毎に大きさの異なる分散 $(\hat{\sigma}^{(s)})^2$ に従うガウスノイズ $\epsilon\{(\hat{\sigma}^{(s)})^2\}$ が加えられている.

コンテキストニューロン数 $M = 100$ 、時定数 $\tau = 2$ の S-CTRNN を用いて、500,000 回の繰り返し計算により学習を行った. 学習後のネットワークに、各パターンに関して自己組織化されたコンテキストニューロンの初期値をセットし、閉ループによって時系列の生成を行った. 教示時系列と S-CTRNN の閉ループによる平均の出力を図 1 に示す.

図 1 から、全てのパターンに関して、その平均を S-CTRNN が出力していることがわかる. これから、学習に用いられた全 72 個の時系列パターンが複数アトラクターとして一つの S-CTRNN に埋め込まれているといえる. さらに、予測された分散が教示時系列を作成する際に用いられた分散の正解値を近似していることも確認した.

また、事前実験において従来の CTRNN は分散の小さなパターンの記憶学習に失敗することを確認した. これは、前述のように分散の小さなパターンの予測誤差が、分散の大きなパターンの予測誤差に「埋もれる」ことによって生じたと考えられる.

これらから、ノイズの分散の大きさが異なるような複数のパターンを学習する場合、S-CTRNN を用いることで学習時に分散を予測し尤度関数に用いるため学習が安定したと考えられる. また、[5] で示されているように、その予測された分散を閉ループに足しこむことで教示時系列の確率的構造の再現も可能となる.

Learning to Memorize Multiple Temporal Patterns Using S-CTRNN: Shingo Murata (Waseda Univ.), Hiroaki Arie (Waseda Univ.), Tetsuya Ogata (Waseda Univ.), Jun Tani (KAIST), and Shigeki Sugano (Waseda Univ.)




図 1: 教示時系列 (グレー) と S-CTRNN の閉ループによる平均の出力 (黒) . 教示時系列に加えられたガウスノイズの分散 $(\hat{\sigma}^{(s)})^2$ は列毎に共通で、左から 0.001, 0.0015, 0.002, 0.0025, 0.003, 0.0035, 0.004, 0.0045, 0.005 である .

4. まとめと展望

本研究では、ガウスノイズの分散の大きさが異なる全 72 個の時系列パターンを、S-CTRNN が複数アトラクターとして記憶可能であることを示した .

今回の実験では、人工的に作成された単純な 2 次元の時系列パターンを学習対象として用いたが、今後はこの結果を参考にし、人間のモーションキャプチャデータやロボットの感覚・運動データといった、より高次元で複雑なものを扱う予定である .

謝辞

本研究成果の一部は、文部科学省科研費基盤研究 (S) (No. 25220005), 文部科学省科研費新学術領域研究「構成論的発達科学」(No. 24119003), 文部科学省「卓越した大学院拠点形成支援補助金」, JST さきがけ領域「情報環境と人」の助成を受けたものです . 本研究成果の一部は、早稲田大学理工研プロジェクト研究「自然と共生する知能情報機械系に関する基盤研究」の一環として行

われたものです . ここに謝意を表します .

参考文献

- [1] K. Doya and S. Yoshizawa, "Memorizing Oscillatory Patterns in the Analog Neuron Network," in Proceedings of the IEEE International Joint Conference on Neural Networks (IJCNN '89), 1, pp. 27-32, Washington, DC, USA, June 1989.
- [2] J. Tani and M. Ito, "Self-Organization of Behavioral Primitives as Multiple Attractor Dynamics: A Robot Experiment," IEEE Transactions on Systems, Man and Cybernetics Part A, 33(4), pp. 481-488, 2003.
- [3] J. Namikawa and J. Tani, "Building Recurrent Neural Networks to Implement Multiple Attractor Dynamics Using the Gradient Descent Method," Advances in Artificial Neural Systems, 2009. doi:10.1155/2009/846040
- [4] J. Namikawa, R. Nishimoto, H. Arie, and J. Tani: "Synthetic Approach to Understanding Meta-Level Cognition of Predictability in Generating Cooperative Behavior," Advances in Cognitive Neurodynamics (III), Springer, pp. 615-621, 2013.
- [5] S. Murata, J. Namikawa, H. Arie, S. Sugano, and J. Tani: "Learning to Reproduce Fluctuating Time Series by Inferring Their Time-dependent Stochastic Properties: Application in Robot Learning via Tutoring," IEEE Transactions on Autonomous Mental Development, 5(4), pp. 298-310, 2013.