

# Multiple Timescales RNN を用いた敵対的模倣学習による時系列の複雑化と構造化

佐々木 太樹<sup>†</sup> 野口 渉<sup>‡</sup> 飯塚 博幸<sup>‡,§</sup> 山本 雅人<sup>‡,§</sup>  
 北海道大学 大学院情報科学院<sup>†</sup> 北海道大学 大学院情報科学研究所<sup>‡</sup>  
 北海道大学 人間知・脳・AI 研究教育センター<sup>§</sup>

## 1. はじめに

鳥のさえずりは自然界における複雑で階層構造を持つ時系列として知られる．鳥のさえずりのように生物たちが進化の過程で複雑かつ構造を持った時系列を獲得したプロセスを探索する研究がなされており，特に複雑化プロセスについては敵対的模倣という個体間の競争が時系列の複雑化を促進することが示されている[1]．一方で，時系列の構造化を同時に促進するようなプロセスは明らかになっていない．

本研究では時系列の複雑化および構造化を同時に促進するプロセスのモデル化を試みる．特に時系列の構造化が各個体の時系列生成を担う神経回路網の階層性に起因するとの仮説の下，そのモデルとして異なる時間スケールで活動する複数のニューロン群から構成される Multiple Timescales RNN (MTRNN) [2]を用いる．提案モデルによる2個体間での敵対的模倣のシミュレーションの結果，各個体が生成する時系列の複雑性が増加しつつも構造化が促進されることを示す．また，時系列はMTRNNによって機能的に階層性を伴い生成されうること示す．

## 2. シミュレーションモデル

本研究では各個体がMTRNNを用い，互いの時系列を真似しつつも相手からは真似されないようにする敵対的模倣を行う．なお，本研究で扱う時系列は4種類の記号['A', 'B', 'C', 'D']からなる記号列とする．

### 2.1. Multiple Timescales RNN (MTRNN)

MTRNN は Input-Output (IO) 層，Fast Context (FC) 層，Slow Context (SC) 層と呼ばれる3つのRNNの層を持ち，それぞれは異なる速度で内部状態を更新する．また，各層はIO-SC間を除

### Complexity Growth and Structurization of Time Series by Adversarial Imitation Learning using Multiple Timescales RNN

Taiki Sasaki<sup>†</sup>, Wataru Noguchi<sup>‡</sup>, Hiroyuki Iizuka<sup>‡,§</sup> and Masahito Yamamoto<sup>‡,§</sup>

<sup>†</sup> Graduate School of Information Science and Technology, Hokkaido University

<sup>‡</sup> Faculty of Information Science and Technology, Hokkaido University

<sup>§</sup> Center of Human Nature, Artificial Intelligence, and Neuroscience, Hokkaido University

いて互いに結合重み行列を介して繋がっている．各層で行われる計算を以下に示す．

$$h_t^l = \left(1 - \frac{1}{\tau_l}\right) h_{t-1}^l + \frac{1}{\tau_l} \sum_{k \in I^l} w_k^l x_t^k, \quad (1)$$

$$y_t^l = \begin{cases} \text{Softmax}(h_t^l) & (l = IO) \\ \text{Sigmoid}(h_t^l) & (\text{otherwise}) \end{cases}, \quad (2)$$

$$x_t^l = \begin{cases} \mathbf{0} & (t = 0) \\ y_{t-1}^l & (\text{otherwise}) \end{cases}. \quad (3)$$

ここで， $\tau_l$ は $l$ 層で用いる時定数， $x_t^l, h_t^l, y_t^l$ はそれぞれ $l$ 層の $t$ ステップ目における入力，内部状態および出力を表す． $I^l$ は $l$ 層への結合重み行列を有するRNNの集合であり， $I^{IO} = \{IO, FC\}$ ,  $I^{FC} = \{IO, FC, SC\}$ ,  $I^{SC} = \{FC, SC\}$ である．また $w_k^l$ は $k$ 層から $l$ 層への結合重み行列を表す．(1)式は $l$ 層での内部状態の更新を行う式であり，内部状態の更新速度は時定数 $\tau_l$ に依存する．本研究では $\tau_{IO} = 1.2$ ,  $\tau_{FC} = 2$ および $\tau_{SC} = 30$ としている．また，(2)および(3)式はそれぞれ各層の出力および入力を与える式であり，出力は内部状態に活性化関数を適用することで得られ，入力は直前のタイムステップの出力により与えられることを示す．特にIO層の出力 $y_t^{IO}$ は出力する記号の確率分布であり，系列 $\mathbf{S} = [y_1^{IO}, y_2^{IO}, \dots, y_T^{IO}]$ を各個体の生成する時系列とする．ここで $T$ は時系列長を表す．

### 2.2. 敵対的模倣学習

本研究では2個体A, B間での敵対的模倣のプロセスを以下の手順でモデル化する．

1. 個体A, BはMTRNNを用い，それぞれの時系列 $\mathbf{S}^A, \mathbf{S}^B$ を生成する．
2. 個体AはBの時系列 $\mathbf{S}^B = [y_1^{IO(B)}, y_2^{IO(B)}, \dots, y_{T-1}^{IO(B)}]$ を受け取り，模倣時系列 $\mathbf{S}^{A'}$ を生成する (図1)．つまり，個体AのMTRNNのIO層への入力 $x_t^{IO(A)}$ は(3)式に代わり(4)式となる．

$$x_t^{IO(A)} = \begin{cases} \mathbf{0} & (t = 0) \\ y_{t-1}^{IO(B)} & (\text{otherwise}) \end{cases}. \quad (4)$$

個体Bも同様に模倣時系列 $\mathbf{S}^{B'}$ を生成する．

3. 個体Aは模倣時系列 $\mathbf{S}^{A'}$ をBの記号列 $\overline{\mathbf{S}^B}$ に近づけつつも，時系列 $\mathbf{S}^{A'}$ はBの模倣記号列 $\overline{\mathbf{S}^{B'}}$ から遠ざかるように以下の損失 $E^A$ によ




図 1 MTRNN の構造

り MTRNN の重みを更新する.

$$E^A = L(\mathbf{S}^{A'}, \mathbf{S}^B) + L(\mathbf{1} - \mathbf{S}^A, \mathbf{S}^{B'}). \quad (5)$$

ここで,  $L(\mathbf{X}, \mathbf{Y})$  は  $\mathbf{X}$  と  $\mathbf{Y}$  の交差エントロピー誤差を表し,  $\bar{\mathbf{X}}$  は確率分布の時系列  $\mathbf{X}$  から得られる記号列を表す. 個体 B も同様に MTRNN の重みを更新する.

敵対的模倣のプロセスは手順 1 から 3 を繰り返すことで進行し, この一巡を 1 epoch とする.

### 3. 実験

MTRNN を用いた敵対的模倣学習により時系列の複雑化と構造化が同時に起こることを示す. なお, 本研究では時系列の複雑性の評価指標に各個体の記号列  $\mathbf{S}^A, \mathbf{S}^B$  を DEFLATE アルゴリズムによる圧縮後の記号列のサイズを圧縮前の記号列のサイズで割ることで得られる圧縮率を用いる. また構造化の評価には SEQUITUR アルゴリズムによる記号列の文法圧縮を施し, 得られる構文木の深さを測ることで記号列の持つ階層性を測る. すなわち, 記号列中に繰り返し現れる部分列もまた部分列の組み合わせからなるといった言語的入れ子構造を測る.

#### 3.1. 実験設定

時系列長  $T = 63$  とし, IO 層, FC 層および SC 層のニューロン数をそれぞれ 4, 32, 4 としている. また MTRNN の最適化手法に Adam を用い, 学習率は 0.005 とした.

#### 3.2. 時系列の複雑化と構造化

図 2 に記号列の圧縮率と構文木の最大の深さの推移を示す. 図 2(a) より, 各個体の生成する記号列は圧縮しづらい時系列と変化していき, 時系列の複雑性は増加することがわかる. また図 2(b) より, 記号列は階層を深め, 時系列の構造化も同時に促進されることがわかる.

#### 3.3. 機能的な階層性を伴った時系列生成




図 2 (a) 圧縮率の推移

(b) 構文木の深さの推移




図 3 (a) 初期の記号列

(b) 750epoch 時の記号列

3.2 節で示した記号列そのものの階層性とは別に, MTRNN は FC 層では繰り返し現れる部分列の生成を担い, SC 層では部分列の並び替えを担うといった RNN 層の機能的な階層性を伴った時系列生成が行われる [2]. ここでは 3.2 節の実験で学習された MTRNN を初期状態として, SC 層, すなわち  $\mathbf{W}_{SC}^{SC}$  のみを更新する重みとした上で敵対的模倣学習を行う. なお, FC 層により生成される部分列を検出するため, 本研究ではこの学習の過程で出力される各個体の記号列を 50 epoch 毎に抽出し, それらを系列データとして系列パターンマイニングの手法の一つである SPADE を適用する. これにより SC 層の学習を通して保存される部分列の検出が可能となる. 図 3 は個体 B の記号列を検出された部分列毎に色分けした例であり, 4 種類の部分列 ACBBA (赤), ADCBA (緑), ACBA (青) および ADBBA (橙) を並び替えるように敵対的模倣学習が進むことがわかる. よって, 敵対的模倣学習において時系列は機能的な階層性を伴い生成されることが示唆される.

### 4. まとめ

本研究では MTRNN を用いた敵対的模倣学習により時系列の複雑化と構造化が同時に促進されることを示した. また, 時系列は MTRNN により機能的な階層性を伴い生成されることが示唆された.

#### 参考文献

- [1] Yamazaki S, Iizuka H and Yamamoto M. Complexity of bird song caused by adversarial imitation learning. *Artificial Life and Robotics* 25(1), pp.124-132, 2020.
- [2] Yamashita Y and Tani J. Emergence of Functional Hierarchy in a Multiple Timescale Neural Network Model: A Humanoid Robot Experiment. *PLOS Computational Biology* 4(11), e1000220, 2008.