

電気光遅延リザーバコンピューティングにおける強化学習を用いたモデル選択実験

Experiment on adaptive model selection using reinforcement learning in optoelectronic reservoir computing

埼玉大¹, 東大情理² ○水戸 遼平¹, 菅野 円隆¹, 成瀬 誠², 内田 淳史¹
Saitama Univ¹, Univ. Tokyo²

Ryohei Mito¹, Kazutaka Kanno¹, Makoto Naruse², and Atsushi Uchida¹

Emails: r.mito.047@ms.saitama-u.ac.jp, auchida@mail.saitama-u.ac.jp

はじめに:

近年、機械学習（人工知能）に関する研究開発が盛んに行われており、光を用いた実装にも注目が集まっている[1]。光を利用することで高速な情報処理が可能となる。光を用いた機械学習手法の一つとして、光リザーバコンピューティングが挙げられる[2]。その特徴の一つは、レーザと時間遅延フィードバックループをネットワークの代わりに使用し、出力の重みのみを学習することである。ネットワーク部を学習する必要がないため、少量データで学習が可能であり、さらに物理実装に適した情報処理手法であることが知られている。

リザーバコンピューティングによる情報処理において、学習済みの入力モデルとは異なるモデルが入力された場合、情報処理精度が悪化することが考えられる。一方で様々な入力モデルを学習させた場合、個々のモデルに対する情報処理精度が悪化すると考えられる。この問題に対処する手法として、強化学習を用いたモデル選択手法が報告されている[3]。これまでに数値シミュレーションにおいてモデル選択が有効であることが示されているが、実験的な調査は未だ行われていない。

そこで本研究では、異なる複数のモデルから生成された時系列データを入力信号とし、電気光遅延リザーバコンピューティングと強化学習を用いたモデル選択を実験的に行うことを目的とする。

方法: 本研究では、電気光遅延システム[2]によりリザーバコンピューティングを実装する。これは半導体レーザ、電気-光変換を行う光強度変調器、信号を遅延させるための光ファイバループから構成される。リザーバコンピューティングにより入力信号の予測を行うことを考え、予測対象のモデルが一定間隔で異なる3つのモデルに切り替わることを想定する。各モデルに対して、予め異なる重みで学習を行う。予測を行う際に、高い予測精度を示す重みを強化学習に[4]基づいて選択する。




Fig. 1 Schematic diagram of adaptive model selection using reservoir computing.

次にリザーバコンピューティングにおける強化学習を用いたモデル選択の概念図を Fig. 1 に示す。本研究では、異なる3つのモデルの波形を入力し、応答波形から各モデルに対し学習を行った3つの異なる重みを取得する。次に3つの異なるモデルが一定間隔で切り替わる波形を入力し、応答波形を取得する。

用意した3つの異なる重みと切り替わる波形の応答波形から、3つの異なる予測結果 p_1, p_2, p_3 を取得する。この3つの予測結果に対し、 $[-1, 1]$ の値を取りうる異なるカオス波形を割り当てる。各予測結果に対応するカオス波形の比較を行い、ある地点でサンプリングを行った際に最大値を取るカオス波形を選択する。次に選択した予測結果の予測誤差を算出し、過去に選択した予測誤差の50点分の平均値と比較を行う。平均値よりも選択した予測誤差が小さい場合には、モデルに対応したカオス波形の振幅に正のバイアスを加える。予測誤差が大きい場合には負のバイアスを加える。バイアスはカオス波形と同じ $[-1, 1]$ の間で変化する波形とする。バイアスが1に到達すると、対応するモデルの予測結果のみが選ばれる。

結果: 強化学習によるモデル選択を100回行った時の正しいモデルが選択された割合 (Correct Model Selection Rate, CMSR) を Fig. 2 に示す。本研究で用いたモデルは、レスラーモデル、ローレンツモデルとマッキングラスであり、波形の初期値と順番は毎回ランダムに変化させる。Fig. 2 (a) より、モデルは時系列のサンプリング点数 $n = 1000$ ごとに切り替わっている。Fig. 2 (b) は CMSR 結果を示しており、モデルが切り替わっても正しいモデルが選択された割合は0から1へ増加していることが確認できる。切り替わる前と後では正しいモデルが選択された割合の上昇の速さが異なる。これはモデルの判別の難しさに依存すると考えられる。このように、3つのモデルが時間的に切り替わる場合に強化学習を用いることで、モデル選択を実験的に達成した。




Fig. 2 Result of adaptive model selection.

まとめ: 本研究では、複数の異なるモデルから生成された時系列データを入力信号とし、電気光遅延システムのリザーバコンピューティングと強化学習を用いたモデル選択を実験的に行った。学習モデルが時間的に切り替わる入力信号に対して、強化学習によるモデル選択の有用性を示した。

参考文献

- [1] A. Argyris, et al., Sci. Rep., **8**, 8487 (2018).
- [2] L. Larger, et al., Opt. Express, **20**, 3241 (2012).
- [3] K. Kanno, et al., Sci. Rep., **10**, 10062 (2020).
- [4] K. Morijiri, et al., Proc. NOLTA 2020, 1 (2020).