

セル・オートマトンを用いた Reservoir Computing における Kernel Rank ・ Generalization Rank と長期・短期記憶の関係性と特徴分析

理学専攻・情報科学コース 岩井さくら (指導教員：Natanael Aubert-Kato)

1 はじめに

再帰ニューラルネットワーク (RNN) とは、ニューラルネットワークを拡張し、時系列データを扱えるようにしたものである。RNN は、層を重ね過去の情報を伝搬することでより多くのモデル化が可能になる反面、計算コストが膨大になってしまうという一面もある。

本研究では、その RNN の欠点を解消する学習モデルである Reservoir Computing(RC)[1] に着目した。RC は RNN に比べ、学習コストを削減できるという利点がある。この RC をセル・オートマトンというアルゴリズムを用いて構築し [2], 全ルール分の特徴分析を通して、今後のルールの選択を容易なものとする。

2 背景

2.1 Reservoir Computing

RC は、入力層と中間層 (Reservoir 層) の間で重みをランダムに決定する。そして、出力層でのみ簡単な関数を使い学習を行う。これにより、膨大になりがちな RNN のコストを大幅に削減することができる。さらに重みの更新を行わない簡単な構造により、低電力での動作することができ、様々な物理システムを使用したハードウェア実装を可能としている。また Reservoir 層でのみノード間の結合を許し層の内部状態を保つことで、モデル内に短期記憶を用意し時系列データの因果関係を扱えるようにしている。つまり、内部で非線形変換が行われていれば Reservoir として使える可能性も秘めているということである。




図 1: Reservoir Computing

2.2 セル・オートマトン

セル・オートマトンとは、格子状の計算モデルである。個々のセルの状態を現在の状態と隣接するセルの状態に応じて、一定のルールに従って時間的に更新させていく。このルールを活用することで Reservoir 層の設定をルール選択のみで行うことができるのである。図 2 にルール 90 と、ランダムな初期状態からルール 90 に従いセル・オートマトンを更新させた例を示す。またセル・オートマトンのもう一つの側面としては、0・1 のバイナリ表現で構成されているという点がある。整数しか使用せず実数を必要としないため、Reservoir として使用することで、学習のための計算が簡単になり、またメモリの使用を抑えられると考えられる。




図 2: セル・オートマトンの進化例 (ルール 90)

3 実験手法

セル・オートマトンの Reservoir としての特徴を分析するために、ポピュラーな RNN のタスクである 5-bit memory task に加え、Kernel Rank ・ Generalization Rank の計測を取り入れた。

- **Kernel Rank (KR)** : Reservoir が異なる入力パターンを分離できるかどうかの能力を示す指標である。Reservoir は異なる入力に対して非線形変換を行い、それらの適切な読み出しを行うため、Reservoir の非線形表現を生成する能力を測定する必要がある。良い Reservoir は高い KR を持つ。
- **Generalization Rank (GR)** : 類似の入力ストリームが与えられた場合の Reservoir の汎化能力を示す尺度である。強力な計算機において、類似の入力値に対しては類似の非線形変換を行うことが必要なため、Reservoir が見たことのない入力データの将来の結果を予測する能力を定量化する必要がある。良い Reservoir は低い KR を持つ。
- **5-bit memory task** : 5 ビット 32 パターンの入力値を正しく予測できるかどうかを調査する (図 3)。これによって任意の時間までの Reservoir の記憶保持能力を測ることができる。

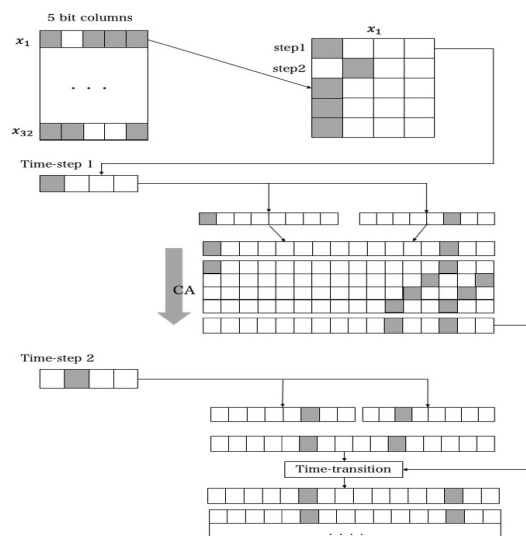


図 3: 5-bit memory task の構成

それぞれのルールにおいてセル・オートマトンの進化回数 (I) と入力値のランダムマッピングの回数 (R) を変化させてシミュレーションを行った。

4 実験結果

KR・GR 縦軸が I, 横軸が R として表した結果を図 4・5 に示す。256 ルールのうち Kernel Rank において良い結果を示したのはルール 30 で精度は 0.95187(図 4 左上), 次にルール 45 で 0.94968(図 4 左下)であった。Generalization Rank において良い結果を示したのはルール 128 で精度は 0.020624(図 5 左上), 次にルール 8 で 0.04843(図 5 左下)であった。ルール 0 についてはここでは除外している。




図 4: Kernel Rank




図 5: Generalization Rank

5-bit memory task 一番良い結果を示したのはルール 45 であり精度は 0.95556 (図 6 左上), 次にルール 22 で精度は 0.93990 (図 6 左下)であった。R を大きくすると, ほとんどのルールで性能が向上した。しかし, I の値によっては性能は低下するものが多かった。これは, Reservoir のサイズが十分でないために進化によって記憶の伝搬が上手くいかなかったという原因が考えられる。



図 6: 5-bit memory task

相関係数 KR・GR と 5bittask の結果の相関係数を調べたところ, KR と正の相関が見られた。これは, セル・オートマトンの入力値の分離能力が長時間に渡って記憶の伝搬することを手助けしているからだと考えられる。反対に入力値を汎化する GR とは負の相関を持っており, 記憶の長期的な伝搬とは相性が悪いことがわかった。

表 1: 5bittask との相関係数

	KR	GR	KR&GR
相関係数	0.67488	-0.75673	-0.00586

3 特徴の関係性 最後に, これまでの結果を平均してルール毎にまとめ, 横軸が KR, 縦軸が GR, カラーが 5-bit memory task を表す 2 次元の表とした (図 7)。先ほどの相関係数の値の通り, 5-bit memory task の結果が高くなるとどうしても GR が高くなってしまいう傾向が見られた。そのため, 高い性能を持つ Reservoir を選択するためには, 3 つの特徴全てのバランスを見なければならないことがわかった。その上で KR・5-bit memory task が高く, GR が低いという良い結果が得られたのは, ルール 43, 142, 154 であった。特にルール 43 は, KR が 0.88812, GR が 0.26468, 5-bit memory task の結果が 0.81468 となり十分 Reservoir としての性能を果たせることがわかった。




図 7: GR(縦軸)・KR(横軸)・5bittask(color) のルール毎の関係性を表したもの

5 まとめと今後の課題

本研究では, 計算コストが少ないモデルである Reservoir Computing にセル・オートマトンを使用し, 全ルールにおける特徴分析を行った。そして, それぞれのルールの特徴が判明し, 今後使用する際のルール選択が容易となった。今後は, この得られた特徴を基にルールを選択し, 少ない計算量で高い性能を必要とする小型ロボットのコントローラ [3] に実装し, テストしていく予定である。

参考文献

- [1] Yamane T. Héroux J. B. Nakane R. Kanazawa N. Takeda S. ... & Hirose A. Tanaka, G. Recent advances in physical reservoir computing: A review. *Neural Networks*, Vol. 115, pp. 100–123, 2019.
- [2] Ozgur Yilmaz. Reservoir computing using cellular automata. *arXiv preprint arXiv:1410.0162*, 2014.
- [3] Ahler C. Nagpal R. Rubenstein, M. Kilobot: A low cost scalable robot system for collective behaviors. *IEEE international conference on robotics and automation*, Vol. 8, pp. pp.3293–3298, 2012.