

福岡工業大学 学術機関リポジトリ

リザバーコンピューティングによる極端現象の発生時間予測に向けて

メタデータ	言語: ja 出版者: 福岡工業大学総合研究機構 公開日: 2023-12-06 キーワード (Ja): キーワード (En): 作成者: 中川 正基, 大久保 健一 メールアドレス: 所属: 情報工学科, 山口東京理科大学工学部電気工学科
URL	http://hdl.handle.net/11478/0002000062

リザバーコンピューティングによる 極端現象の発生時間予測に向けて

中川 正基（情報工学部情報工学科）
大久保 健一（山口東京理科大学工学部電気工学科）

Toward Occurrence Time Prediction for Extreme Events Using Reservoir Computing

NAKAGAWA Masaki (Department of Computer Science and Engineering, Faculty of Information Engineering)
OKUBO Ken-ichi (Department of Electrical Engineering, Faculty of Engineering, Sanyo-Onoda City University)

Abstract

Machine learning methods for predicting extreme events have been variously proposed. Reservoir computing (RC) methods are important for extreme events since it requires promptness. This study aims to propose a framework for predicting the occurrence time of extreme events using RC and to evaluate its prediction ability. This report describes the efforts for them.

Keywords : Reservoir computing, Extreme events, Promptness, Time horizon of prediction

1. はじめに

気象・経済・地震などにみられる極端な現象は、発生確率は低いがひとたび起これば社会に大きな影響を与える。このような極端現象の予測に関して、時系列データへの様々な機械学習的手法が提案されている。その中でもリカレントニューラルネットワーク (RNN) を用いたリザバーコンピューティング (RC) は時系列データ向けで高速な学習が可能な手法であり⁽¹⁾、速報性が必要な極端現象予測において重要な手法であると考えられる。本研究の目的は、RC による極端現象の発生時間予測の新たな枠組みを提案し、その予測性能を評価することである。本稿では、この目的に向けた現状の取り組みについて報告する。

2. 背景

近年、極端現象に対して、力学系理論の立場からメカニズムとデータを組み合わせて予測につなげるアプローチが発展してきている^(2, 3)。このアプローチでは、極端現象は決定論的法則の下で状態空間中の「極端事象集合」上で起きると考える。このアプローチの延長線上で、時系列データに深層学習などの機械学習的手法を適用し、状態空間と観測量の間の写像を学習し、極端現象の予測につなげるアプローチが盛んに研究されている^(4~8)。中でも、時系列データを扱うことから RNN を用いる RC が取り上げられることが多くなってきており^(9, 10)。特に、部分観測系に対応した Asch らの RC を用いる手法⁽¹¹⁾では、順伝搬型ニューラルネットワ

ーク (FNN) や Long Short Term Memory (LSTM) を比較対象として性能評価を行っており、RC を用いる手法の一定の優位性が示されており興味深い。

上記の RC を用いる手法は極端現象予測の速報性の必要性から今後重要になると考えられる。しかしながら、我々は、従来の RC を用いる手法には共通の問題点があると考えている。それは、まず極端現象に対して時系列予測 (m ステップ先予測) を行い、その予測された時系列に基づいて極端現象の発生時刻を予測するという 2 段階構えになっている点である。この 2 段階の予測方法では、(1) 速報性に影響を与える可能性がある、(2) 予測の期間 (time horizon of prediction) [m ステップ] を変えられない、変える場合は再学習が必要になる、というデメリットがある。そこで本研究では、この問題点を回避するため、現在までの時系列データから直接「次の極端現象が起きるまでの時間」を予測する RC を用いる手法の提案を目指す。本研究により、従来の RC を用いる手法に実用的な視点を新たに加味し、速報性や予測の期間の問題に対して素朴だが実用的な解決策を与える。

3. 提案手法の概要

以下は、Asch らの RC を用いる手法⁽¹¹⁾をベースとした、現在我々が検討している提案手法の概要である。但し、本研究は継続中であり、提案手法には今後変更が生じる可能性がある。以降、先行研究とは Asch らの研究⁽¹¹⁾を指す。

3.1 リザバーモデル RC で用いるリザバーのモデルとして

エコーステートネットワーク (ESN)⁽¹²⁾を用いる。ESNにはいくつかの派生モデルがあり、先行研究ではいわゆる基本モデルを用いている。しかし、極端現象は早い変化と遅い変化が混在しているため、変化の速度に柔軟に追従することを可能とする仕組みを備えたものが良いと考えられる。そこで本提案手法では、Leaky Integrator (LI) モデルを用いる。LI モデルはリーク率によりリザバーの状態変化の速さを調節することができる（詳しくは、文献⁽¹⁾の該当部分を参照されたい）。リーク率をうまく設定、あるいは適応的に設定することで、極端現象の過去の情報をうまく使うことができると考えられる。

3.2 学習アルゴリズム RC ではリザバーからの読み出し部の出力結合重み行列を線形回帰などの簡便な学習アルゴリズムで最適化する。先行研究では、リッジ回帰 (L_2 正則化項をもつ線形回帰) を用いている。リッジ回帰はデータを一定期間貯めておき、一括してパラメータを最適化するバッチ学習の一種である。極端現象の予測における速報性の重要性を考えると、時々刻々のデータが与えられるたびにパラメータを最適化するオンライン学習が適していると考えられる。そこで本提案手法では、オンライン学習の一種である逐次最小二乗 (RLS) 法を用いる（詳しくは、文献⁽¹⁾の該当部分を参照されたい）。RLS 法を用いることで速報性のある予測器を実現できると考えられる。RC と RLS 法の組み合わせは FORCE 学習として知られているが⁽¹³⁾、我々の知る限り、これを極端現象の予測に適用した例はない。

3.3 予測対象 時系列予測が RC に適したタスクであることは広く知られている⁽¹⁾。そのため、先行研究では 2 段階の予測方法（まず時系列予測を行い、その予測された時系列に基づいて極端現象の発生時刻を予測）を採用していた。しかし、この 2 段階の予測方法は、先述の通りデメリットがある。そこで本提案手法では、より直接的に、現在までの時系列データから「次の極端現象が起きるまでの時間」を予測する。現在までの時系列データを入力すると次の極端現象が起きるまでの時間を出力するように、リザバーからの読み出し部の出力結合重み行列を最適化する。予測対象を、次の極端現象が起きるまでの時間に絞ることで、より速報性があり、より柔軟な予測器を実現できると考えられる。

3.4 入力変数 通常の RC による時系列予測では、状態空間のすべての変数をリザバーに入力する。しかし先行研究では、この点を現実的に考え、観測者は状態空間の一部の変数しか観測できないこと（部分観測系）を前提にして、状態空間の一部の変数だけをリザバーに入力している。従って、本提案手法でも状態空間の一部の変数だけを入力する。このような一部の情報だけを入力とすれば、より現実的な予測器を実現できると考えられる。

4. 今後の計画と現状

以下に今後の計画と現状を記す。但し、本研究は継続中であり、進捗によって計画に変更が生じる可能性がある。

4.1 先行研究の追試 まず本研究の着想に影響を与えた、先行研究の追試を行う。これによりハイパーパラメータを設定する上でのコツをつかむ。また、先行研究で比較対象としている FNN や LSTM などでの追試も行う。

4.2 プロトタイプの実装 極端現象の発生時間を予測する RC のプロトタイプを考案し、それをプログラム実装する。先行研究でも扱われている極端現象のパラダイムモデル（レスラー方程式やローレンツ方程式などの間欠的カオス力学系）を用いてテストし、細部のアーキテクチャを決定していく。

4.3 性能評価 提案手法の最適なハイパーパラメータを決定するため、極端現象のパラダイムモデルを用いて予測性能のテストを繰り返す。そして、その最大予測性能を定量化していく。さらに、先行研究で扱っていた、より現実的な極端現象のモデル（フィットヒュー・南雲方程式やコルモゴロフの流れ）を用いて現実的な予測性能を評価する。また、他の手法（FNN や LSTM など）との性能比較も行い、提案手法の特徴を明らかにしていく。

4.4 現状 まず先行研究の追試を行うために、Asch らが公開しているプログラム⁽¹⁴⁾を用いた。Asch らのプログラムでは、ESN の学習を Python ライブラリの `easyesn` により行い、その可視化を MATLAB により行っている。ESN による予測手法の再現、また先行研究において比較対象とされていた FNN や LSTM による予測手法の再現には概ね成功することができた。現時点では（ハイパーパラメータをデフォルトに固定しているため）十分な追試を行ったとは言い難いが、現在は、ひとまず先にプロトタイプの考案・実装の準備に取り掛かっている。プロトタイプの実装のため、著者のひとり（中川）がかつて C 言語で実装した ESN によるカオス時系列予測のプログラムを用いることにした。Asch らのプログラムを使わない理由は、Asch らは Python ライブラリを多用しており、アルゴリズム開発の自由度がないと判断したためである。この C プログラムはローレンツ方程式を対象としているが、当面は先行研究に合わせてレスラー方程式を対象とする。現在、先行研究と同じ設定で C プログラムの実装を進めている。

5. おわりに

本稿では、RC による極端現象の発生時間予測に向けた現状の取り組みを報告した。提案手法は先行研究をベースに、速報性があり、予測の期間の変更問題を回避できるような、より極端現象に適していると思われるアーキテクチャを採用している。現状はアイデアを具現化する段階であり、早急にプロトタイプの実装を進めたい。今後、実際に極端現象を予測させる過程で様々な追加の工夫が必要になってくると思われる。試行錯誤を繰り返しながら実用的な予測手法にまで高めていきたい。

将来展望として、極端現象の少数データ性の観点から、駆動方程式が分かっていない極端現象（例えば、ロスアラモス

のレーザー時系列など) の予測に提案手法を適用し、提案手法の実用性の評価を行っていきたい。

謝辞 本研究は、福岡工業大学情報科学研究所の 2022 年度スタートアップ研究支援制度により実施したものである。

文 献

- (1) 田中剛平、中根了昌、廣瀬 明:「リザバーコンピューティング: 時系列パターン認識のための高速機械学習の理論とハードウェア」、森北出版 (2021).
- (2) M. Farazmand and T. P. Sapsis: "Extreme events: Mechanisms and prediction," *Appl. Mech. Rev.*, Vol.71, 050801 (2019).
- (3) T.P. Sapsis: "Statistics of Extreme Events in Fluid Flows and Waves," *Annu. Rev. Fluid. Mech.*, Vol.53, pp.85-111 (2021).
- (4) D. Ding, M. Zhang, X. Pan, M. Yang, and X. He: "Modeling Extreme Events in Time Series Prediction," in *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (KDD '19)*, pp.1114-1122 (2019).
- (5) D. Qi and A. J. Majda: "Using machine learning to predict extreme events in complex systems," *Proc. Natl. Acad. Sci. U.S.A.*, Vol.117, pp.52-59 (2020).
- (6) J. Meiyazhagan, S. Sudharsan, and M. Senthilvelan: "Model-free prediction of emergence of extreme events in a parametrically driven nonlinear dynamical system by deep learning," *Eur. Phys. J. B*, Vol.94, pp.1-13 (2021).
- (7) J. Meiyazhagan, S. Sudharsan, A. Venkatesan, and M. Senthilvelan: "Prediction of occurrence of extreme events using machine learning," *Eur. Phys. J. Plus*, Vol.137, 16 (2022).
- (8) J. Jiang, Z-G Huang, C. Grebogi, and Y-C Lai: "Predicting extreme events from data using deep machine learning: When and where," *Phys. Rev. Res.*, Vol.4, 023028 (2022).
- (9) A. Chattopadhyay, P. Hassanzadeh, and D. Subramanian: "Data-driven predictions of a multiscale Lorenz 96 chaotic system using machine-learning methods: Reservoir computing, artificial neural network, and long short-term memory network," *Nonlin. Processes Geophys.*, Vol.27, pp.373-389 (2020).
- (10) V. Pyragas and K. Pyragas: "Using reservoir computer to predict and prevent extreme events," *Phys. Lett. A*, Vol.384, 126591 (2020).
- (11) A. Asch, E. J. Brady, H. Gallardo, J. Hood, B. Chu, and M. Farazmand: "Model-assisted deep learning of rare extreme events from partial observations," *Chaos*, Vol.32, 043112 (2022).
- (12) H. Jaeger: "The ‘echo state’ approach to analyzing and training recurrent neural networks - with an erratum note," *GMD Technical Report* 148 (2001).
- (13) D. Sussillo and L. F. Abbott: "Generating coherent patterns of activity from chaotic neural networks," *Neuron*, Vol.63, pp.544-557 (2009).
- (14) A. Asch, E. J. Brady, H. Gallardo, J. Hood, B. Chu, and M. Farazmand: "GitHub repository: Deep learning for extreme events," (2021); available at <https://github.com/mfarazmand/DeepLearningExtremeEvents>