

Symposium (Oral) | Symposium : Towards social applications of physical reservoir computing using new materials and new principles

📅 Thu. Sep 19, 2024 1:30 PM - 5:10 PM JST | Thu. Sep 19, 2024 4:30 AM - 8:10 AM UTC 🏢 A41 (TOKI MESSE 4F)

[19p-A41-1~6] Towards social applications of physical reservoir computing using new materials and new principles

Teruo Kanki(Osaka Univ.)

1:30 PM - 2:10 PM JST | 4:30 AM - 5:10 AM UTC

[19p-A41-1]

Machine-learning computing utilizing an insulating magnetic film as a continuous-media-type reservoir

○Ryosho Nakane^{1,2} (1.Univ. of Tokyo, 2.EEIS)

2:10 PM - 2:50 PM JST | 5:10 AM - 5:50 AM UTC

[19p-A41-2]

Theoretical analysis of physical reservoir computing using spin waves

○Natsuhiko Yoshinaga^{1,3,5}, Satoshi Iihama², Yuya Koike⁴, Shigemi Mizukami³ (1.Future Univ. Hakodate, 2.Nagoya Univ., 3.Tohoku Univ. AIMR, 4.Tohoku Univ., 5.AIST)

3:00 PM - 3:40 PM JST | 6:00 AM - 6:40 AM UTC

[19p-A41-3]

Silicon CMOS Physical Reservoir Computing

○Tetsuya Asai¹ (1.Hokkaido University)

3:40 PM - 4:20 PM JST | 6:40 AM - 7:20 AM UTC

[19p-A41-4]

Complex time series pattern recognition with reservoir computing

○Gouhei Tanaka¹ (1.NITech)

4:20 PM - 5:00 PM JST | 7:20 AM - 8:00 AM UTC

[19p-A41-5]

Material Reservoir Computing Devices with Promising Social Application

○Hirofumi Tanaka^{1,2} (1.LSSE, Kyushu Inst. Tech., 2.Neumorph Center, Kyushu Inst. Tech.)

5:00 PM - 5:10 PM JST | 8:00 AM - 8:10 AM UTC

[19p-A41-6]

Closing

○Seiya Kasai¹ (1.Hokkaido Univ.)

絶縁性磁性体膜を連続媒質型リザーバーに利用した 機械学習コンピューティング Machine-learning computing utilizing an insulating magnetic film as a continuous-media-type reservoir

東大工学系 d.lab¹, 電気系²

中根了昌^{1,2}

¹Systems Design Lab, ²Department of Electrical Engineering and Information Systems,
Graduate School of Engineering, The Univ. of Tokyo
Ryosho Nakane^{1,2}

再帰型ニューラルネットワークを用いた機械学習コンピューティングの一つであるリザーバーコンピューティング (RC) は、調整パラメータを持たない「リザーバー」と呼ばれる系列データ入出力変換の溜池を用いる [1, 2]。この特徴によって、リザーバーから出力層に接続された結合重みのみを線形回帰により最適化することで、様々な時系列データの情報処理が可能となる。ここでリザーバーの機能性は、短期的記憶を持ちながら 1 次元系列データを高次元空間に非線形写像することである。物理 RC は、こうしたリザーバーの機能性を自然に潜在する非線形物理ダイナミクスによって置き換えた「物理リザーバー」を実現する試みで、これまで様々な物理系を用いたコンピューティングが原理実証されている [3, 4]。物理リザーバーは、簡便な電子デバイス等でも実現が可能であることから、次世代超低消費電力エレクトロニクスを目指した電子デバイス・回路分野における物理 RC の研究が活性化してきている。

物理 RC システムは利用する物理リザーバーに依存して、ネットワーク型、フィードバック型、ヒステリシス型、連続媒質型、のシステムに分類することができる [5]。ここで連続媒質型とは、物理量が外部刺激によって応答し、しばらくすると元に戻る興奮性媒質を物理リザーバーに利用したシステムを示す。代表例は、物理 RC 黎明期において報告された、文字通りの物理リザーバー「バケツ中の水」を利用したシステムである [6]。内部配線の無い非常に簡便な物理リザーバーであるため拡張性と高性能化のポテンシャルが高いが、自由度が高い反面、システム設計の見通しが立ちづらい困難があり、他の型に比べると報告例は多くない。一方、時系列入力が励起する時空間に分布した非線形ダイナミクスを利用するこの型は、物理 RC の計算原理を具現化しているといえる。このことから、物理 RC 計算原理の深い理解に役立つ「物理ダイナミクスと計算性能の関係解明」や、工学的発展のために必要な「物理 RC システム設計法の確立」につながる知識と技術を集積していくには、優れた系のひとつであると考えている。

これまで、物理シミュレーションをベースとした計算実験によって、局所電子スピンの興奮性媒質となる連続様な絶縁性磁性体膜をリザーバーに用いた 1 入力多出力電子デバイスを提案し、研究を行ってきた [7-9]。利用する物理量は局在電子スピンの 1 方向成分である。デバイス動作原理は、磁性体膜中心に位置する入力電極の局所において励起された運動はスピン波となって連続空間を伝播し、空間に分布した多数の検出器によってスピンの時系列出力信号を得ることである。この単純な系において、短期記憶性、非線形性、高次元性という写像の要求仕様をどのように満たして情報処理タスクの計算性能を高めていくかを探究してきた。短期記憶と非線形現象を同時に満たし短期記憶性と非線形性につなげるには物理系の過渡応答を利用することが有用であることから [5]、スピン歳差運動の緩和時間を見積もり、RC 計算の離散時間ステップとの対応関係を多数試行した。また、1 つの時系列入力から多様な時系列出力信号を得て高次元性につなげるためには、ダイナミクスの空間分布を生み出す仕掛けが必要であり、非線形現象が起こりやすい小さな外部磁場を用いること、スピン波の反射と干渉を多数起こすと同時に非線形現象を導入するためにストライプ磁区を利用すること、外部磁場によりダイナミクスを操作して出力信号を変化させること、などの工夫を駆使した。計算実験の利点を活かし、こうした数々のパラメータ設定に対してタスク計算性能がどのように変化するかに関連性を調べた。これと同時に、物理現象の特徴量抽出に基づく考察を行うことで、どのような非線形物理現象が有用であるかを見出しつつある。

講演ではスピンを用いた物理 RC の結果とともに、それにより見出された物理現象と計算原理との関係の考察、計算性能を高めるヒントとなるシステム設計の技術、などについても紹介をおこなう。

参考文献 [1] H. Jaeger, GMD Technical Report **148**, 13 (2001). [2] W. Maass, T. Natschläger, and H. Markram, Neural Comput. **14**, 2531 (2002). 706 [3] G. Tanaka, et al., Neural Netw. **115**, 100 (2019). [4] K. Nakajima, Jpn. J. Appl. Phys. **59**, 060501 (2020). [5] 田中, 中根, 廣瀬, リザーバーコンピューティング, 森北出版, 2021 年. [6] C. Fernando and S. Sojakka, European Conf. Artificial Life, 588 (2003) [6] R. Nakane, G. Tanaka, and A. Hirose, IEEE ACCESS **6**, 4462 (2018). [7] R. Nakane, A. Hirose, and G. Tanaka, Phys. Rev. Res. **3**, 033243 (2021). [8] R. Nakane, A. Hirose, and G. Tanaka, Phys. Rev. Appl. **19**, 034047 (2023).

スピン波による物理リザーバー計算の理論的解析

Theoretical analysis of physical reservoir computing using spin waves

はこだて未来大情報¹, 名古屋大工², 東北大 AIMR³, 東北大工⁴, 産総研 MathAM-OIL⁵,

○義永 那津人^{1,3,5}, 飯浜 賢志², 小池 雄也⁴, 水上 成美³

Future Univ. Hakodate¹, Nagoya Univ.², Tohoku Univ.³, AIST⁴,

○Natsuhiko Yoshinaga^{1,3,4}, Satoshi Iihama², Yuya Koike³, Shigemi Mizukami³

E-mail: yoshinaga@fun.ac.jp

近年、ナノメートル、ギガヘルツで動作する省電力人工知能の実現に向けてスピントロニクスの技術を用いた脳型計算機の物理実装が注目を集めている。その中で、リザーバー計算はニューラルネットワーク内部の重みを調整せずに学習を行うことができるため、物理実装の有望な手法となっている。これまでにスピントルク発振器やスピン波を内部層として用いた物理リザーバー計算機が実験的に報告されてきたが、短期記憶容量などの学習性能は他の物理系である光リザーバーに比べて劣っているのが現状である。スピントロニクスを使ったりリザーバー計算の高性能化には、スピンダイナミクスがどのように学習性能と結びついているのかを明らかにする必要がある。そこで、本研究では、ナノスケールにおける高性能なスピン波リザーバー計算をマイクロマグネティックシミュレーションによって実証し、理論的な解析を行うことで高い学習性能に必要な条件を明らかにすることを目的とする。

図(c)に本研究で考えるスピン波のシステムを示す。入力と出力を兼ねたノードにおいて、入力となる時系列に比例する強度でスピン注入トルクによりスピンダイナミクスを励起し、発生したスピン波を出力ノードで読み出す。リザーバー計算による時系列データの学習では、入力の時系列から、過去の時刻のデータを読み出したり（記憶）、未来のデータの予測などのタスクを行うことができる（図(a)）。スピン波のダイナミクスを記述する Landau-Lifshitz-Gilbert 方程式から、入力に対する応答を計算することで、入力した情報が他のノードにどのように伝わるのかを解析した（図(b)）。その結果、ノード間の距離の最大値を特徴的なシステムサイズとした時に、このサイズとスピン波の電波速度との間に比例関係がある時に学習性能が最大になることを見出した。講演では、マイクロマグネティックシミュレーションの結果とともに、スピン波によるリザーバー計算の学習のメカニズムについて議論する。

[Ref.] Satoshi Iihama, Yuya Koike, Shigemi Mizukami, Natsuhiko Yoshinaga, *npj Spintronics*, **2**, 5 (2024).




Fig. (a-c) Schematics of our physical reservoir computing system using spin waves. (d,e) The linear (MC, d) and nonlinear (IPC, e) memory capacity obtained from our theoretical analyses of the Landau-Lifshitz-Gilbert equation. (f) Schematics of propagation of information from an input to output nodes with different delay time.

シリコン CMOS 物理リザーバーコンピューティング

Silicon CMOS Physical Reservoir Computing

北大情科院 浅井 哲也

Hokkaido Univ., Tetsuya Asai

E-mail: asai@ist.hokudai.ac.jp

シリコン CMOS デバイスで構成されたアナログおよびデジタルリザーバーとそのオンライン学習器からなる物理リザーバーコンピューティングの概要と応用例を紹介する。CMOS リザーバー・学習器は、性能目標を設定した上で、ボトムアップで回路を構築できる特徴を持っている。限られたハードウェアリソース（CMOS 素子、面積、電力）の範囲内で、リザーバーコンピュータとしての性能を最大化するための様々な工夫が込められている。

まず、北大の物理リザーバーを紹介する。具体的には、以下の3つのタイプがある：

1. アナログ CMOS リザーバー[1]：省回路面積と低消費電力を重視し、アナログ CMOS デバイスでリザーバーを構成
2. 低～中速演算用デジタル CMOS リザーバー[2]：様々なタスクに適応できる非線形性を持ち、内部重みを自動生成するデジタル CMOS リザーバー。重みパラメータを保存するメモリが不要
3. 高速演算用デジタル CMOS リザーバー[3]：高速演算・リアルタイム処理に特化したデジタル CMOS リザーバー

次に、北大のリザーバーオンライン学習器を紹介する。以下の2つのタイプがある：

1. フォグ・クラウド向け超高速 FORCE 学習エンジン[4]：シストリックアレイによる高速な学習を実現するが、コストが高く回路面積も大きい。
 2. エッジ向け学習エンジン[5]：アンサンブルカルマンフィルタを用いた省面積・低電力・低コスト（しかし低スループット）の学習エンジンで、エッジデバイス向けに適している
- 最後に、これらの CMOS リザーバーの実応用例と今後の展望について述べる。

参考文献

1. Abe Y., et al., *Scientific Reports*, vol. 14, no. 1, 10966 (2024).
2. Abe Y., et al., *Nonlinear Theory and Its Applications*, vol. E15-N, no. 2, pp. 262-272 (2024).
3. Abe Y., et al., *Int. J. Parallel, Emergent and Distributed Syst.*, vol. 39, no. 2, pp. 197-213 (2024).
4. Yoshida K., et al., *Journal of Signal Processing*, vol. 26, no. 4, pp. 103-106 (2022).
5. 玉田 洸太, 阿部 佑紀, 浅井 哲也, "アンサンブルカルマンフィルタのストリーミングハードウェアアーキテクチャ," 電子情報通信学会複雑コミュニケーションサイエンス研究会 (CCS), 富山県立大学, (富山), 2023 年 11 月 11-12 日.

リザーバーコンピューティングによる複雑時系列パターン認識

Complex time series pattern recognition with reservoir computing

名工大工¹ °田中 剛平¹

Nagoya Institute of Technology¹, °Gouhei Tanaka¹

E-mail: gtanaka@nitech.ac.jp

リザーバーコンピューティングは簡便で高速な機械学習を可能とする枠組みであり、時間方向の依存性をもつ時系列データのパターン認識に適している[1]。リザーバーによる情報変換は、**excitability** をもつさまざまな物理系の過渡応答を利用して実現することができ、各種物理系を基盤とした物理リザーバーコンピューティングの研究が著しく進展してきている[2]。特定の物理リザーバーコンピューティングデバイスの性能向上には、情報符号化・復号手法、信号の前処理・後処理手法、信号検出手法などの実装面での直接的な工夫が鍵となる[3]。

一方で将来の社会応用を念頭におくならば、数理モデル・アルゴリズム研究で見出された知見の導入や対象とする物理系の特性に好適な応用の考案なども必要となるだろう。本講演では、リザーバーコンピューティングの数理的研究における近年の発展を概観しつつ、複雑な時系列データの予測・分類・異常検知等の具体的な応用事例を紹介する[4,5,6]。これらを踏まえて、IoT 社会でのリザーバーコンピューティングの活用方法と課題について議論する。

- [1] 田中 剛平, 中根 了昌, 廣瀬 明, リザー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] G. Tanaka, T. Yamane, J. B. Heroux, R. Nakane, N. Kanazawa, S. Takeda, H. Numata, D. Nakano, and A. Hirose, Recent Advances in Physical Reservoir Computing: A Review, *Neural Networks*, vol. 115, pp. 100-123 (2019).
- [3] G. Tanaka and R. Nakane, Simulation platform for pattern recognition based on reservoir computing with memristor networks, *Scientific Reports*, vol. 12, 9868 (2022).
- [4] Z. Li, Y. Liu, and G. Tanaka, Multi-Reservoir Echo State Networks with Hodrick-Prescott Filter for Nonlinear Time-Series Prediction, *Applied Soft Computing*, vol. 135, 110021 (2023).
- [5] H. Tamura, K. Fujiwara, K. Aihara, and G. Tanaka, Mahalanobis distance of reservoir states for online time-series anomaly detection, *Authorea Preprints* (2023).
- [6] Z. Li, K. Fujiwara, and G. Tanaka, An Echo State Network-Based Method for Identity Recognition with Continuous Blood Pressure Data, *Proceedings of the International Conference on Artificial Neural Networks (ICANN)*, *Lecture Notes in Computer Science*, vol. 14257, pp.13-25 (2023).

謝辞: 本研究の一部は JSPS 科研費 (23K28154), ムーンショット型研究開発事業 (JPMJMS2021), JST-CREST (JPMJCR19K2), 東京大学社会連携部門「モビリティ知能社会デザイン」の助成を受けたものである。

社会応用が期待されるマテリアルリザーバー演算素子

Material Reservoir Computing Devices with Promising Social Application

九工大生命体工¹, 九工大 Neumorph センター² ○田中 啓文^{1,2}

Kyushu Institute of Technology¹, Hirofumi Tanaka¹

E-mail: tanaka@brain.kyutech.ac.jp

近年、ソフトウェアを使用した深層学習(DL)の計算能力の向上が目覚ましい。それに伴い、人工知能(AI)の実用化は急速に広がり、社会全体に発展的影響を与えている。しかしながら、電力消費量の大きさも問題になっており、高効率 AI 演算モデルが必要とされている。その一つとして注目されているリザーバー演算(RC, Fig.1(a))は学習時における人工ニューラルネットワーク中間層各層における重み更新が、リザーバー内では非線形ノードを導入することで固定化され、出力信号の線形和部分でのみ学習するため高効率になる。このリザーバー層が非線形ノードのランダムネットワーク(RNW)であることに注目し、ジャンクション部分が非線形性を示す導電性ナノマテリアルの RNW に置換したものをマテリアルリザーバーと呼ぶ。この場合、情報を電気信号として導入することによりリザーバーはアナログ素子として働き、出力信号が演算済みの状態で得られ、さらなる省エネルギー化が期待される。

我々は RNW 用マテリアルとして、原子スイッチにも使われる Ag_2S のナノワイヤ(NW)ネットワークのほか、 Ag_2Se -NW[1]、 Ag_2S ナノ粒子[2,3]、カーボンナノチューブネットワーク[4]などを用いた。他にもポリマー[5]など有機物やイオン伝導体を用いることもある。消費電力から換算すると 100TOPS/W 程度と考えられ、これは欧州のグループの提案デバイスの試算[6]とほぼ同じ値である。マテリアルリザーバーはノード数を圧倒的に大きく取れ、将来の性能向上により 1 デバイス当たりのノード数 10^8 - 10^9 程度に増加させることができると試算されており、拡張性が高い。当日はデータ拡張[7]、システム拡張[8]、インセンサ演算[9,10]などロボット応用など社会的貢献が期待される応用例も紹介する。

謝辞 本研究に対する JST ALCA-Next、JST CREST、JSPS 科研費などの研究資金援助や、マテリアルリザーバー研究に携わって頂いた全共同研究者、研究室のスタッフ・学生・OB・OG に感謝申しあげる。

参考文献 [1] T. Kotooka, H. Tanaka et al., *Nature Portfolio*, archive (2021). DOI: 10.21203/rs.3.rs-322405/v1. [2] Hadiyawardman, H. Tanaka et al., *Jpn. J. Appl. Phys.* 60, SCCF02 (2021). [3] T. T. Dang, H. Tanaka et al., *Appl. Phys. Lett.* 124, 091903 (2024). [4] D. Banerjee, H. Tanaka et al., *Adv. Intell. Syst.* 4, 2100145 (2022). [5] Y. Usami, H. Tanaka et al., *Adv. Mater.* 33, 2102688 (2021). [6] S. Bose et al., *Nat. Nanotechnol.* 10 1048 (2015). [7] T. Kotooka, H. Tanaka et al., *Appl. Phys. Express*, 16, 014002 (2023). [8] Y. Tanaka, H. Tanaka et al., *IEEE International Symposium on Circuits and Systems (ISCAS2023)*, 2056, (2023). [9] K. Kimizuka, H. Tanaka et al., *arXiv:2406.03958v1*. [10] 君塚、2024 年 3 月応用物理学会講演奨励賞受賞




Fig. 1 (a) Reservoir network. All nodes with nonlinearities are connected randomly. The computation of the intermediate layer is treated as a black box, so there is no need for training. Learning is performed only in the output layer. (b) Material reservoir using SWNT. Junction density was about $800/\mu\text{m}^2$. (c) Stepwise object binary classification using a single-walled carbon nanotube (SWNT)/porphyrin (Por-) POM reservoir device. Toyota's human-assist-robot (left) with a schematic of the arm connected to the gripper via force sensors collects tactile data from changes and the grasping force applied to the objects block and dog. Signal obtained by the sensor input to the SWNT (black line)/Por-POM (green circle) reservoir with recurrent connections (red arrow) (upper right) (d) Time-series inputs obtained from different objects (i.e., Hedgehog (HH), dog, bus, block) input separately. (e) One-hot vector coding was used for binary classification. The lines in the graph represent the respective target signals for HH, dog, bus, and block, respectively. Modified from original article [4].