

リザーバーコンピューティングの概念と最近の動向

Concept of Reservoir Computing and Its Recent Trends

田中剛平

Abstract

リザーバーコンピューティングは再帰的ニューラルネットワークの特殊なモデルを一般化した概念で、時系列情報処理に適した機械学習の枠組みの一つである。リザーバーコンピューティングの最大の特長は、入力信号をリザーバーで変換した後、読み出し部のみを簡便なアルゴリズムで訓練することで、極めて高速な学習を可能にする点である。近年、リザーバーコンピューティングの応用範囲は急速に広がり、また物理的リザーバーを利用した機械学習デバイスの開発も注目されている。本稿では、リザーバーコンピューティングの概要と最近の動向を紹介する。

キーワード：機械学習、ニューラルネットワーク、時系列、力学系、人工知能デバイス

1. はじめに

人工知能や機械学習による情報処理が欠かせない世の中になりつつある。これまで人手を掛けて判断を行ってきた業務を、データのみを用いて自動的に行おうという動きはビジネスの世界でも活発で、データの収集が成功の鍵になるとも言われている。こうしたトレンドを支える機械学習モデルの一つが、人工ニューラルネットワークである。その中でも、画像認識をはじめとする多様な応用で高い性能を発揮するディープラーニング（深層学習）が大きな注目を集めてきたが、これは階層的ニューラルネットワークを利用する。一方、再帰的ニューラルネットワークは、前の時刻のニューロンの状態が、他のニューロンにフィードバック入力されるような構造であり、時系列情報の機械学習に適している。リザーバーコンピューティングはその特殊なモデルを基礎として発展してきた概念である。

リザーバーコンピューティングは、近年様々な実データの時系列パターン認識に応用されてきている。その最大のメリットは、他の再帰的ニューラルネットワークモデルに比べて、学習が極めて高速であるという点である。

また、「作り込まない」物理的実装が可能であることから、新たな機械学習デバイスの開発につながると期待されている。そのため、リザーバーコンピューティングは、機械学習やニューラルネットワークのコミュニティだけではなく、エレクトロニクスを含む他の分野からも高い関心を集めている。

本稿では、リザーバーコンピューティングの成り立ちと概念を解説し、その応用例と最近の動向について紹介する。なお、詳しい内容については、リザーバーコンピューティングに関するレビュー論文^{(1),(2)}を参考にされたい。

2. リザーバーコンピューティングの概念

リザーバーコンピューティングの概念を説明するために、簡単な例を考えてみよう。リザーバー (Reservoir) という単語には、液体を入れておく容器やため池、という意味がある。文字どおり解釈すれば、液体やため池による計算、ということになる。水面に石を投げ込むとしよう。すると、波紋のパターンが広がる。このパターンは、入力である石の大きさや形によって変化するから、入力の情報を反映していると考えられる。では、複数の石を続けざまに投げ込むと、どうなるであろうか。図1に示すように、石が一つの場合よりも、はるかに複雑な波紋パターンが生み出されるであろう。このような波紋の動的パターンは、投げ込まれた複数の石の大きさや形、更にはそれらの投げ込まれる順番にも依存する。ま

田中剛平 東京大学大学院工学系研究科国際工学教育推進機構
E-mail gouhei@sat.t.u-tokyo.ac.jp
Gouhei TANAKA, Nonmember (Graduate School of Engineering, The University of Tokyo, Tokyo, 153-8505 Japan).
電子情報通信学会誌 Vol.102 No.2 pp.108-113 2019年2月
©電子情報通信学会 2019

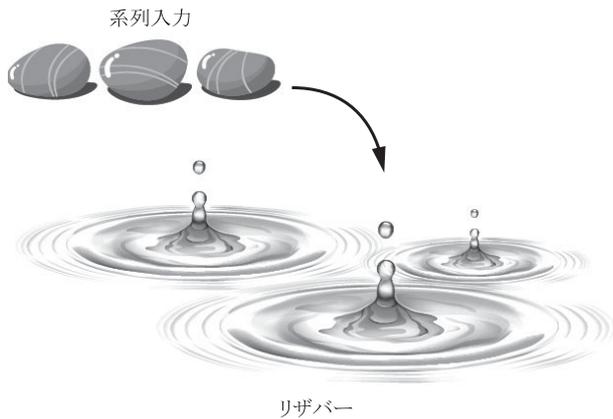


図1 リザーバーコンピューティングの概念

た、波紋同士の干渉も起こるから、入力の与え方に応じて、非常に多くの時空間パターンが生成される。つまり、リザーバーは、系列入力を波紋の時空間パターンに変換する装置とみなすことができる。

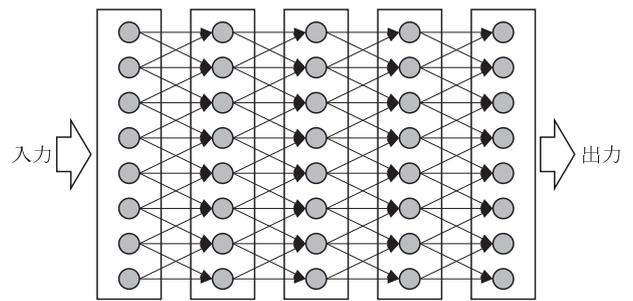
例えば、複数の系列入力があり、それらを定性的に二つのクラスに分類したいとする。ただし、系列入力を見ただけでは、分類することが難しいでしょう。このとき、それぞれの系列入力に対する波紋パターンを観察することにより、二つのクラスに分類することが容易になるならば、リザーバーによる情報変換が、系列パターンの分類に役立つことになる。このように、リザーバーコンピューティングの狙いは、リザーバーが生成する動的パターンから、簡便なアルゴリズムを用いて系列入力の識別を行うことである。リザーバーには、「大量の情報の蓄積」という意味もあり、ここでは過去の入力の情報を蓄積する（埋め込む）役割を果たしているもの、と考えることができる。

3. リザーバーコンピューティングの成り立ち

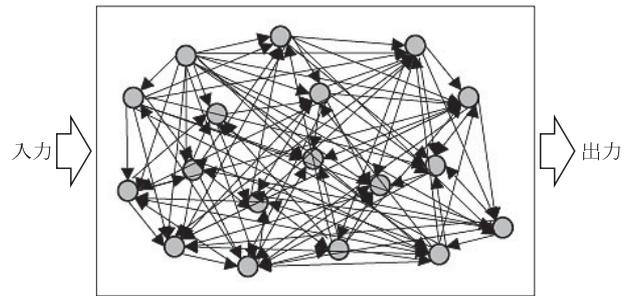
3.1 階層的及び再帰的ニューラルネットワーク

リザーバーコンピューティングは再帰的ニューラルネットワークに由来するので、その位置付けを明確にするために、まず階層的、再帰的ニューラルネットワークの違いについて述べておこう。

図2(a)に示すように、階層モデルは、互いに結合しないニューロン群の層を複数持つ。入力信号は、ニューロンの入出力関数によって変換されながら、出力側に向かって一方に伝えられる。誤差逆伝搬法等の学習アルゴリズムを使えば、サンプルデータから、入力と出力を関連付ける未知の関数を近似することができる。この階層構造には、過去の入力情報を記憶する仕組みがないから、各サンプルデータは独立に処理される。したがって、サンプルデータを異なる順番で与えたとしても、学



(a) 階層的ニューラルネットワーク



(b) 再帰的ニューラルネットワーク

図2 人工ニューラルネットワークの代表的な構造

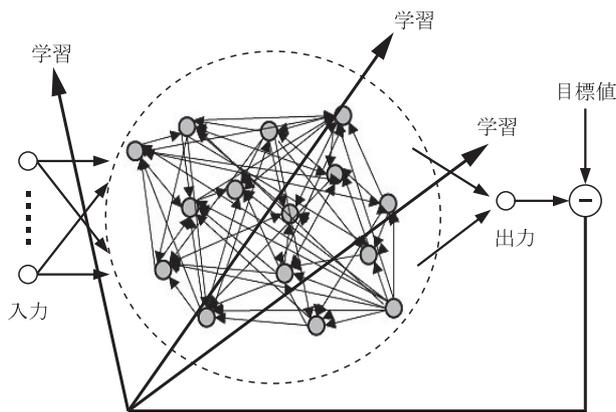
習の結果として構築されるモデルは同じになる。

これに対して再帰モデルは、図2(b)に示すように、フィードバック結合を有するニューロン群から成る。ここで、外部から時系列入力が与えられるとしよう。あるニューロンの状態は、現在の外部入力及び他のニューロンからのフィードバック入力に応じて決まる。フィードバック入力は他のニューロンの前の時刻の状態であり、これは過去の外部入力に依存するから、ニューロン状態は外部入力情報の履歴を反映している。すなわち、ニューロン群のダイナミックな活性パターンは、過去の外部入力の記憶を持つ。したがって、時系列入力の前後関係を考慮したパターン認識を行うことができる。このように、再帰的ネットワークは力学系を近似するのに適しており、時系列データの背後にある時間発展の法則を抽出するという目的に使える。この場合には、学習の結果として構築されるモデルは、データを与える順番に依存する。

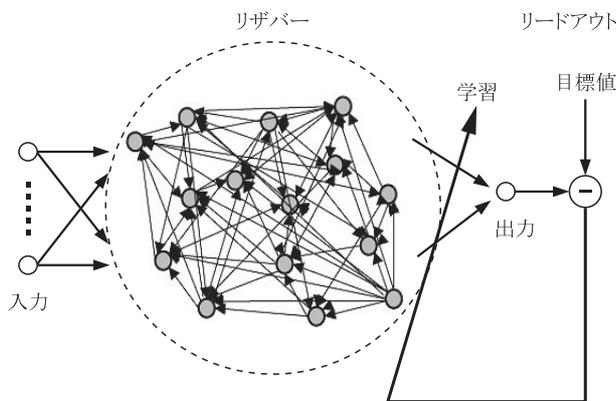
端的に言えば、階層的ニューラルネットワークは静的なデータ、再帰的ニューラルネットワークは動的なデータのパターン処理を行うのに適している。

3.2 リザーバーコンピューティング

1980年代に、一般的な再帰的ニューラルネットワークに対する学習アルゴリズムが提案された。代表的なものは、Backpropagation Through Time (BPTT)⁽³⁾ や Real-Time Recurrent Learning (RTRL)⁽⁴⁾である。図3



(a) 再帰的ニューラルネットワーク



(b) リザーバーコンピューティング

図3 時系列情報処理モデルの比較

(a)に示すように、ネットワークの出力と目標値の誤差を最小化するように、全ての結合荷重を勾配法によって修正していく。しかし、ネットワークサイズの増加とともに、前者は学習時間が、後者は結合荷重を記憶するためのメモリが、爆発的に増大してしまうという問題があった。また、勾配爆発・消失の問題が生じて、学習アルゴリズムの収束性が悪くなることも問題であった。そのため、計算機が現在ほど高性能でなかった時代には、実際的な応用が余り進まなかった。

その後、2000年代初めに、一部の結合荷重のみを学習するモデルが独立に提案された。Jaegerによって提案されたEcho State Network (ESN)^{(5),(6)}と、Maassらによって提案されたLiquid State Machine (LSM)^{(7),(8)}である。これらのモデルは、いずれも図3(b)に示すような構造を持つ。固定した再帰的ニューラルネットワークを学習によって調整せずに、リザーバーとして用いることから、これらのモデルは統一的にリザーバーコンピューティングと呼ばれるようになった⁽⁹⁾。

リザーバーコンピューティングモデルは、リザーバー部とリードアウト部から構成される。入力情報はリザーバーに

よって非線形変換され、高次元の特徴空間に写像される。出力は、リザーバーの動的状態の線形結合で与えられる。目標値と同じ出力が得られるように、この結合係数のみを線形回帰などの簡単なアルゴリズムを用いて学習する。入力を高次元空間に非線形変換で射影することにより、入力の線形分離を可能にするという考え方は、機械学習におけるカーネル法の発想と共通している。リザーバーコンピューティングの研究では、実質的にはESNまたはLSMのいずれかを用いていることが多いので、それぞれの特徴を述べよう。

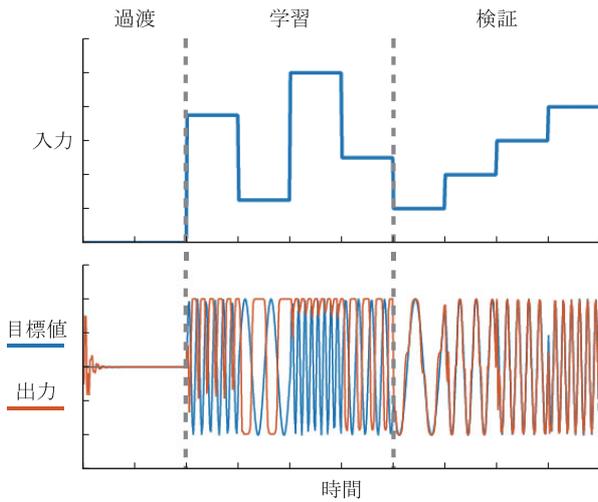
ESNでは、リザーバーは非線形活性化関数を持つ人工ニューロンの再帰的ネットワークによって構成される。ネットワークはスパースでランダムな構造をとる。ニューロン群の活動の中に、過去の入力情報を反響(Echo)させて、時系列入力のパターンを学習する。適切な学習を行うには、各時刻での入力の影響がリザーバー内で時間とともに徐々に消失していくことが必要である。このような性質を、Echo state property^{(5),(10)}と呼ぶ。高い計算性能を実現するには、再帰的ネットワークの結合重み行列のスペクトル半径を調整するなど、あらかじめ良いリザーバーを設計しておくことが必要であり、そのための設計指針^{(10),(11)}を考慮することが望ましい。

LSMでは、リザーバー(リキッドとも呼ぶ)はスパイクニューロンモデルの再帰的ネットワークによって構成される。スパイクニューロンモデルは、ニューロンのスパイク発火を忠実に再現する微分方程式モデルである。このモデルは、脳の皮質における時間依存情報のリアルタイム処理を動機として提案された。そのため、ESNよりも生物学的に妥当な仕組みを取り入れている。例えば、再帰的ネットワークの構造に関しては、空間的に近い位置のニューロンほど密な結合を持つという仮定を置くことが多い。LSMのリザーバーは、Fading memory^{(12),(13)}、すなわちリザーバーの出力は有限の過去の入力だけに依存するという性質を持つことが望ましいとされる。これは、ESNにおけるEcho state propertyに対応する性質である。

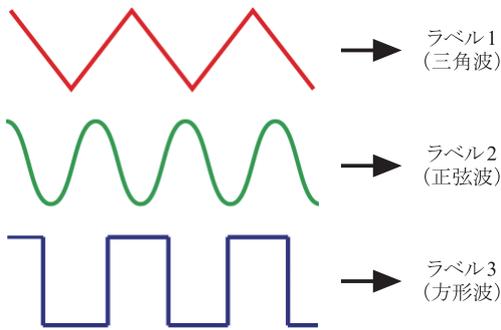
4. リザーバーコンピューティングの最近の動向

4.1 実問題への応用

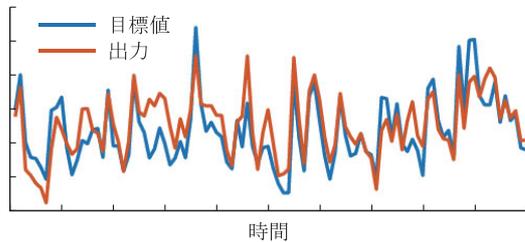
リザーバーコンピューティングは、他の再帰的ニューラルネットワークと同様に、様々な時系列データの学習に応用することができる。図4に、時系列パターン認識の代表的なタスクを例示した。図4(a)は、時系列生成タスクの例を示す。ここでは、入力と与えられる周波数を持つ正弦波を出力することである。学習期に四つの周波数を与え、対応する正弦波を出力するように学習すると、検証期において未知の周波数を入力しても対応する正弦波を正しく出力していること



(a) 時系列生成タスクの例



(b) 時系列分類タスクの例



(c) 時系列予測タスクの例

図4 時系列パターン認識

が分かる。図4(b)は、時系列分類タスクの例を示す。振幅が一定で周波数の異なる正弦波、三角波、方形波を多数生成し、一部を訓練データとして正しいラベルを出力するように学習する。すると、残りの検証データに対しても、正しいラベルを出力させることが可能となる。図4(c)は、時系列予測タスクの例を示す。時系列データの一部を訓練データとして使い、次の時刻の値を出力するように学習する。すると、残りの検証データに対しても予測をすることが可能となる。

表1は、リザーバーコンピューティングがこれまで応用されてきた対象を一覧にしたものである⁽²⁾。時系列データのパターン認識は広い分野で必要とされるものである

表1 リザーバーコンピューティングの応用例⁽²⁾

カテゴリー	対象
生物・医療	EEG, fMRI, ECG, EMG, 心拍, バイオマーカ, 眼球運動, マンモグラム, 肺画像
画像	手書き文字画像, 動画画像
音声	発話, 音響, 音楽, 鳥の鳴き声
機械	車両, ロボット, センサ, モータ, 圧縮器, 制御器, アクチュエータ
工業	発電所, 送電線, 再生可能エネルギー, エンジン, 燃料電池, バッテリー, ガスフロー, ディーゼル油, 炭鉱, 油圧掘削機, ボイラ, 穀物粉碎機, 歩道橋, エアコン
通信	電波, 電話, インターネット通信
環境	風力・風向, オゾン濃度, PM2.5, 廃水, 降雨, 地震
安全	暗号
経済・金融	株価, 株価指数, 為替
社会	言語, 文法, 構文, スマートフォン

から、応用範囲も多岐にわたることが分かる。ほとんどが時系列データを対象としたもので、多くの応用は、先に述べた時系列生成、時系列分類、時系列予測のいずれかに帰着される。画像は静的なデータであるから、画像認識への応用は意外に思われるかもしれない。しかし、画像データをセグメントに分割して、画素のピクセル値から成る一次元の系列データに変換すれば、リザーバーコンピューティングで扱うことができる^{(14), (15)}。セグメントに分割する際に、局所的な画素の相関を残しておけば、そのような相関を学習することが可能となるだろう。リザーバーコンピューティングの応用が急速に広まっているのは、学習に必要な計算が簡単で、機械学習の専門家でなくても手軽に利用できるためだと考えられる。また、リザーバーコンピューティングは高速な学習が可能であるので、センサ等で取得される時系列データのリアルタイム処理と相性が良い。

4.2 モデルの発展

リザーバーコンピューティングの性能は、入力の情報表現、入力のスケーリング、リザーバーの構造と大きさ、出力の情報表現、リードアウトの学習アルゴリズムなどに依存するが、これらの要素を最適に調整することは依然として簡単な問題ではない。タスクや扱うデータの種類が変わったとき、どのように調整し直せばよいかもまだ十分に明らかではない。そのため、従来のESNやLSMを基礎として、リザーバーコンピューティングモデルを改良・発展させる研究も盛んに行われてきた。新しいモデルは、①複数のリザーバーや適応的に変化するリザーバーなど新しい構造を用いるモデル、②リザーバーコンピューティングと深層学習や強化学習を組み合わせたハイブリッドモデル、③リードアウトの学習アルゴリズムを工

夫したモデル，④リザーバーの構成要素を別の要素に置き換えたモデル，などに分類することができる。また，理論面においても，非線形力学系理論，情報理論，統計理論などを用いて，リザーバーのダイナミクスと全体の計算性能の間の関係を明らかにしようとする研究が活発に行われている。

4.3 物理的実装

リザーバーコンピューティングの物理的実装の研究も多くの注目を集めている。2.で説明したように，リザーバーの役割は，入力を非線形変換により高次元の特徴空間に射影することであるから，必ずしも再帰的ニューラルネットワークを用いる必要はない。他の非線形システムや物理系を用いてもよい。非線形性を確認するには，リザーバーのダイナミクスを記述する数理モデルを作って，線形システムではない（重ね合わせの原理が成り立たない）ことを確認すればよい。数理モデルを導出するのが困難な場合は，線形分離不可能な XOR（排他的論理和）問題などを解くことで非線形性を例証することができる。また，2.2で述べたように，リザーバーは Fading memory (Echo state property) を持つことで高い計算能力を発揮すると経験的に言われている。入力的情報をどれくらいの期間リザーバー内に記憶できるかは，記憶容量 (Memory capacity) を調べることで分かる⁽¹⁶⁾。また，入力の情報を有限の時間だけ記憶するためには，(入力なしの) リザーバーのダイナミクスがカオス的であっても，余りに速く平衡点に収束する漸近挙動であっても困る。したがって，リザーバーの制御パラメータをカオスの縁 (Edge of chaos) に設定することがよいとされる⁽¹⁷⁾。

表2に，これまでに提案されている物理的リザーバーの分類を示す⁽²⁾。リザーバーをハードウェアで実装することにより，計算機上のシミュレーションよりも，高速な演算が可能になると期待される。特に，電気・電子系，光学系，スピン系を用いたリザーバーは，低消費電力で動作する，高速オンライン機械学習デバイスを実現するのに

表2 物理的リザーバーの分類⁽²⁾

カテゴリ	例
力学系モデル	遅延力学系，セルオートマトン，結合振動子系
電気・電子系	ASIC, FPGA, VLSI, アナログ回路，神経模倣回路，メモリスト回路
光学系	半導体光増幅器，光電子系，レーザキャビティ，光導波路
スピン系	スピントルク振動子，スピン波，スキルミオン
機械系	ばね質点系，テンセグリティロボット，ソフトロボット
生物系	脳部位，培養細胞
その他	ナノスケール材料，量子系

有望である。リザーバーを訓練するための仕組みが必要ないので，他の学習モデルよりも実装が容易で，物理現象をそのまま活用することが可能である。また，リザーバーの構成要素を必ずしも均一に作製しなくてもよく，ナノスケールの微細回路素子の製造ばらつきを利用して性能向上を図る試みも検討されている^{(18), (19)}。本小特集では，幾つかの物理的リザーバーの具体例を扱っているので，そちらも参照して頂きたい。

5. おわりに

本稿では，リザーバーコンピューティングの概念と成り立ちを説明し，最近の研究動向を紹介した。人工知能方面においては，リザーバーコンピューティングは，時系列パターン処理を行うのに大変便利な枠組みであり，今後ますます実用化に向けた発展とハードウェアデバイスの開発が見込まれる。他方で，脳科学においても，文脈に依存した脳の情報処理原理はまだ十分明らかになっておらず，リザーバーコンピューティングの研究を通じて，その理解が進む可能性もある。リザーバーコンピューティングが，新たな情報処理の枠組みとして，電子情報通信分野を含む多くの分野に寄与することを期待する。

謝辞 本稿の一部は JSPS 科研費 16K00326 の助成を受けたものです。

文 献

- (1) M. Lukoševičius and H. Jaeger, "Reservoir computing approaches to recurrent neural network training," *Computer Science Review*, vol. 3, no. 3, pp. 127-149, 2009.
- (2) G. Tanaka, T. Yamane, B.J. Héroux, R. Nakane, N. Kanazawa, S. Takeda, H. Numata, D. Nakano, and A. Hirose, "Recent advances in physical reservoir computing: A review," arXiv: 1808.04962, 2018.
- (3) P.J. Werbos, "Backpropagation through time: what it does and how to do it," *Proc. IEEE*, vol. 78, no. 10, pp. 1550-1560, 1990.
- (4) R.J. Williams and D. Zipser, "A learning algorithm for continually running fully recurrent neural networks," *Neural Comput.*, vol. 1, no. 2, pp. 270-280, 1989.
- (5) H. Jaeger, "The "echo state" approach to analyzing and training recurrent neural networks-with an erratum note," GMD Technical Report 148, German National Research Center for Information Technology, 2001.
- (6) H. Jaeger and H. Haas, "Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless communication," *Science*, vol. 304, no. 5667, pp. 78-80, 2004.
- (7) W. Maass, T. Natschläger, and H. Markram "Real-time computing without stable states: A new framework for neural computation based on perturbations," *Neural Comput.*, vol. 14, no. 11, pp. 2531-2560, 2002.
- (8) W. Maass, "Liquid state machines: motivation, theory, and applications," *Neural Computation, Computability in context: computation and logic in the real world*, pp. 275-296, World Scientific, 2011.
- (9) B. Schrauwen, D. Verstraeten, and J.V. Campenhout, "An overview of reservoir computing: theory, applications and implementations," *Proc. the 15th European Symposium on Artificial Neural Networks*, pp. 471-482, 2007.
- (10) I.B. Yildiz, H. Jaeger, and S.J. Kiebel, "Re-visiting the echo state property," *Neural Netw.*, vol. 35, pp. 1-9, Nov. 2012.
- (11) M. Lukoševičius, "A practical guide to applying echo state networks,"

- Neural Networks : Tricks of the trade, pp. 659-686, Springer, 2012.
- (12) W. Maass, T. Natschläger, and H. Markram, "Fading memory and kernel properties of generic cortical microcircuit models," *Journal of Physiology-Paris*, vol. 98, no. 4-6, pp. 315-330, 2004.
- (13) S. Boyd and L.O. Chua, "Fading memory and the problem of approximating nonlinear operators with Volterra series," *IEEE Trans. Circuits Syst.*, vol. 32, no. 11, pp. 1150-1161, 1985.
- (14) A. Jalalvand, W. De Neve, R. Van de Walle, and J-P. Martens, "Towards using reservoir computing networks for noise-robust image recognition," *Proc. the 2016 International Joint Conference on Neural Networks*, pp. 1666-1672, 2016.
- (15) Z. Tong and G. Tanaka, "Reservoir computing with untrained convolutional neural networks for image recognition," *Proc. the 2018 International Conference on Pattern Recognition*, pp. 1289-1294, 2018.
- (16) H. Jaeger, "Tutorial on training recurrent neural networks, covering BPTT, RTRL, EKF and the echo state network approach," *GMD Report 159, Fraunhofer Institute AIS*, 2002.
- (17) T. Natschläger, N. Bertschinger, and R. Legenstein, "At the edge of chaos : Real-time computations and self-organized criticality in recurrent neural networks," *Proc. NIPS*, pp. 145-152, 2004.
- (18) G. Tanaka, R. Nakane, T. Yamane, D. Nakano, S. Takeda, S. Nakagawa, and A. Hirose, "Exploiting heterogeneous units for reservoir computing with simple architecture," *Proc. International Conference on Neural Information Processing*, pp. 187-194, Springer International Publishing, 2016.
- (19) G. Tanaka, R. Nakane, T. Yamane, S. Takeda, D. Nakano, S. Nakagawa, and A. Hirose, "Waveform classification by memristive reservoir computing," *Proc. International Conference on Neural Information Processing*, pp. 457-465, Springer International Publishing, 2017.

(平成 30 年 8 月 27 日受付 平成 30 年 10 月 31 日最終受付)



たなか こうへい
田中 剛平

2000 東大・工・計数卒。2005 同大学院新領域創成科学研究科博士課程了。2013 から東大大学院工学系研究科特任准教授。複雑系動力学や省エネルギー情報処理の研究に従事。2016 IEEE Trans. Nanotech. Best Paper Award, 2017 応用数理学会業績賞など各受賞。

