

知っておきたいキーワード

リザーバーコンピューティング

田中剛平†

† 東京大学大学院工学系研究科

"Reservoir Computing" by Gouhei Tanaka (Graduate School of Engineering, The University of Tokyo, Tokyo)

キーワード：機械学習、時系列データ、ニューラルネットワーク、人工知能、情報処理デバイス

まえがき

近年、人工知能はさまざまな分野の産業やサービスに取り入れられつつあります。人工知能を実現するために中心的な役割を果たすのが機械学習と呼ばれる技術です。機械学習技術は、

データに潜むパターンやルールを学習アルゴリズムに基づいて機械的に抽出することを目的とします。機械学習によって獲得されたパターンやルールは推論に用いられ、予測や分類などの知的情報処理に役立てられます。リザーバーコンピューティングは、学習の高

速性と簡便性を特長とする機械学習の枠組みです。時系列パターン認識への応用が期待されるとともに、エネルギー効率の高い機械学習デバイスを実現するための基礎技術としても注目されています¹⁾。

新しい機械学習手法の必要性

機械学習モデルの一つに、脳の仕組みを模倣した人工ニューラルネットワークがあります。近年では、データ量の充実と計算機の発達のおかげで、深層ニューラルネットワークやリカレントニューラルネットワーク(図1)を用いる深層学習(ディープラーニング)技術が実用的な手段となり成功を取っています。しかし、深層学習を行うには多くの時間と計算リソースが必要となることも珍しくありません。技術者が深層学習を使うには、① 深層学習のアルゴリズムを理解し、② 深層学習が可能となる十分な量のデータを取得し、③ 高性能な(例えばGPUを備えた)コンピュータを準備し、④ 長時間の学習計算と結果の検証を繰り返しながらモデルのハイパーパラメータを

調整する、などのハードルをクリアする必要があります。そうした技術者の負担を軽減する手法の一つとして、リザーバーコンピューティングへの関心が高まってきています。リザーバーコンピューティングでは線形回帰などの基礎的な学習アルゴリズムを用いるの

で、その理解は容易で、通常のコンピュータを使って高速な学習計算を行うことができます。高速学習という特長は、環境に応じてハイパーパラメータを頻繁に調整し直す必要がある場合や、時系列データをリアルタイムで機械学習処理する場合に特に有用です。

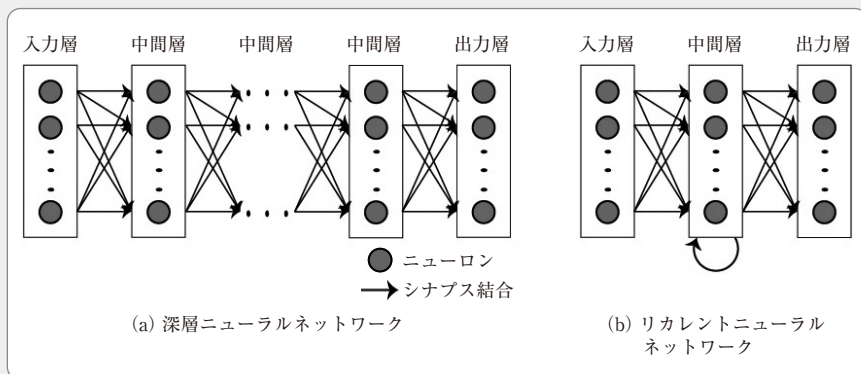


図1 深層学習を適用するニューラルネットワーク

リザーコンピューティングとは

リザーコンピューティングは、いくつかの特殊なリカレントニューラルネットワークモデル²⁾³⁾から派生した計算の枠組みで、主に時系列データの機械学習に利用されます。典型的なリザーコンピューティングモデルは、入力層、リザー、出力層から構成されます(図2)。入力層は時系列データを受け取って適当な重み付けを行い、リザーへ情報を送ります。リザーは、スパースでランダムな結合をもつリカレントニューラルネットワークで与えられ、入力層からの情報を高次元時系列データに非線形変換します。時系列入力データの時間方向の関係性(依存性)を考慮するために、リザーは過去の入力情報を蓄積して記憶する役割を持ちます。リードアウトで

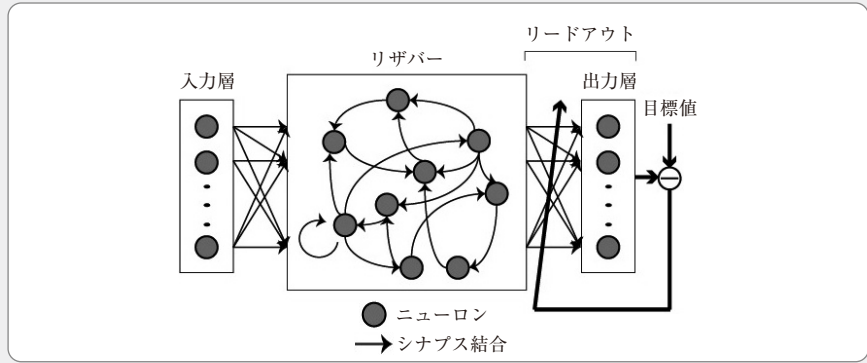


図2 リザーコンピューティングモデル

は、その高次元時系列データを用いて、線形回帰などの簡便な学習アルゴリズムにより回帰や分類などのパターン解析を行います。リザーコンピューティングモデルの特徴は、リザーと出力層の間の結合重みだけを学習アルゴリズムで決定し、入力層とリザーの間の結合重みとリザー内のフィー

ドバック結合重みはあらかじめ固定しておく点です。この工夫によって、すべての結合重みを学習する一般のリカレントニューラルネットワークに比べて高速な学習が可能となるのです。ただし、高い計算性能を実現するには、あらかじめ固定する結合重みの値を適切に設定しておく必要があります⁴⁾。

時系列パターン認識

リザーコンピューティングでは時系列データを扱います。時系列データは、センサや計測器を通じて時々刻々と変化する一連の値として取得されます。こうした時系列データに対する主な機械学習タスクには、時系列生成、時系列分類、時系列予測などがあります。図3(a)は時系列生成タスクの例です。入力は一連の定数値が時間とともに切り替わる時系列データで、出力は入

力値を周波数とするような正弦波です。学習したモデルは、正弦波発生器(ファンクションジェネレータの一種)として動作します。このようなタスクは、例えばロボットの動的パターン生成などに応用されます。図3(b)は時系列分類タスクの例です。入力は正弦波または三角波の時系列データで、出力は正弦波または三角波に対応するラベルです。学習したモデルは時系列入力の定性的な違いを判別することができます。このようなタスクは、

例えば、音声信号から発話者や発話内容を推定する音声認識などに応用されます。図3(c)は時系列予測タスクの例です。入力は乱数の時系列データで、出力は入力のある非線形システムによって非線形変換した時系列データです。学習したモデルは上記の非線形システムを近似するので、時系列データの将来を予測することができます。このようなタスクは、例えば、気象予測や経済予測などに応用されます。




図3 代表的な時系列パターン認識

物理リザーバーコンピューティング

リザーバーコンピューティングモデルは、従来のリカレントニューラルネットワークに比べて学習時に変更する要素が少ないので、ハードウェア実装が比較的容易であると考えられます。また近年、リザーバーの非線形変換機能を物理現象によって実現する物理リザーバーコンピューティングも注目されています⁵⁾。電子、光、スピン、流体、機械、ナノ粒子、培養細胞などさまざ

まな媒質・基質を利用する物理リザーバーが提案されています。また、実装を効率化するため、リザーバーの新しい実装方式も提案されています。例えば図4(a)は、遅延フィードバックをもつ単一非線形ノードを利用するリザーバーを示しています。一つの非線形ノードにより入力の変換を行い、遅延ループ上の仮想ノード状態の観測により高次元時系列信号を生成します。図4(b)は、波動現象を利用するリザーバーを示しています。波の非線形干渉により非線形変換を行い、空間

内の複数箇所における状態観測により高次元時系列信号を生成します。いずれもネットワークタイプのリザーバーと比べて多くの配線の実装を必要としないというメリットがあります。こうした物理リザーバーコンピューティングシステムは、高効率機械学習デバイスを実現するための基盤として有望であり、また自然現象を計算資源として活用した自然計算(ナチュラールコンピューティング)の発展にもつながると考えられます。




図4 物理リザーバーコンピューティング

むすび

本稿では、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を紹介しました。現在、本手法の計算能

力の数学的解析、発展的モデルの構築、実世界の課題への応用、実際の脳の文脈依存的情報処理との関係についての議論、などが精力的に行われています。物理実装の面では、理論家と実験家が

協力することで大きな飛躍が見られるのではないかと期待されます。時系列パターン認識を行う際には、本手法を一度試してみたいはかがでしょうか。

(2020年1月27日受付)

参考文献

- 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 (仮)", 森北出版, 2020年発行予定
- 2) H. Jaeger: "The "echo state" approach to analysing and training recurrent neural networks-with an erratum note", GMD Technical Report, 148, 34 (2001)
- 3) W. Maass, T. Natschläger and H. Markram: "Real-time computing without stable states: a new framework for neural computation based on perturbations", Neural Computation, 14, 11, pp.2531-2560 (2002)
- 4) M. Lukoševičius and H. Jaeger: "Reservoir computing approaches to recurrent neural network training", Computer Science Review, 3, 3, pp.127-149 (2009)
- 5) Tanaka, et al: "Recent advances in physical reservoir computing: a review", Neural Networks, 115, pp.100-123 (2019)



たなか ごうへい
田中 剛平

2005年、東京大学大学院新領域創成科学研究科博士課程修了。東京大学生産技術研究所助教、特任准教授などを経て、現職。複雑系科学、数理工学、脳型コンピューティングなどの研究に従事。博士(科学)。