

# 論文の内容の要旨

## Self-supervised learning models for temporal feature analysis

(時系列情報の特徴検出のための自己教師あり学習モデル)

朝吹 俊丈

時系列の学習は、運動時系列や言語の獲得などにおいて極めて重要な役割を担っている。脳にはこうした時系列を学習する機能が備わっており、それにより我々は高次の認知活動を行うことが出来る。我々が複雑な時系列を学習できるのは、外界の規則的な短い時系列を、一つのまとまり(チャンク)として学習・認識する機能が脳に備わっているためであると考えられる。

時系列中のチャンクの学習は、主に大脳基底核において行われていると考えられているが、その神経学習原理は明らかになっていない。チャンクの学習メカニズムを明らかにすることは、脳による時系列情報の階層的処理の仕組みを理解することに不可欠であり、本研究では時系列中のチャンクを教師なしで学習する学習モデルを提案することでこの仕組みに迫った。

第一の研究では、脳が運動時系列を生成する際の神経表現について調べた。我々が手を動かす、などといった運動を行う際、その準備、開始、実行の各段階において運動野が指令を送っている。実際、マウスを用いたレバー運動の実験では、運動野の各層において、運動時系列の各段階で選択的に活動が上昇する細胞が見つかった。運動野は脳の複数の部位から入力を受け取っており、そこに含まれた情報を元にして運動を指令するための神経活動を生成していると考えられる。しかし、運動野が受け取る入力が神経活動に如何に関与しているかは明らかになっていない。そこで、ここではシナプス入力の総和を反映していると考えられている LFP (Local Field Potential) に独立成分分析 (Independent Component Analysis; ICA) を適用することで分離された、4つの独立な信号をリカレントネットワークモデルへの入力として用いて運動時系列の学習を行った。出力素子への教師信号には、マウスが行なった前肢運動におけるレバーの位置情報を用いた。この条件のもと、出力素子へのシナプス荷重を学習した。学習後のリカレント回路には、レバーを保持している期間に高い(低い)活動を示す Hold-related (Movement-off) 細胞や、レバーを引いた時に活動する Movement-relate 細胞、さらにレバーを引く直前に活動する Pre-movement 細胞などに似た活動

を示すものなど、実験により観測されているものと非常に良く似た挙動を示す素子が出現した。この結果から、リカレントネットワークを用いて脳における時系列表現を探ることの妥当性が確かめられた。

以上において説明した枠組みでは、モデルに望ましい出力を教師信号として与える必要があり、時系列からの非自明な特徴を抽出するためには、外部からの教師信号を必要としない枠組みを考える必要がある。そこで、第二の研究では、二つの独立したリカレントネットワークを用いたチャンクの教師なし学習法を提案した（図1左）。刺激に用いる時系列は複数の要素から成り、入力層はこれらの要素に対応する神経細胞から構成されている。ここでは、時系列に含まれる要素を  $a, b, c, \dots$  などとし、それぞれ一定の時間提示されるとした。なお、各要素の提示は時間的に重複しない。時系列中には規則的な短いチャンクが頻繁に出現し、二つの回路は同一の時系列入力を受けるものとする。本モデルでは、それぞれの回路に対する教師信号を、互いの出力を用いて生成する。本モデルでは教師信号がモデル自体から生成されるため、教師なしの枠組みで学習が行われる。このもとで互いの出力間の誤差が十分小さくなるまで学習を行うと、学習前では出力はチャンクと無関係であるものの（図1右上）、学習後ではチャンクの末尾に鋭く応答するようになった（図1右下）。

本モデルで各回路の出力数を増やし、複数のチャンクが繰り返し出現する時系列を入力として提案モデルを学習すると、各出力は各チャンクに選択的に応答するようになった。提案モデルはチャンク間に重なりがある場合などの複雑な状況でもチャンクの検出を行うことが可能であることを示した。さらに、提案モデルはチャンク間に共通する時系列が含まれている場合や、従来の手法では検出が困難であった時間的コミュニティ構造を持つ時系列の学習にも適用可能であることが明らかとなった。さらに、モデルは神経回路のダイナミクスに程よい強度のノイズ成分が含まれており、二つの回路が十分独立している際に学習性能が最大になることがわかった。

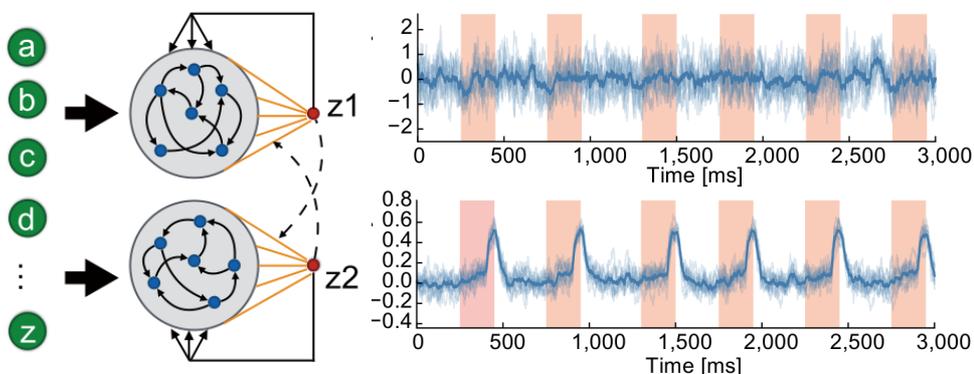


図1 チャンクの教師なし学習モデルとその出力の応答

上で説明したモデルは、独立した回路が必要であることと、時系列中のチャンクの数  
 が既知でないと学習できないなどの短所がある。そこで、樹状突起を考慮すること  
 で、単一のニューロンにより時系列の特徴を教師なしで抽出する手法を提案した。本  
 モデルにおけるニューロンは、細胞体と樹状突起の二つのコンポーネントからなる(図  
 2)。樹状突起はポアソンスパイク列を入力として受け取り、細胞体の膜電位は樹状突  
 起に依存する。細胞体の発火率は、その膜電位に非線形関数  $\phi^{\text{som}}$  を施したもので与  
 えられ、この非線形関数は過去の出力の一次および二次のモーメントにより時事刻々  
 と変化することで、活動を一定の範囲に留める。本モデルでの学習は、樹状突起の活  
 動が細胞体の活動を予測するような方向にシナプス荷重を変化させる。

本モデルにおいて行う学習タスクとして、まずはじめにランダムなポアソンスパ  
 イク列の中に3つのパターンが繰り返し出現するような入力考えた。このスパイク列  
 を樹状突起に入力し、シナプス荷重の学習を行った。学習前期では細胞体と樹状突起  
 の活動は大きく異なっており、細胞体の出力は提示されたパターンとは関係が認めら  
 れなかった。一方学習後期では、二つのコンパートメントの活動は十分近くなってお  
 り、さらにそれらは特定のパターンが出現した時にのみ高い値をとるようになった。  
 本モデルで第二の研究で行った時系列チャンクと時間的コミュニティ構造を持つ時系  
 列を入力して学習すると、やはり各特徴に応じた活動が生成された。

さらに、本モデルを複数用いて互いに即抑制がかかったネットワークモデルを構築  
 し、複数の信号の分離を行えることを示した。複数の未知の信号が混合された状態か  
 ら元の信号へ分離することはブラインド信号源分離と呼ばれており、工学的にも極め  
 て重要な技術である。ここでは、二つの楽器(バソン、クラリネット)の波形を線型に  
 混合し、得られた混合信号を元に入力スパイクを生成した。この入力を用いて二つ  
 の出力からなる提案モデルを学習した結果、各出力は二つの楽器のいずれかに対応する  
 真の波形を生成するようになった。

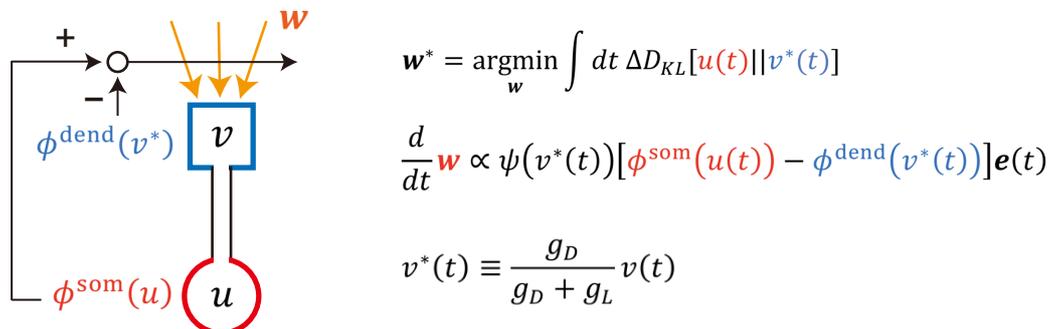


図2 時系列中の特徴検出を行うための2コンパートメントニューロンモデル

次に、提案モデルおよび既存の信号分離アルゴリズムのパフォーマンスの比較を行った。既存のものとしては、独立成分分析を行う手法のうちの一つを選んだ。一つ目は、信号の非ガウス性を高めるように学習する FastICA で、二つ目は SOBI (second order blind identification) である。SOBI では、片方の信号に時間的なずれを導入し、複数のズレを与えた全ての組み合わせにおいて相関を最小化するように学習を行う。FastICA が信号の時間的情報を一切含まないのに対し、SOBI ではそれを考慮している点が大きな違いである。比較においては、二つの楽器が異なる曲を演奏している場合 (信号が独立) と、同一の曲を演奏している場合 (信号は独立とは限らない) で行った。結果として、信号が独立な場合では、提案手法を含めた三つの手法は、いずれも高い学習パフォーマンスを示した。一方、非独立な場合には、FastICA のパフォーマンスは残りの二つの手法に比べて著しく低い値になった。

本論文では、時系列中のチャンクを教師なしで学習する神経回路モデルを提案した。ここで提案したモデルは、モデル自身の出力を教師信号として用いて学習を行うものであり、これは予測符号化やベイズ推定で行われているような、入力信号自体を予測する手法や、力学系のサドルコネクションに着目してチャンクを埋め込む手法とは大きく異なる。本研究で提案したモデルは、従来のチャンク学習モデルでは解決できなかった時系列のコミュニティ構造の検出や、非独立な信号の分離なども可能であり、時系列学習に新たな視点を与えた。