

## 論文題目 高次視覚野の部品表現と位相的組織化を実現する学習モデルの提案

氏 名 細田 謙二

脳の特筆すべき機能の一つは、ものを見る能力である。顔やコップなど、多様な物体を様々な状況で冗長に認識することは現在のコンピュータでも真似できない。このような物体認知は、脳の中では腹側経路と呼ばれる階層的な視覚システムを通して行われる。この経路は幾つかの連続する皮質領野からなり、段階的により複雑でより冗長な物体特徴を視覚入力から抽出する。物体のエッジ抽出から始まり、曲率、T字特徴などを経て、さらに高次の物体特徴、例えば顔の特徴など、が抽出される。また、この経路を経るにつれ、ニューロンの刺激応答は、位置、大きさ、角度などの物体変化に対してよりロバストになる。

腹側経路の物体表現は、とりわけ、次の2つの特性を有している。一つは部品的な物体表現である。個々のニューロンは、物体そのものをコードするのではなく、また、フーリエ分解のように完全に分散的にコードするのでもなく、冗長な部品的な物体特徴をコードする。例えば、この経路の最終段階に位置するinferior temporal cortex (IT野) の集団的活動の計測から、物体呈示によって皮質上の複数の活動パッチが出現し、個々の活動パッチがその物体の部分的特徴をそれぞれ表していることが示されている。

もう一つは連続する物体特徴が皮質空間上連続的にコードされるという位相的組織化である。この組織化では、似た刺激選択性をもつニューロン同士が皮質上近接する。さらに、皮質の接線方向に対する刺激選択性の変化が、特定の連続的な物体変化と連動する。この考えは、IT野の集団的活動の計測から、物体呈示によって励起された個々の活動パッチの皮質上の位置が物体の系統的な変形に伴って連続的に変化することから提唱されている。これまでに、これら2つの表現特性に関して様々な理論的考察がなされてきたが、まだその内部メカニズムは明らかになっていない。

従来、皮質の位相的組織化を説明する学習モデルとして、Self-organizing Maps (SOM)法[3]が用いられてきた。SOMは、高次元の個々の入力を低次元マップ上の個々の点に、なるべく似た入力同士がマップ上近接するように写像する。特に、一つの入力を連続的に変化させると、その代表点も連続的に変化するという位相保存性を持つ。この手法によって脳の位相的組織化の様々な側面が説明されてきた。しかし、SOMの代表点は入力そのものを表しており、脳の部品表現は説明できない。

本研究では、上述の部品表現と位相的組織化を同時に実現する学習モデルを提案する。このモデルは、non-negative matrix factorization (NMF)という基底分解手法に位相保存性を持たせるように発展させたものである。一般に、基底分解手法は入力データを複数の基底の重み付け組

み合わせで再現するような基底および組み合わせ係数を導く。代表的な基底分解手法である Principal Component Analysis (PCA) は、このデータ再現を最大限に追い求め、完全に分散的な表現を導く。別の代表的な基底分解手法である Vector quantization (VQ) は、入力をどれか一つの基底によってのみ表現するという制約を課し、入力をクラスわけする。PCA では基底と係数が、VQ では基底が正負いずれの値もとりにうることができる一方、NMF は、このデータ再現において、基底および組み合わせ係数の全要素が非負であるという制約を課す。非負制約があるために、基底同士の打ち消しあいがないという特徴を持つ。NMF は特に、回数や割合のような非負のデータに対し、直感的に分かりやすい部分的な表現を導くことが示されている。さらに、NMF の非負制約は、脳の情報コーディングと関連がある。脳における情報の運び手は神経細胞の発火率で、それは非負であるからである。さらに、神経細胞の結合重みは、興奮性結合と抑制性結合のどちらかで、学習はそれぞれで符号が変わらずに起こるからである。非負制約の学習は脳の中で自然に実装されると考えられる。

提案モデル (Topographic NMF: TNMF) への拡張は、NMF の基底間に外的な近傍結合関数を設けることで行われる。非負制約があるために近傍関数の位相構造に従って基底が重なり合うようになる。ここで、非負制約は部品表現だけでなく位相的組織化においても重要である。この拡張によって、NMF 由来の部品表現とともに、入力の連続的変化を捉えるような位相的組織化が実現される。SOM では一つの入力はマップ上の一点で表されるが、TNMF では一つの入力は複数の点 (活動ピーク) で表される。このとき、個々の点は入力の部分的特徴を表し、その部分的特徴が連続的変化するとマップ上を連続的に移動する。SOM は VQ の位相的拡張版といえるが、TNMF は NMF の位相的拡張版といえる。

本論文では、TNMF を腹側経路の学習モデルとして捉え、TNMF の特性を明らかにした。具体的には、腹側経路の初期段階を模倣した階層モデルを組み入れ、その最終層の出力を TNMF モデルへの入力とした。この階層モデルは、応答の選択性を高める処理と不変性を高める処理を交互に行う。具体的には、S 層と C 層と呼ばれるものが交互になって構築され、S 層ではパターンマッチング的に特徴検出が行われ応答選択性が高められ、C 層では S 層の応答が OR 回路的に統合され応答不変性が高められる。一つの学習層からなる基底分解モデルでは応答の選択的と冗長性はトレードオフの関係にあるが、このような多層構造によってそのようなトレードオフ問題が解消される。ここでは実際に、階層モデルが TNMF の学習によって高次視覚野で見られたような部品表現と位相的組織化を獲得したことを定性的に示した。

次に、階層モデルおよび TNMF 学習の生理学的妥当性を検討するため、多数の視覚刺激に対する応答に関して、階層モデルと実際のサルの IT 野ニューロンとの比較を行った。ただし、本論文では、簡略化のため、集団応答の正の応答構造にのみ着目し、切り捨てた抑制応答の情報表現は取り扱わなかった。具体的には、ニューロン応答は刺激呈示期間中の発火率から、自発発火率で引いたものとし、負の値をとった場合にはゼロとした。ここで、全刺激に対する全てのニューロンの正の応答の分散と負の応答のそれはそれぞれ 22.2 と 3.5 であり、ニューロン応答の大部分の情報 は正の応答にあったといえる。

比較ではまず、各ITニューロンに対し、最もよく似た刺激選択性を持つモデルニューロンを各モデル層からそれぞれ選び出した。そして、幾つかのITニューロンの刺激選択性はモデルニューロンのそれによってかなりの程度説明できることを示した。次に、モデルニューロンのITニューロンに対する応答の再現性のよさをモデル層のレベルで定量的に評価した。ここでは確率的な指標を導入した。そして、単一ニューロンレベルのIT野の選択性の再現において、構築した階層モデル、そしてTNMF学習の生理学的妥当性を示した。

また最後に、TNMF を脳の学習モデルとして提案するだけでなく、データマイニング手法として提案した。まず、TNMF を IT 野のニューロンデータに適用し、ニューロンの集団コーディングの様子を可視化したマップが得られた。その表現は過去の様々な IT 野の知見と整合性がとれていた。次に、TNMF を Web コンテンツに対しユーザー集団が付与したタグ回数のデータに適用し、より効果的に集合知を俯瞰して見渡せる地図が得られた。特に、関連のあるコンテンツ同士が近くに配置されるとともに、複合的な意味を持つコンテンツは複数の点で表され、従来のマッピング方法よりもより豊かな情報を捉えることができた。

結論として、本研究では、腹側視覚経路に見られる部品表現と位相的組織化という表現特性を統一的に説明する学習モデルとして、TNMF を提案した。そして、視覚システムを構築し、生理学データと比較することによって、TNMF 学習の生理学的妥当性を示した。さらに、TNMF をデータマイニング手法として提案し、その応用可能性を示した。