

脳活動の時空間パターンに基づく深層学習デコーディングによって明らかにされた視覚情報処理: fMRIとEEGの同時計測による研究

1235072 古谷玲 【 認知神経科学研究室 】

Visual Information Processing Revealed by Deep Neural Decoding Based on Spatiotemporal Patterns of Brain Activity: A Concurrent fMRI and EEG Study

1235072 Rei Furutani 【 Cognitive Neuroscience Lab. 】

1 はじめに

腹側視覚経路では主に物体の形状、色や質感への選択性があり、特に脳の前方領域ではより複雑な視覚刺激の処理を行っている。例えばFFA(Fusiform Face Area)は顔の情報処理を担い、PPA(Parahippocampal Place Area)は場所の情報処理を担い、LO(Lateral Occipital)などはオブジェクトの情報処理を担っている [1]。このように、大まかな視覚カテゴリごとに処理の領域が異なることが明らかになっているものの、カテゴリ内の情報処理についてはほとんど分かっていない [2]。本研究では空間分解能に優れた機能的磁気共鳴画像法 (fMRI) と時間分解能に優れた脳波の同時脳活動データを深層学習により学習させ、trial basedで被験者が見た画像のデコードを行った。カテゴリの異なる視覚刺激は別々の脳領域にて処理されるという点で、fMRIが識別に貢献すると考えられる。一方で、カテゴリ内の個別の視覚刺激は同一領域内において時間的に異なる反応を示すという点から脳波が貢献すると考えられる (図1)。

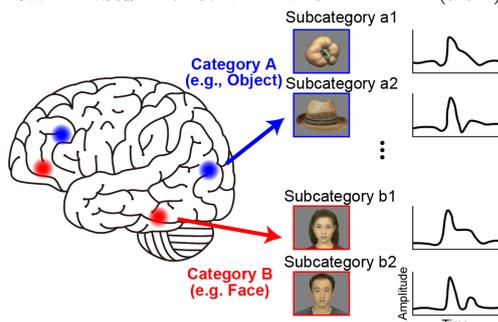


図 1: 脳内視覚表象の時空間モデル

2 方法

2.1 参加者

同意を得た健康な参加者 53 名 (男性 34 名、女性 19 名、年齢範囲: 18~25 歳) で実験を行った。

2.2 実験デザイン

実験刺激は、顔と物体の視覚カテゴリから 40 枚のカラー画像を用いた。“顔カテゴリ”は、“男性顔サブカテゴリ”と“女性顔サブカテゴリ”で構成される。“物カ

テゴリ”は、“自然物サブカテゴリ”と“人工物サブカテゴリ”で構成される。

2.3 実験手順

参加者にはボタンを押すことで対応する視覚サブカテゴリ (男性顔、女性顔、自然物、人工物) を判定してもらった。各 run は 50 試行のシーケンスで構成される。各試行では 500 ms の刺激が提示され、その後 9,500 ms の固視点が提示された。各参加者は 3~12 run (9.9 ± 2.8 , 平均 \pm SD、合計 523 run) の fMRI と脳波の同時記録を行った。その結果、顔試行 10,460 回、物体試行 10,460 回、空白試行 5,230 回の合計 26,150 試行の神経活動データが得られた。

3 解析

3.1 fMRI 単変量解析

参加者ごとの解析では、一般線形モデルを用いてタスク event のパラメータ値を推定した。グループレベルの解析では、各参加者の contrast map について、グループ平均検定を行った。ボクセルクラスタを、 $P < 0.001$, uncorrected のボクセル単位の有意水準を用いて同定し、FSL の randomise 関数を用いて ($N=5,000$)、FWE, $P < 0.05$ の閾値を持つ全脳で有意性をテストした。

3.2 脳波 ERP 解析

視覚サブカテゴリごとに、すべての正解試行のデータを平均化することで、単一の事象関連電位 (ERP) を作成した。あるチャンネルの ERP がカテゴリごとに異なる時間的特徴を示しているかどうか調べた。

3.3 ディープニューラルネットワーク (DNN) 分類器

視覚的なカテゴリカル表象とサブカテゴリカル表象を反映する時空間神経活動を探索するために、ディープニューラルネットワーク (DNN) 分類器を新規に構築した。モデルの Train/Validation は、PyTorch (<https://pytorch.org/>) を用いて実施した。DNN モデルは、(1)fMRI データ用の 3次元畳み込みニューラルネットワーク (CNN) と、(2) 脳波データ用の 2次元 CNN から構成した。Trial based の fMRI ボリュームと脳波時系列データを入力データ

セットとして用いた。不正解試行とノイズの多い試行を除去した後、これを無作為に10個のサブセットに分割して10-foldクロスバリデーションテストを行った。

4 結果

4.1 fMRI 単変量解析

カテゴリ間の contrast では、顔カテゴリにおいてはFFA、物カテゴリについてはLOで賦活が見られた。一方で、カテゴリ内 contrast については有意な賦活はほとんど見られなかった。

4.2 脳波 ERP

カテゴリ間、カテゴリ内のERP差分ともに複数のchで波形の違いがあった。

4.3 DNN によるデコーディング

DNN 識別結果のスコアを図2に示す。カテゴリ間(顔/物)の平均識別精度はTrain=78.1%、Validation=77.2%であった。Train、Validation共にchance level (50%)に対して統計的に有意な差が認められた(t-test: Train, $p=8.91e-12$, $t=43.52$; Validation, $p=2.71e-18$, $t=231.10$)。顔カテゴリ内(男性顔/女性顔)の平均識別精度はTrain=68.0%、Validation=53.8%であった。Train、Validation共にchance level (50%)に対して統計的に有意な差が認められた(t-test: Train, $p=3.65e-06$, $t=9.98$; Validation, $p=1.11e-13$, $t=70.97$)。物カテゴリ内(人工物/自然物)の平均識別精度はTrain=64.9%、Validation=53.9%であった。Train、Validation共にchance level (50%)に対して統計的に有意な差が認められた(t-test: Train, $p=1.50e-06$, $t=11.10$; Validation, $p=1.52e-11$, $t=41.01$)。

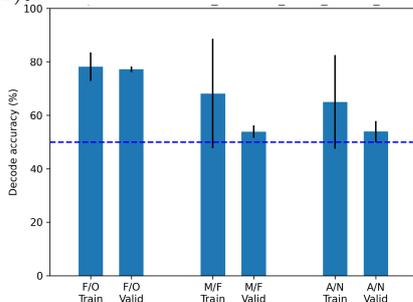


図2: DNNによる視覚情報の識別結果。F/O: 顔と物の識別成績, M/F: 男性顔と女性顔の識別成績, A/N: 人工物と自然物の識別成績。エラーバーは標準偏差

4.4 Grad CAMによる特徴マップの可視化

顔カテゴリ識別ではFFA領域を、物カテゴリ識別では両側のLO領域などが学習に影響を与えていることがfMRIの結果により明らかとなった(図3)。顔カテゴリ内識別(男性顔/女性顔サブカテゴリ)については、脳波では400msから600msにおいてweightに差がみられた。また人工物/自然物サブカテゴリの脳波では200ms付近のweightが大きく異なっていた(図4)。

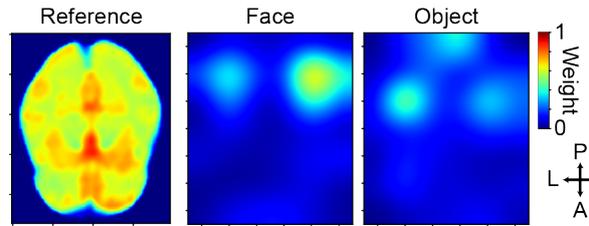


図3: Grad CAMによるfMRIカテゴリ間特徴マップの可視化。左: reference画像, 中央: 顔カテゴリ特徴マップ, 右: 物カテゴリ特徴マップ。

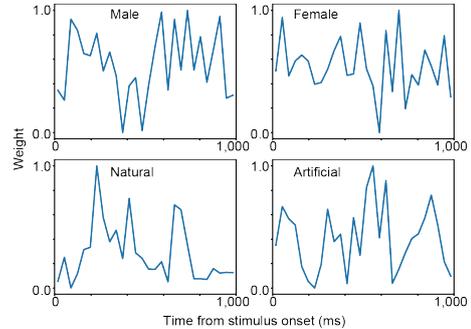


図4: Grad CAMによる脳波カテゴリ内特徴マップの可視化。0msから500msで刺激提示した。左上: 男性顔, 右上: 女性顔, 左下: 自然物, 右下: 人工物。

5 考察

カテゴリごとの視覚情報処理は、fMRI単変量解析の結果が先行研究と一致しており、DNN識別結果でも高いスコアが得られた。また、Grad CAMを用いた識別特徴の可視化においてもfMRI単変量解析の賦活領域との一致が見られた。カテゴリ内については、DNN識別はchance level (50%)に対して統計的に有意な差はあったものの、実用的な数値には至らなかった。この理由としては、trial basedの解析では脳波のS/N比が十分ではないことが挙げられる。実際、平均波形であるERPで(Object内は特徴的な差分が見られたが)Face内では大きな波形の違いが見られなかった。ただし、Grad CAMによる可視化の結果、カテゴリ内については脳波の時間的な特徴の差が貢献していることが分かった。特に、刺激提示後比較的遅い時間のパターンが貢献していたことも含めて、部分的に仮説を指示する結果になったといえる。DNN識別結果については、モデルのハイパラメータの検証が不十分であり、最善のモデル探索が行えていなかった可能性がある。今後、grid searchなどを用いた探索を行う必要がある。

参考文献

- [1] Grill-Spector and Weiner, 2014, Nat Rev Neurosci, 15(8): 536-48.
- [2] Miyakawa et al, 2018, Cereb Ctx, 28(4): 1416-1431.