

3次元 fMRI 画像からの脳情報デコーディングにおける CNN の適用

1215084 佐々木 泰一 【 知能情報学研究室 】

Application of Convolutional Neural Network to Brain Decoding from 3-Dimensional functional Magnetic Resonance Imaging

1215084 SASAKI, Taichi 【 Intelligent Informatics Laboratory 】

1 はじめに

近年,社会の高齢化に伴い,医療や介護の分野で BCI が期待されている.その中で,脳活動データから人間の状態を解読する脳情報デコーディングの研究が行われている [1].これまで脳情報デコーディングは,物体認識や自然画像認識などで成功報告がされている.感情の脳情報デコーディングについても研究がされているが,これには SPM(Statistical Parametric Mapping)によって脳の賦活強度の高い部分をいくつか選択し特徴とする方法や,Searchlight と呼ばれる,球などの幾何学的に定義された関心領域を脳内で移動させ,それを特徴とする方法などを用いた MVPA(Multi-Variate Pattern Analysis) が主に用いられてきた.

CNN を用いた脳情報デコーディングはいくつか報告されているが,これらは物体認識などの感情と比較して低次脳機能のデコーディングである [2][3].また,脳活動データは本来 3次元であるが,多くの研究では 2次元のスライス画像の集まりに 2D-CNN を適用している.3次元の CNN も存在するが,脳情報デコーディングにおける 3D-CNN の適用例はまだほとんど報告されていない.これには,3D-CNN が 2D-CNN に比較して多くのパラメータがあり,また計算資源を要することも問題になっていると考える.そこで本研究では,これまで SVM で行われていた感情の脳情報デコーディングを対象として,3D-CNN の適用に加え,新たに提案する特徴選択を行い 2D-CNN を適用し,その性能を明らかにする.

2 提案手法

本研究では,3次元 fMRI データに 3D-CNN を適用するだけでなく,2D-CNN による特徴抽出・識別を行うための特徴選択を提案する.これまででは,2次元 EPI 画像のスライスをそのまま用いていたが,これでは,スライス間にまたがる局所特徴が失われることが考えられ,新たに,スライス面に直交する 2方向の面についてリスライスを行い,これも入力画像として用いることを提案する.すなわち元の画像が水平断面のスライスである場合に,新たに矢状断面,冠状断面のスライスを再構成し,これも入力画像として追加する.

具体的な方法を図 1 に示す.それぞれの断面で,スライスごとに画像を並べる.この際,水平断面が他の 2面に比べサイズが小さく,それを同サイズにする必要がある.ここでは,配列に 0 を代入することでサイズを同じにしている.3つの 2次元画像の配列を一つの配列とし,それを 1レコードとして扱うパターンを提案手法として識別器を作成する.

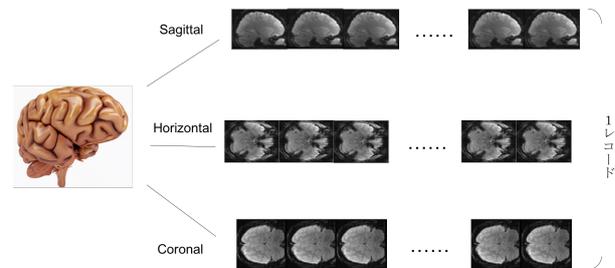


図 1 3つの断面図を 1レコードとして扱う例

3 実験

本研究で用いる 2D-CNN および 3D-CNN は,CPU: Core i7-7700K(4.20GHz),GPU: GTX1080Ti,メモリ: 32GB の計算機上にシステムを構築している.

3.1 データセット

あらかじめ感情指標が評定されたカラー画像セットである OASIS を被験者 8 名に提示し,その時の脳活動を fMRI 装置で計測した脳活動データ 362 枚のうち,レスト部分を除いた 144 枚をそれぞれ使用する.144 枚の内訳は,快感情を誘起する画像を見せた際の脳活動データ 72 枚と,不快感情を誘起する画像を見せた際の脳活動データ 72 枚である.脳活動データは SPM12 を用いて頭部の動き補正,標準脳への正規化を行う.

3.2 学習モデルおよび評価方法

学習モデルとして 3D-CNN および提案手法による 2D-CNN を用いる.また,比較対象として,2D-CNN に 1方向の断面画像のみを用いた場合を 3種類と,SVM を用いる.それぞれで学習を行い,識別率を算出する.識別率の算出は,データセットを 10 分割し,その中の 1グループをテストデータ,残りの 9グループを学習デー

表 2 実験結果

	A	B	C	D	E	F	G	H
2D-CNN(提案手法)	80.2%	80.0%	68.5%	85.7%	76.6%	86.2%	90.1%	85.3%
2D-CNN(horizontal)	75.5%	80.8%	69.4%	79.2%	75.9%	79.0%	84.1%	82.9%
2D-CNN(sagittal)	77.0%	77.2%	68.7%	82.0%	75.9%	77.8%	79.9%	82.8%
2D-CNN(coronal)	75.1%	79.2%	67.2%	79.6%	77.2%	79.3%	82.0%	79.2%
SVM	66.2%	85.3%	60.4%	60.6%	70.2%	75.0%	79.1%	80.2%
3D-CNN	73.6%	82.5%	66.8%	77.1%	73.5%	80.6%	82.0%	78.8%

タとし識別率を算出する．これを 10 回繰り返して、各識別率の平均をその学習の識別率とする．2D-CNN および 3D-CNN は 500 エポックの中で最も高い識別率のものを用いる．実装には Keras を用い、学習モデルは表 1 のように 10 層で構成し、畳み込み層のフィルタの数は全て 20 で検証する．SVM は、RBF カーネルを用い、PSO(Particle Swarm Optimization) を用いてハイパーパラメータを定める．ハイパーパラメータは C, γ をそれぞれ、 $1 \sim 1000, 10^{-12} \sim 1$ の範囲で探索し、最も識別率が高かった値を用いる．

表 1 2D-CNN の学習モデル

layer	filter	stride	unit	f(x)
畳み込み層 1,3,5,7 層目	$3 \times 3 \times 20$	1	-	ReLU
プーリング層 2,4,6,8 層目	2×2	2	-	-
全結合層	-	-	1000	ReLU
出力層	-	-	2	softmax

4 実験結果および考察

4.1 提案手法と従来の 2D-CNN および SVM との比較

それぞれの学習方法で算出した識別率を表 2 に示す．2D-CNN、または 3D-CNN を用いた場合が、SVM を用いた学習と比較して、被験者 1 名を除き最も高い識別率となった．このことから、CNN は人間の感情の脳情報デコーディングにおいて有効であると考えられる．2D-CNN を用いた場合のそれぞれの手法ごとの識別率を比較すると、提案手法の場合に被験者 G で 90.1% と最も高い識別率となった．また、他の被験者を見た場合にもほぼ全ての被験者において他の手法より高い識別率となった．このことから、2 次元 EPI 画像のスライスそのまま用いた場合に失われていた局所特徴が、提案手法では失われずに表現できていると考えられる．

4.2 提案手法と 3D-CNN の比較

提案手法と 3D-CNN を比較した場合、被験者 B を除き、提案手法の方が高い識別率となった．さらに、提案

手法と 3D-CNN における最大 batch size と、エポックごとの学習にかかる時間を表 3 に示す．最大 batch size を比較すると、提案手法の方がより batch size を大きくすることができることがわかった．つまり、より低スペックなマシンにおいても学習を行うことができると言える．さらに、学習時間を比較すると提案手法の場合により早く学習が終わることがわかった．

これらのことから、提案手法は 3 次元 fMRI 画像からの脳情報デコーディングへの 2D-CNN の適用において有効であると考えられる．

表 3 実験結果

	最大 batch size	時間 (s/epoch)
提案手法	16	3.24
3D-CNN	4	4.30

5 まとめ

本研究は人間の感情のデコーディングを検討した．脳活動データは 3 次元画像であり、通常の 2D-CNN にすべての情報を保持したまま適用することができない．そこで、本研究では 2D-CNN に 3 次元画像を適用する方法を検討した．結果として提案手法は多くの被験者で、比較対象と比べ高い識別率となった．また、提案手法は 3D-CNN よりも少ない計算資源で学習することができる．

参考文献

- [1] Orhan Firat, et al., "DEEP LEARNING FOR BRAIN DECODING," IEEE International Conference on Image Processing, pp. 2784–2788, 2014.
- [2] Tomoyasu Horikawa, et al., "Hierarchical Neural Representation of Dreamed Objects Revealed by Brain Decoding with Deep Neural Network Features," Front. Comput. Neurosci., Vol. 11, Article 4, 2017.
- [3] Haiguang Wen, et al., "Neural Encoding and Decoding with Deep Learning for Dynamic Natural Vision," Cerebral Cortex, pp. 1–25, 2017.