

深層学習による技能獲得前の脳画像を用いた運動学習能力の推定

1230385 山口 竜矢 【身体情報サイエンス研究室】

1 はじめに

我々は運動学習を通して様々な運動技能を獲得することができるが、学習能力には個人差が生じるため事前予測が困難である。先行研究の解析手法では、技能獲得前の脳画像と運動学習能力の関連部位の同定が行われたが、各特徴を用いた多次元的な評価による予測は困難である。しかし、Conventional Neural Network(CNN)を用いた画像認識による脳画像解析を行うことで、運動学習能力と関連のある脳部位の特徴抽出が行え、多次元的に評価した運動学習能力の予測が可能となる。

そこで本研究では、複数の CNN モデルを用いて技能獲得前に撮像した脳画像から運動課題の成績を予測できるか検討した。

2 実験方法

本研究では事前に回答された運動歴に関するアンケートから、利き手が右利きかつジャグリング未経験の本学学生 70 名 (女性 24 名, 平均年齢 20.9 歳) が参加した。

2.1 脳画像の撮像

機能画像と構造 (拡散テンソル, 3 次元 T1 強調) 画像を撮像し、技能獲得前の脳状態を計測した。機能画像は fMRI 装置内に表示される固視点をリラックスした状態で注視してもらい、安静時脳活動を 10 分間撮像した。

2.2 ジャグリング課題の実施

脳画像撮像後、右手で 2 つのボールを内回しで交互に投げ上げる 2 ボールジャグリング課題を実施した。見本動画を 3 回提示し、投げ始めからボールが落ちるか、動作が止まるか、2 球同時に保持するまでを 1 試行とし、合計 250 試行を行った。各試行の成功回数を数え、運動課題開始から 10 分毎に 3 分間の休憩を設けた。

3 解析

データが不適切な 2 名を除く 68 名で解析を行った。

3.1 成績評価

被験者 1 名の試行総数が 248 試行だったため、全被験者の試行総数を 248 試行に統一した。各試行の成功回数から合計を算出し、運動課題の学習度とした。

3.2 データセット・前処理

SPM12 の toolbox である DPARSFA を用いて、機能画像から mfALFF 画像を作成した。SPM12 を用いて、拡散テンソル画像から白質画像 (DTI), 3 次元 T1 強調画像から灰白質画像 (VBM) を作成した。また、各画像を水平断面方向にスライスした 2 次元画像を作成した。各画像に対し、運動課題の学習度から上位 34 人と下位 34 人の 2 クラスに分類しラベル付けを行った。

3.3 推定モデル

3D-CNN と 2D-CNN を用いて 2 クラス分類を行った。3D-CNN では VGG, ResNet, Cole-CNN, Fixed Filter, Down Scaling を用いた [2]。2D-CNN では事前学習済みモデル ResNet50 を用い、ファインチューニングを行った。20 回の正解率の平均をモデルの評価とした。

4 実験結果

3D-CNN, 2D-CNN の結果を表 1 に示す。3D-CNN では全モデルで正解率が低く、運動課題の学習度を予測することはできなかった。2D-CNN でファインチューニングを行った場合は、運動課題の学習度を高精度で予測することができた。その結果からチャンスレベル (50%) との 1 標本 t 検定の結果、全画像で有意差が得られた ($p < .01$)。また一元配置分散分析の結果、画像間の平均に有意差が得られた ($p < .01$)。さらに Bonferroni の多重比較により、全画像間の平均に有意差が得られ ($p < .01$)、VBM 画像の正解率が有意に高いことが示された。

表 1 各モデルの正解率の平均

Model	3D-CNN			
	mfALFF	DTI	VBM	同時入力
VGG	52.86±13.19	43.93±12.96	44.64±11.32	49.29±3.27
ResNet	48.57±3.97	45.00±3.28	46.07±2.67	36.79±2.61
Cole-CNN	48.93±2.55	42.14±2.59	45.36±2.28	44.29±2.52
FixedFilter1	43.93±2.45	47.86±2.60	46.07±3.00	45.36±2.90
FixedFilter2	41.79±2.99	51.79±2.83	47.50±2.94	45.71±3.49
FixedFilter3	47.50±2.45	48.57±2.82	46.43±3.04	45.36±2.33
DownScaling	47.14±3.25	48.93±2.22	47.14±3.53	48.21±3.80
Model	2D-CNN			
	mfALFF	DTI	VBM	同時入力
ResNet50	82.73±2.18	77.55±1.85	92.56±2.57	86.37±2.87

各モデルの正解率 (%) は平均値 ± 標準偏差で表記。

5 考察

3D-CNN では過学習が確認され、データが少ないため適切な学習が行えなかったと考えられる。2D-CNN で用いた事前学習モデルは大量の画像を学習しているため、脳画像のような特殊な画像、かつ少ないデータに対しても適切な学習が行え、高精度で運動課題の学習度を予測できたと考えられる。特に Bonferroni を用いた多重比較の結果から、灰白質画像を用いることで高精度の予測が可能であることが示唆された。

参考文献

- [1] 横田文, “技能獲得前の脳画像を用いた運動学習能力の予測に関する検討”, 高知工科大学, 修士学位論文, 2022.
- [2] 笹谷健文, “機械学習による脳構造 MRI からの個人属性の推定”, 高知工科大学, 修士学位論文, 2019.