

安静時機能的 MRI の時系列解析を目的とした

空間的次元圧縮手法の提案

The method of dimension reduction of fMRI data of resting state using 3D convolutional deep auto-encoder

5116E009-6 高橋 真麻
TAKAHASHI Maasa

指導教員 尾形 哲也 教授
Prof. OGATA Tetsuya

概要:本研究では、脳状態を立体的に撮影したデータである安静時機能的 MRI の空間的次元圧縮手法の提案を目的とする。安静時機能的 MRI は個人の脳状態を表した有益な情報源であるが、空間情報が大きいため、その時間変化に着目した研究は少ない。そのため、深層学習の技術の一つである自己符号化器を安静時機能的 MRI の空間的次元圧縮に利用した。従来の自己符号化器は主に平面画像に用いるものであるが、3次元フィルタによる畳み込みを組み込むことで立体的な MRI データの学習を試みた。学習を行った結果、入力立体画像の高い類似度での復元と、特徴量の抽出が確認された。

キーワード: ディープラーニング, 自己符号化器, 安静時機能的 MRI

keywords: Deep Learning, Auto Encoder, resting state fMRI

1. 背景

人の脳は何もしていない状態、すなわち安静時でも活動している。安静時とは、動いたり特定の物事について考えたりしておらず、寝ていない状態のことを指す。

MRI 撮像器の中で横たわって 10 分程度、目を開けた状態で安静時の脳活動を計る。これを安静時機能的 MRI と呼ぶ、このとき脳は活発に活動しており、更には特定の領域間の活動には相関も見られることがわかっている。

安静時の機能的結合群を解析することで様々なことを予測することができる。被験者の短期記憶力[1]や学習能力[2]がある程度予測可能であるほか、自閉症[3]や鬱[4]などの精神疾患患者と健常者を見分けることができる。ゆえに安静時機能的 MRI は患者の脳状態を示す有益な情報源であると考えられており、様々な解析、研究がこれまで行われている。

ここで、近年画像分野における解析手法では、深層学習が注目を集めている。深層学習とは、多層のニューラルネットワークを用い機械が自動的にデータから特徴を抽出する機械学習の方法論である。

脳機能画像の解析においても、実際に深層学習の利用が試みられている。Jang ら(2016)は、深層学習を用いて安静時機能的 MRI の解析を行い、被験者の年齢推定を行った[5]。しかし、学習の際入力として用いられているのは関心領域の機能的結合群であり、これは人手による前処理が必要であり、時系列情報を含まない静的な情報である。

そこで本研究では、安静時機能的 MRI の空間的次元圧縮手法の提案を目的とする。これにより、高次元の空間情報を圧縮することで、将来的に時系列を含んだ新しい脳機能画像の解析への展望が期待される。

2. 提案手法

自己符号化器とは、入力画像を、元の次元量よりも小さい次元の内部層を通過して、出力として元画像を再現するように学習する。入力画像と出力画像の誤差が小さくなるように内部のパラメータが更新されていき、中央部に特徴量を獲得することができる。

通常、自己符号化器は主に平面画像に用いられるものであるが、今回、3次元フィルタによる畳み込みを符号化、復号化の部分に組み込むことで、局所的な空間の関係性を保持したまま MRI 立体画像の特徴量の抽出を試みる。




図 1. 3次元畳み込みを含む自己符号化器

3. 実験

オープンソースの安静時機能的MRIデータを26被験者分用意し, 24被験者分をモデルの学習用データ, 2被験者分を学習後のモデルの性能テスト用データとした. データの脳サイズはCONNという解析用ソフトウェアを用いて標準化し, $(x,y,z)=(91,109,91)$ (= 902,629次元)に均一化した. また, 入力画像の時系列は194stepであった. これらを学習の入力として, 3次元畳み込みを含む自己符号化器の中央層を20次元に設定し, 脳機能画像の3次元データに対する確率的勾配法によるバッチ学習を行った.

4. 結果

バッチ学習後のテストデータの入力, 出力, 及び誤差の断面画像を図2に示す.




図2. テストデータの入出力及び誤差の断面画像

図より, 入力画像と出力画像の誤差の値は小さく, 入力と類似度の高い出力が得られたと言える. これは, ふたつの根平均二乗誤差 $RMSE = 0.124$, 正規化相互相関 $NCC = 0.959$ という数値的結果からも示された.

中央層を20次元に設定した本モデルにおいても, 安静時機能的MRIの入力画像の再現が十分に可能であるということが確認できた.

次に, 得られた特徴量の時系列を生成したものを図3に示す.




図3. 抽出した特徴量の時系列

図3より, 得られた特徴量はどれも時系列変化に乏しいことが確認された. これは, 脳活動の不変な成分が全体の特徴量にも影響していることが推測される. 今後の課題として, この不変成分を除去した解析を試みる必要が挙げられる.

5. まとめと展望

本研究では, 安静時機能的MRIの空間的な次元圧縮手法の提案を目的とした. そのため, 3次元畳み込みを含む自己符号化器を利用した. モデルによる学習の結果, 入力立体画像の高い精度での復元と, 特徴量の抽出が確認されたが, 得られた特徴量の時系列変化は乏しいことが確認された. 今後の課題として, 脳活動の不変成分を除去し再度特徴量抽出を行うことで, 時間情報を考慮した解析への応用が期待される.

参考文献

- [1] Hampson M, Driesen NR, Skudlarski P, Gore JC, Constable RT(2006) Brain connectivity related to working memory performance. *J Neurosci* 26(51):13338-13343
- [2] Baldassarre A et al. (2012) Individual variability in functional connectivity predicts performance of a perceptual task. *Proc Natl Acad Sci USA* 109(9):3516-3521.
- [3] Anderson JS, et al. (2011) Functional connectivity magnetic resonance imaging classification of autism. *Brain* 134(12): 3742-3754
- [4] Zeng LL, et al. (2012) Identifying major depression using whole-brain functional connectivity: A multivariate pattern analysis. *Brain* 135(5):1498-1507
- [5] Jang & Lee (2016) Deep neural network for age prediction using resting-state fMRI data. *OHBM 2016*.