

令和 4 年度
修士学位論文

機械学習による MRI 脳画像からの 回帰モデルの説明性に関する研究

A Study on Explainability of Machine
Learning-Based Regression Models for Brain MRI

1255122 安岡 薫

指導教員 吉田 真一

2023 年 2 月 28 日

高知工科大学大学院 工学研究科 基盤工学専攻
情報学コース

要 旨

機械学習による MRI 脳画像からの 回帰モデルの説明性に関する研究

安岡 薫

近年、脳から得られた様々なデータと、性別や年齢、健康に関する指標を用いた解析を行うことで、脳と、個人属性または健康状態の関連について調査する研究が盛んに行われている。Park らの研究では脳内の病変である白質病変と、BMI や血圧などの健康指標を対象とした解析を行い、それらの関連が有意であることが示されている。その中で、機械学習による脳画像を対象とした画像認識の研究も数多く存在し、Cole らの研究では MRI 脳画像を用いた 3 次元畳み込みニューラルネットワーク (3D-CNN) による年齢推定において、決定係数 R^2 が 0.92 と高精度な推定モデルが構築されている。しかし、CNN はモデルから推定を行った理由を明らかにすることが難しく、説明性の観点で課題がある。

そこで本研究では 3D-CNN による回帰モデルを用い、複数の前処理手法により得られた脳画像に対して、脳との関連が報告されている年齢、BMI の推定を行い、さらに部位ごとのマスクを用いて抽出した特定の脳部位を対象とする複数パターンの機械学習を実行することで、それらにより得られた結果から推定に影響を与えた部位や要因の考察を行った。その結果、年齢に関して、脳部分の構造が推定に寄与しているという結果が得られた。そして、より推定に寄与した脳部位として縁上回 (後部)、前頭極、海馬傍回 (後部)、下前頭回 (弁蓋部)、側頭平面などが得られた。BMI に関しては、脳部分との関連は得られず、脳以外が推定に寄与しているという結果が得られた。

キーワード CNN, 説明性, MRI 脳画像

Abstract

A Study on Explainability of Machine Learning-Based Regression Models for Brain MRI

YASUOKA, Kaoru

In recent years, many studies have been conducted to investigate the relationship between the brain and personal attributes or health status by analyzing various data obtained from the brain, and gender, age, and health indices. In a study by Park et al., white matter hyperintensity, which are lesions in the brain, and health indicators such as BMI and blood pressure were analyzed and showed significant associations. In the study by Cole et al., a highly accurate estimation model with a coefficient of determination R^2 of 0.92 was constructed for age estimation using a three-dimensional convolutional neural network (3D-CNN) based on MRI brain images. However, CNNs have a problem in terms of explainability because it is difficult to clarify the reason for the estimation from the model.

In this study, a 3D-CNN regression model was used to estimate age and BMI, which have been reported to be related to the brain, for brain images obtained by multiple preprocessing methods. In addition, machine learning of multiple patterns targeting specific brain regions extracted using region-specific masks was performed. The results of the experiment provide a discussion of the sites and factors that affected the estimation. The results showed that the structure of the brain part contributed to the estimation with respect to age. The brain regions that contributed more to the estimation were supramarginal gyrus, posterior division, frontal pole, parahippocampal

gyrus, posterior division, inferior frontal gyrus, pars opercularis, and planum temporale. BMI was not related to brain regions, indicating that other regions than the brain contributed to the estimation.

key words CNN, Explainability, Brain MRI

目次

第 1 章	序論	1
1.1	研究背景	1
1.2	研究目的	2
第 2 章	関連研究・関連技術	3
2.1	白質病変と健康指標の関連	3
2.2	FSL	3
第 3 章	実験	7
3.1	データセット	7
3.1.1	年齢推定に用いるデータセット	7
3.1.2	BMI 推定に用いるデータセット	9
3.2	脳画像に対する前処理	10
3.3	実験で用いる機械学習手法	13
3.4	実験方法	14
3.5	12 種類の脳画像を対象とした 3D-CNN による年齢・BMI の推定	15
3.6	分割された脳部位を対象とした 3D-CNN による年齢の推定	18
第 4 章	結果	20
4.1	年齢推定の結果	20
4.1.1	12 種類の脳画像を用いた年齢推定の結果	20
4.1.2	48 領域に分割された脳部位を用いた年齢推定の結果	23
4.2	BMI 推定の結果	24
第 5 章	考察	27

目次	
5.1	年齢推定に関する考察 27
5.2	BMI 推定に関する考察 28
第 6 章	結論 30
謝辞	31
参考文献	32
付録 A	34
A.1	12 種類の脳画像を用いた年齢推定の結果 34
A.1.1	(1) を用いた年齢推定の結果 34
A.1.2	(2) を用いた年齢推定の結果 34
A.1.3	(3) を用いた年齢推定の結果 34
A.1.4	(4) を用いた年齢推定の結果 35
A.1.5	(5) を用いた年齢推定の結果 35
A.1.6	(6) を用いた年齢推定の結果 35
A.1.7	(i) を用いた年齢推定の結果 35
A.1.8	(ii) を用いた年齢推定の結果 35
A.1.9	(iii) を用いた年齢推定の結果 36
A.1.10	(iv) を用いた年齢推定の結果 36
A.1.11	(v) を用いた年齢推定の結果 36
A.1.12	(vi) を用いた年齢推定の結果 36
A.2	BMI 推定の結果 37
A.2.1	(1) を用いた BMI 推定の結果 37
A.2.2	(2) を用いた BMI 推定の結果 37
A.2.3	(3) を用いた BMI 推定の結果 37
A.2.4	(4) を用いた BMI 推定の結果 37

目次

A.2.5	(5) を用いた BMI 推定の結果	38
A.2.6	(6) を用いた BMI 推定の結果	38
A.2.7	(i) を用いた BMI 推定の結果	38
A.2.8	(ii) を用いた BMI 推定の結果	38
A.2.9	(iii) を用いた BMI 推定の結果	38
A.2.10	(iv) を用いた BMI 推定の結果	39
A.2.11	(v) を用いた BMI 推定の結果	39
A.2.12	(vi) を用いた BMI 推定の結果	39
A.3	48 領域に分割された脳部位を用いた年齢推定の結果	39

目次

2.1	矢状断における Harvard-Oxford atlas	4
3.1	男性 (213 名) の年齢分布	8
3.2	女性 (284 名) の年齢分布	8
3.3	男性 (216 名) の BMI 分布	9
3.4	女性 (284 名) の BMI 分布	10
3.5	前処理 1. による脳画像の変化	10
3.6	前処理 2. による脳画像の変化	11
3.7	前処理 3. による脳画像の変化	11
3.8	前処理 4. による脳画像の変化	12
3.9	脳皮質を 48 領域に分割	12
3.10	3D-CNN のネットワーク構成の概略図	13
3.11	5 分割交差検証	15
3.12	3 次元画像と推定実験	16
3.13	男性 (187 名) の年齢分布	16
3.14	女性 (247 名) の年齢分布	17
3.15	男性 (188 名) の BMI 分布	17
3.16	女性 (248 名) の BMI 分布	18
3.17	48 に分割された脳部位を用いた年齢推定	19
4.1	(1) の散布図 ($R^2=0.7126$)	21
4.2	(2) の散布図 ($R^2=0.6144$)	21
4.3	(3) の散布図 ($R^2=0.5831$)	21
4.4	(4) の散布図 ($R^2=0.5587$)	21

図目次

4.5	(5) の散布図 ($R^2=0.6369$)	22
4.6	(6) の散布図 ($R^2=0.3564$)	22
4.7	(i) の散布図 ($R^2=0.6472$)	22
4.8	(ii) の散布図 ($R^2=0.6391$)	22
4.9	(iii) の散布図 ($R^2=0.4702$)	22
4.10	(iv) の散布図 ($R^2=0.7238$)	22
4.11	(v) の散布図 ($R^2=0.7504$)	23
4.12	(vi) の散布図 ($R^2=0.7256$)	23
4.13	(1) の散布図 ($R^2=0.464$)	25
4.14	(2) の散布図 ($R^2=-0.243$)	25
4.15	(3) の散布図 ($R^2=0.383$)	25
4.16	(4) の散布図 ($R^2=-0.0180$)	25
4.17	(5) の散布図 ($R^2=-0.0467$)	25
4.18	(6) の散布図 ($R^2=-0.116$)	25
4.19	(i) の散布図 ($R^2=0.273$)	26
4.20	(ii) の散布図 ($R^2=-0.397$)	26
4.21	(iii) の散布図 ($R^2=0.282$)	26
4.22	(iv) の散布図 ($R^2=0.145$)	26
4.23	(v) の散布図 ($R^2=0.119$)	26
4.24	(vi) の散布図 ($R^2=0.0701$)	26

表目次

2.1	Harvard-Oxford atlas により分割された 48 領域	5
3.1	ネットワーク構成の詳細	14
4.1	年齢の推定精度 (R^2)	21
4.2	部位ごとの年齢推定精度 (R^2) とボクセル数	23
4.3	BMI の推定精度 (R^2)	24
5.1	(4) を用いた年齢推定の精度 (R^2)	28
5.2	(6) を用いた年齢推定の精度 (R^2)	28
A.1	(1) を用いた年齢推定の精度 (R^2)	34
A.2	(2) を用いた年齢推定の精度 (R^2)	34
A.3	(3) を用いた年齢推定の精度 (R^2)	34
A.4	(4) を用いた年齢推定の精度 (R^2)	35
A.5	(5) を用いた年齢推定の精度 (R^2)	35
A.6	(6) を用いた年齢推定の精度 (R^2)	35
A.7	(i) を用いた年齢推定の精度 (R^2)	35
A.8	(ii) を用いた年齢推定の精度 (R^2)	35
A.9	(iii) を用いた年齢推定の精度 (R^2)	36
A.10	(iv) を用いた年齢推定の精度 (R^2)	36
A.11	(v) を用いた年齢推定の精度 (R^2)	36
A.12	(vi) を用いた年齢推定の精度 (R^2)	36
A.13	(1) を用いた BMI 推定の精度 (R^2)	37
A.14	(2) を用いた BMI 推定の精度 (R^2)	37

表目次

A.15 (3) を用いた BMI 推定の精度 (R^2)	37
A.16 (4) を用いた BMI 推定の精度 (R^2)	37
A.17 (5) を用いた BMI 推定の精度 (R^2)	38
A.18 (6) を用いた BMI 推定の精度 (R^2)	38
A.19 (i) を用いた BMI 推定の精度 (R^2)	38
A.20 (ii) を用いた BMI 推定の精度 (R^2)	38
A.21 (iii) を用いた BMI 推定の精度 (R^2)	38
A.22 (iv) を用いた BMI 推定の精度 (R^2)	39
A.23 (v) を用いた BMI 推定の精度 (R^2)	39
A.24 (vi) を用いた BMI 推定の精度 (R^2)	39
A.25 48 領域に分割された脳部位を用いた年齢推定の結果	39

第 1 章

序論

1.1 研究背景

脳は、個人に関する様々な情報が反映される場所であると考えられ、近年、脳から得られた様々なデータと、性別や年齢、健康に関する指標を用いた解析を行うことで、脳と、個人属性または健康状態の関連について調査する研究が盛んに行われている。Park らによる先行研究では脳内の病変である白質病変と、BMI や血圧などの健康に関する指標とで有意な関連が示されている [1]。また、脳画像は、個々人の脳の状態を可視化したものであるため、個人に関する情報を推定する際に、有用な構造情報を内包した重要なデータであると考えられている。しかし、脳画像から微細な構造の違いを、人間の視覚で捉えることは難しい。その中で、機械学習は微細な脳の構造の違いを認識することに適しているという考えのもと、機械学習による脳画像を対象とした画像認識の研究も多く存在する。Cole らの研究では MRI 脳画像を用いた 3 次元畳み込みニューラルネットワーク (3D-CNN) による年齢推定において、決定係数 R^2 が 0.92 と高精度な推定モデルが構築されている [2]。しかし、ニューラルネットワーク全般として、モデルがブラックボックスであるという特性により、認識や、推定に至った理由を明らかにすることが難しく説明性が乏しいことから、医療などの分野への応用に関して課題を抱えている。

1.2 研究目的

本研究では 3D-CNN による回帰モデルを用い、複数の前処理により得られた 12 種類の脳画像に対して、脳と関連が示されたと報告 [1][2] される年齢と BMI の推定を行い、それらの結果を比較することで推定に寄与した要因の解析を行う。さらに年齢の推定に関して、脳画像を各脳部位に分割し、それらを用いた推定を行う。その結果得られた各脳部位からの推定精度を比較することで、推定に寄与した脳部位についても解析を行う。本研究ではこれらの実験により MRI 脳画像を用いた際の年齢、BMI 推定における CNN による回帰モデルの説明性について調査を行うことを目的としている。

第 2 章

関連研究・関連技術

2.1 白質病変と健康指標の関連

脳血管疾患は関与する血管の直径の大きさにより大血管疾患 (LVD) と小血管疾患 (SVD) に分類される。LVD は脳卒中や認知症の原因になり得ると考えられており、また高血圧症や糖尿病、脂質異常症などの先進国における主要な血管リスク状態は LVD の危険因子であると報告されている [3][4]。しかし LVD と比較して SVD はその研究が十分ではなく、高血圧症は SVD の危険因子であるが、糖尿病や脂質異常症は SVD に関して、その役割があまり解明されておらず更なる研究が必要とされている [5]。白質内の細胞外間隙である白質病変は SVD の主要な特徴の一つであり、加齢、高血圧、脳血流の低下による細動脈や毛細血管の消失により生じると考えられている [6]。また白質病変は脳卒中の再発、認知機能の低下、認知症と有意に関連するとされている [7]。その中で、先行研究 [1] では、脳血管疾患の全ての範囲について明らかにするために SVD の特徴である白質病変と、危険因子として挙げられる BMI や最高血圧、最低血圧などの健康に関する指標とで解析が行われている。それにより、BMI、最高血圧、血糖値、トリグリセリド値、LH 比 (LDL コレステロールと HDL コレステロールの比) において関連が有意に示される結果が得られている。

2.2 FSL

FMRIB Software Library(FSL)[8] は、オックスフォード大学の FMRIB の解析グループにより開発された、脳画像に対して使用する分析ツールである。本研究においては、機械

2.2 FSL

学習に用いる脳画像に対し前処理を行う際に、FSL を使用した。また、本研究では脳部分を分割する際、FSL で使用可能な Harvard-Oxford atlas を用いた。Harvard-Oxford atlas とは Center for Morphometric Analysis (CMA) により開発された 48 の皮質、21 の皮質下構造からなる脳アトラスである。Harvard-Oxford atlas は、健康な男性 21 名と健康な女性 16 名（18～50 歳）の T1 強調画像を半自動化ツールを用いてセグメンテーションした後、標準空間 (MNI152) に対する線形レジストレーションを各ラベルに適用し、それらを被験者間で組み合わせ、各ラベルの母集団確率マップを作成することで開発された。本研究ではこれを用いて 48 の皮質領域のセグメンテーションを行った。図 2.1 は脳画像の矢状断における、Harvard-Oxford atlas が分割する領域を FSLeyes[9] を用いて表示したものである。また Harvard-Oxford atlas により分割された脳領域は表 2.1 の通りである。




図 2.1 矢状断における Harvard-Oxford atlas

2.2 FSL

表 2.1: Harvard-Oxford atlas により分割された 48 領域

脳領域
Frontal Pole
Insular Cortex
Superior Frontal Gyrus
Middle Frontal Gyrus
Inferior Frontal Gyrus, pars triangularis
Inferior Frontal Gyrus, pars opercularis
Precentral Gyrus
Temporal Pole
Superior Temporal Gyrus, anterior division
Superior Temporal Gyrus, posterior division
Middle Temporal Gyrus, anterior division
Middle Temporal Gyrus, posterior division
Middle Temporal Gyrus, temporooccipital part
Inferior Temporal Gyrus, anterior division
Inferior Temporal Gyrus, posterior division
Inferior Temporal Gyrus, temporooccipital part
Postcentral Gyrus
Superior Parietal Lobule
Supramarginal Gyrus, anterior division
Supramarginal Gyrus, posterior division
Angular Gyrus
Lateral Occipital Cortex, superior division
Lateral Occipital Cortex, inferior division

2.2 FSL

Intracalcarine Cortex
Frontal Medial Cortex
Juxtapositional Lobule Cortex (formerly Supplementary Motor Cortex)
Subcallosal Cortex
Paracingulate Gyrus
Cingulate Gyrus, anterior division
Cingulate Gyrus, posterior division
Precuneous Cortex
Cuneal Cortex
Frontal Orbital Cortex
Parahippocampal Gyrus, anterior division
Parahippocampal Gyrus, posterior division
Lingual Gyrus
Temporal Fusiform Cortex, anterior division
Temporal Fusiform Cortex, posterior division
Temporal Occipital Fusiform Cortex
Occipital Fusiform Gyrus
Frontal Operculum Cortex
Central Opercular Cortex
Parietal Operculum Cortex
Planum Polare
Heschl's Gyrus (includes H1 and H2)
Planum Temporale
Supracalcarine Cortex
Occipital Pole

第 3 章

実験

本研究では回帰モデルから出力される値の違いにより，二種類の予測値を対象に実験を行った．両実験とも，3D-CNN による回帰モデルを用いた MRI 脳画像を入力とする推定実験であり，その出力値が一方は年齢，一方は BMI となっている．本章では実験を行うにあたり用いたデータセット，前処理手法，実験方法について記述する．

3.1 データセット

本研究では IXI データセット [10] に含まれる T1 強調画像，年齢，そして式 (3.1) により身長と体重から算出した BMI の，3 つのデータを実験に用いる．実験は機械学習による年齢，BMI 推定の二つのタスクに分かれるが，推定実験に必要な T1 強調画像，年齢，BMI，これら 3 つのデータの全てを保持していない被験者も存在し，各推定実験で使用するデータセットは異なる．以下に各推定実験で用いるデータセットについて記述する．

$$\text{BMI} = \text{weight in kilograms} / \text{height in meters}^2 \quad (3.1)$$

3.1.1 年齢推定に用いるデータセット

年齢推定を行う際に用いるデータセットは 497 名（男性 213 名，女性 284 名）の T1 強調画像である．このデータセットの年齢の幅は 20 歳～86 歳となっている．図 3.1 は男性の年齢分布，図 3.2 は女性の年齢分布を表している．

3.1 データセット




図 3.1 男性（213 名）の年齢分布




図 3.2 女性（284 名）の年齢分布

3.1 データセット

3.1.2 BMI 推定に用いるデータセット

BMI 推定を行う際に用いるデータセットは 500 名（男性 216 名，女性 284 名）の T1 強調画像である．このデータセットの BMI の幅は $17.0 \sim 49.6 \text{ kg/m}^2$ となっている．図 3.3 は男性の BMI 分布，図 3.4 は女性の BMI 分布を表している．




図 3.3 男性（216 名）の BMI 分布

3.2 脳画像に対する前処理




図 3.4 女性（284 名）の BMI 分布

3.2 脳画像に対する前処理

本研究で行う機械学習による推定は、複数の前処理を用いたデータセットを対象としている。本研究で用いる前処理は全て FSL により行っている。各前処理手法を以下に示す。

1. オリジナルの脳画像に対し、向きの変更、トリミング、バイアス補正を行う（図 3.5）。得られた脳画像を本論文では (1) とする。




図 3.5 前処理 1. による脳画像の変化

2. (1) から脳部分、脳以外、脳脊髄液 (CSF)、灰白質 (GM)、白質 (WM) の抽出を行う

3.2 脳画像に対する前処理

[11] (図 3.6) . 得られた脳画像を本論文ではそれぞれ (2)～(6) する.




図 3.6 前処理 2. による脳画像の変化

3. (1) に対し標準空間 (MNI152) へ線形レジストレーションを行う [12][13] (図 3.7) . 得られた脳画像を本論文では (i) とする.




図 3.7 前処理 3. による脳画像の変化

4. (i) から脳部分, 脳以外, 脳脊髄液 (CSF), 灰白質 (GM), 白質 (WM) の抽出を行う [11] (図 3.8) . 得られた脳画像を本論文ではそれぞれ (ii)～(vi) する.

3.2 脳画像に対する前処理




図 3.8 前処理 4. による脳画像の変化

以上の (1)～(6) と (i)～(vi) の計 12 種類の前処理手法に基づく 3 次元画像を年齢，BMI 推定の両実験に入力として用いる．さらに (ii) に対し，FSL で使用可能な Harvard-Oxford atlas を用いて，脳の部位マスクを作成し，脳皮質を 48 領域に分割を行う (図 3.9)．この 48 に分割された各脳領域画像は年齢推定の入力に用いる．




図 3.9 脳皮質を 48 領域に分割

3.3 実験で用いる機械学習手法

実験で用いる機械学習手法は3次元畳み込みニューラルネットワーク (3D-CNN) である。本実験で用いる推定モデルの構成は、先行研究 [14] のものを用いている。この推定モデルでは Cole らの研究 [2] の推定モデルに Gloval Average Pooling (GAP)[15] を用いる構成となっており、GAP により過学習を防ぐことを目的としている。図 3.10 は本実験で用いる 3D-CNN のネットワーク構成の概略図である。また表 3.1 は Conv3D(フィルタ数, フィルタサイズ), MaxPooling3D(フィルタ数) などについて各層の詳細なネットワーク構成を示している。




図 3.10 3D-CNN のネットワーク構成の概略図

3.4 実験方法

表 3.1 ネットワーク構成の詳細

No.	Architecture
1	Conv3D(8, 3) → ReLU → Conv3D(8, 3) → BN → ReLU → MaxPooling3D(2)
2	Conv3D(16, 3) → ReLU → Conv3D(16, 3) → BN → ReLU → MaxPooling3D(2)
3	Conv3D(32, 3) → ReLU → Conv3D(32, 3) → BN → ReLU → MaxPooling3D(2)
4	Conv3D(64, 3) → ReLU → Conv3D(64, 3) → BN → ReLU → MaxPooling3D(2)
5	Conv3D(128, 3) → ReLU → Conv3D(128, 3) → BN → ReLU → MaxPooling3D(2)
6	Global Average Pooling → Dense(1)

3.4 実験方法

実験は CNN による MRI 脳画像を入力とした、年齢、BMI の推定であり、5 分割交差検証により行う。そのため、図 3.11 のようにデータセットをランダムに 5 分割し、分割された一つをテストデータ、それ以外を学習データとする組み合わせを、テストデータとして使用するデータ部分を変更することで 5 パターン用意する。そして学習データを用いて 3D-CNN による機械学習を行い、それにより得られた回帰モデルにテストデータを入力し推定を行う実験を、組み合わせに基づき 5 回実行する。その結果として得た決定係数 $R_1^2 \sim R_5^2$ の平均値を、各推定実験における推定精度とする。また決定係数 R^2 は式 (3.2) により得られる。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.2)$$

y_i : i 番目の正解値, $\hat{y}_i$: i 番目の推定値,

$\bar{y}$: y の平均値

3.5 12 種類の脳画像を対象とした 3D-CNN による年齢・BMI の推定



図 3.11 5 分割交差検証

3.5 12 種類の脳画像を対象とした 3D-CNN による年齢・BMI の推定

上述の前処理により得られた (1)～(6) と (i)～(vi) の 12 種類のデータセットを用い、年齢、BMI の推定を行う。各前処理ごとに得られた画像を入力とした推定実験の結果を比較することで年齢、BMI 推定に寄与した部分や要因を解析する。図 3.12 は実験に用いる 3 次元画像と推定実験の関係を図示したものである。また (1)～(6) のデータセットは、個人空間上の脳画像であるため、被験者ごとにスライス数が異なる。そこで、最も多く分布したスライス数の被験者のみを抽出し実験に用いる。その際の被験者数は年齢推定、BMI 推定の各実験でそれぞれ 434 名 (男性 187 名, 女性 247 名)、436 名 (男性 188 名, 女性 248 名) である。図 3.13, 図 3.14, 図 3.15, 図 3.16 はそれぞれ、年齢推定で用いる男性の年齢分布、

3.5 12 種類の脳画像を対象とした 3D-CNN による年齢・BMI の推定

女性の年齢分布, BMI 推定で用いる男性の BMI 分布, 女性の BMI 分布である.




図 3.12 3次元画像と推定実験




図 3.13 男性 (187 名) の年齢分布

3.5 12 種類の脳画像を対象とした 3D-CNN による年齢・BMI の推定




図 3.14 女性 (247 名) の年齢分布




図 3.15 男性 (188 名) の BMI 分布

3.6 分割された脳部位を対象とした 3D-CNN による年齢の推定




図 3.16 女性（248 名）の BMI 分布

3.6 分割された脳部位を対象とした 3D-CNN による年齢の推定

年齢推定において、図 3.17 のように Harvard-Oxford atlas により 48 の領域に分割された脳画像を用い、部位ごとの学習から得られた回帰モデルによる推定精度を比較することで推定に寄与した脳部位の解析を行う。この際、領域ごとに抽出された脳部位の大きさがそれぞれ異なるため、各脳部位のボクセル数を求め、それを含め結果を考察する。

3.6 分割された脳部位を対象とした 3D-CNN による年齢の推定




図 3.17 48 に分割された脳部位を用いた年齢推定

第 4 章

結果

本章では，本研究で行った各実験の結果について記述する．

4.1 年齢推定の結果

年齢推定に関して，12 種類の前処理により得られた脳画像を用いた推定と，48 領域に分割された脳部位を用いた推定について，それぞれの結果を以下に記述する．

4.1.1 12 種類の脳画像を用いた年齢推定の結果

(1)～(6) と (i)～(vi) を用いた 3D-CNN による年齢推定の結果を表 4.1 に示す．結果の比較を行うと，(1) から (2)，(i) から (ii) に脳抽出した場合でも精度の低下があまり見られず，脳部分のみで頭部全体と同程度の推定精度が得られた．また (1) から (i)，(2) から (ii)，(5) から (v) の標準空間への変換を行った場合においても精度の変化が少なく，近しい精度が得られた．また (1) から (3) に脳以外の抽出を行った場合の精度変化は，(1) から (2) へと脳抽出した場合と類似して，あまり大きな精度低下は見られなかった．しかし (i) から (iii) へ標準空間における画像から脳以外の抽出を行った場合では比較的大きな精度低下が見られ，(3) と (iii) の精度差が大きい結果となった．図 4.1～図 4.12 は (1)～(6) と (i)～(vi) の各実験の 5 分割交差検証において，平均値との差が最も小さい結果となる Fold の散布図である．

4.1 年齢推定の結果

表 4.1 年齢の推定精度 (R^2)

(1)	(2)	(3)	(4)	(5)	(6)
0.6925	0.6100	0.5930	0.4777	0.6544	0.4274
(i)	(ii)	(iii)	(iv)	(v)	(vi)
0.6903	0.6256	0.4599	0.7233	0.7483	0.7332




図 4.1 (1) の散布図 ($R^2=0.7126$)




図 4.2 (2) の散布図 ($R^2=0.6144$)




図 4.3 (3) の散布図 ($R^2=0.5831$)




図 4.4 (4) の散布図 ($R^2=0.5587$)

4.1 年齢推定の結果




図 4.5 (5) の散布図 ($R^2=0.6369$)




図 4.6 (6) の散布図 ($R^2=0.3564$)




図 4.7 (i) の散布図 ($R^2=0.6472$)




図 4.8 (ii) の散布図 ($R^2=0.6391$)




図 4.9 (iii) の散布図 ($R^2=0.4702$)




図 4.10 (iv) の散布図 ($R^2=0.7238$)

4.1 年齢推定の結果




図 4.11 (v) の散布図 ($R^2=0.7504$)




図 4.12 (vi) の散布図 ($R^2=0.7256$)

4.1.2 48 領域に分割された脳部位を用いた年齢推定の結果

表 4.2 には Harvard-Oxford atlas により 48 領域に分割された脳部位を用いた推定において、精度が高い上位 5 つの R^2 と部位のボクセル数を示している。推定結果は縁上回 (後部), 前頭極, 海馬傍回 (後部), 下前頭回 (弁蓋部), 側頭平面などがより高い精度となった。

表 4.2 部位ごとの年齢推定精度 (R^2) とボクセル数

	SGpd* ¹	FP* ²	PGpd* ³	IFGpo* ⁴	PT* ⁵
R^2	0.4145	0.4144	0.3802	0.3662	0.3403
Voxel	14829	33571	4116	8301	7763

(*1: 縁上回 (後部), *2: 前頭極, *3: 海馬傍回 (後部), *4: 下前頭回 (弁蓋部), *5: 側頭平面)

4.2 BMI 推定の結果

(1)～(6) と (i)～(vi) を用いた 3D-CNN による BMI 推定の結果を表 4.3 に示す．結果を比較すると，(1) から (2) に脳抽出を行った場合，精度の低下が見られた．また (3) の結果から，脳以外を用いた推定が比較的高い精度となった．(i)～(vi) の結果から標準空間に位置合わせを行った場合の結果も同様に脳部分と比較して脳以外が高い推定精度となった．図 4.13～図 4.24 は (1)～(6) と (i)～(vi) の各実験の 5 分割交差検証において，平均値との差が最も小さい結果となる Fold の散布図である．

表 4.3 BMI の推定精度 (R^2)

(1)	(2)	(3)	(4)	(5)	(6)
0.454	- 0.304	0.374	- 0.0488	- 0.0440	- 0.0947
(i)	(ii)	(iii)	(iv)	(v)	(vi)
0.281	- 0.0758	0.287	0.146	0.115	0.0511

4.2 BMI 推定の結果




図 4.13 (1) の散布図 ($R^2=0.464$)




図 4.14 (2) の散布図 ($R^2=-0.243$)




図 4.15 (3) の散布図 ($R^2=0.383$)




図 4.16 (4) の散布図 ($R^2=-0.0180$)




図 4.17 (5) の散布図 ($R^2=-0.0467$)




図 4.18 (6) の散布図 ($R^2=-0.116$)

4.2 BMI 推定の結果




図 4.19 (i) の散布図 ($R^2=0.273$)




図 4.20 (ii) の散布図 ($R^2=-0.397$)




図 4.21 (iii) の散布図 ($R^2=0.282$)




図 4.22 (iv) の散布図 ($R^2=0.145$)




図 4.23 (v) の散布図 ($R^2=0.119$)




図 4.24 (vi) の散布図 ($R^2=0.0701$)

第 5 章

考察

この章では、各推定実験から得られた結果をもとに、推定に影響を与えた部位や要因の考察を行う。

5.1 年齢推定に関する考察

年齢推定に関して、前章に示した表 4.1 の (1) から (2) に変換した結果精度の低下があまり見られないことから、脳部分が大きく推定に寄与していると考えられる。標準空間への位置合わせを行うことで被験者ごとに異なる脳の大きさが統一されるが、(i) と (ii) の結果が示すように、標準空間上の脳画像を用いた推定の精度も高いことから、脳の大きさは年齢推定を行う上で重要な要素ではないと言える。また (1) から (3) へと脳以外の抽出を行った場合の精度変化は、(1) から (2) へと脳抽出した場合と類似して、あまり大きな精度低下は見られず、脳以外にも年齢推定に寄与する情報があると考えられる。しかし標準空間上の脳以外の部分である (iii) は (3) と比較して精度が低く、個人空間である (3) は脳以外の顔、頭蓋、咽頭、口腔、鼻腔などの部分で年齢推定に寄与する情報があるが、標準空間へ位置合わせを行うことでそれらの部分の寄与が低下することが考えられる。また (5) と (v) の推定精度は比較的高精度な結果が得られた。これら (5) と (v) は脳部分である (2) と (ii) の推定精度を上回る精度であることから、灰白質を抽出することで、年齢推定において不要な情報が削ぎ落とされ、精度が向上したと考えられるため、脳内において灰白質に、より重要な情報があることが考えられる。脳脊髄液と白質も標準空間に位置合わせを行った場合は (iv) と (vi) の結果から高い精度が得られた。個人空間である (4) と (6) の結果は (iv) と (vi) と比

5.2 BMI 推定に関する考察

較して低いが、表 5.1 と表 5.2 が示すように 5 分割交差検証の結果、極端に精度が低い Fold があることが影響している。標準空間への位置合わせを行うことで、そのようなことがなくなり、灰白質と同様に高精度な結果が得られたことから、標準空間へ位置合わせが行われた脳の脳脊髄液、灰白質、白質の分布パターンが推定に寄与していると考えられる。

表 5.1 (4) を用いた年齢推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.6311	-0.006836	0.5587	0.5721	0.6332	0.4777

表 5.2 (6) を用いた年齢推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.5569	0.3564	-0.09211	0.7288	0.5872	0.4274

表 4.2 は、Harvard-Oxford atlas により 48 領域に分割された脳部位を用いた推定において精度が高い上位 5 つの結果を示しているが、推定結果は縁上回 (後部)、前頭極、海馬傍回 (後部)、下前頭回 (弁蓋部)、側頭平面などがより高い精度であった。機械学習に用いるボクセルの量が多いことが推定により優位に働く可能性が考えられる。そのため、推定精度が高いことが、より年齢と関連した部位であると断定することはできないが、各脳部位のボクセル数は 3088~33571 であり、ボクセル数が 4116 と少ない海馬傍回 (後部) など上位に挙げられたことから、ボクセルの量ではなく構造の違いが推定精度に影響を与えた部位を得ることができたと考えられる。また下前頭回 (弁蓋部) はブローカ野に位置し、ブローカ野は機能として言語要素の処理に関すると言われている。縁上回もまた言語要素の処理に関する機能を持つとされることから、加齢と言語能力の関係が脳構造に現れた可能性が考えられる。

5.2 BMI 推定に関する考察

BMI の推定に関して、表 4.3 の (3) の精度が高いことから脳以外が推定に寄与していると考えられる。(2),(4)~(6) は共通して脳部分であり、これらの精度が低いことから脳部

5.2 BMI 推定に関する考察

分ではなく脳以外の喉，皮下などの脂肪量が BMI 推定に影響していると考えられる．(i)～(vi) の結果から，標準空間に位置合わせをした場合でも同様であると考えられる．また先行研究 [1] では加齢や高血圧などの動脈硬化性疾患により生じた白質内の細胞外間隙である白質病変と BMI の関連が有意に示される結果が得られているが，本研究では個人空間上の白質 (6) と標準空間上の白質 (vi) を用いた推定の精度は共に低く、先行研究 [1] での白質 VBM 値の統計的検定では有意であったものの、本研究の CNN では BMI 値推定は困難であった．

第 6 章

結論

本研究では 3D-CNN による回帰モデルを用い、12 種類の前処理手法により得られた脳画像に対して年齢、BMI の推定を行い、それらの精度を比較することで推定に寄与する部位や要因の解析を行った。さらに年齢に関して、脳皮質を 48 領域に分割した部位ごとの脳画像を用いた推定を行い、その推定精度と各部位のボクセル数をもとに、推定に寄与した脳部位の考察を行った。年齢に関して、脳部分の構造が推定に寄与している結果が得られた。その中でも、灰白質により有用な情報が含まれていると考えられる結果が得られた。また本研究では脳の大きさは年齢推定においてあまり重要な要素でないという結果が得られ、それに加え、脳の構造で年齢推定が行える点から、CNN を用いる場合は標準空間に位置合わせを行った脳画像を用いることが望ましいと考えられる。また脳部分においても特に推定に寄与したと考えられる部位として縁上回 (後部)、前頭極、海馬傍回 (後部)、下前頭回 (弁蓋部)、側頭平面などが得られた。しかし各脳部位の大きさの違いから、学習、推定に用いるボクセル数が異なるため、本研究の実験手法では、部位ごとの寄与度に優劣をつける際、各部位に対し公平な評価ができていない可能性が残る。

BMI に関して、本研究の 3D-CNN を用いた脳画像からの推定においては、脳部分との関連は得られず、脳以外が推定に寄与しているという結果となった。しかし、より脳と BMI の関係を認識できる推定モデルが存在する可能性はあり、モデルの構成の改良など、今後の研究が必要である。

謝辞

本研究を進めるにあたり，ご多忙の中，真摯に指導してくださった高知工科大学情報学群の吉田真一教授に感謝いたします。そして本研究の副査を担当してくださった高知工科大学情報学群繁桝博昭教授，ならびに門田宏准教授にも感謝いたします。また大学生活，研究活動を進めていくにあたり，家族の支援によりさまざまな面で助けられました。私を支えてくれた家族にも感謝いたします。

参考文献

- [1] K. Park et al., “Cerebral White Matter Hyperintensity as a Healthcare Quotient,” *Journal of Clinical Medicine*, vol.8, 2019.
- [2] J.H.Cole et al., “Predicting brain age with deep learning from raw imaging data results in a reliable and heritable biomaker,” *NeuroImage*, Vol.163, 2017.
- [3] J. Ding et al., “Large Perivascular Spaces Visible on Magnetic Resonance Imaging, Cerebral Small Vessel Disease Progression, and Risk of Dementia,” *JAMA Neurol*, vol.74, 2017.
- [4] H. Baradaran et al., “Association between Carotid Plaque Features on CTA and Cerebrovascular Ischemia: A Systematic Review and Meta-Analysis,” *AJNR Am J Neuroradiol*, vol.38, 2017.
- [5] J. Staals et al., “Stroke subtype, vascular risk factors, and total MRI brain small-vessel disease burden,” *Neurology*, vol.83, 2014
- [6] J. Lin et al., “Multiple Factors Involved in the Pathogenesis of White Matter Lesions,” *Biomed Res Int*, 2017.
- [7] S. Debette, H.S. Markus, “The clinical importance of white matter hyperintensities on brain magnetic resonance imaging: Systematic review and meta-analysis,” *BMJ*, vol.341, 2010.
- [8] M.W. Woolrich, S. Jbabdi, B. Patenaude, M. Chappell, S. Makni, T. Behrens, C. Beckmann, M. Jenkinson, S.M. Smith. “Bayesian analysis of neuroimaging data in FSL,” *NeuroImage*, No.45.
- [9] P. McCarthy, Fsleyes, December, 2022.
- [10] Biomedical Image Analysis Group. IXI-Dataset.
- [11] Patenaude, B., Smith, S.M., Kennedy, D., and Jenkinson M. “A Bayesian Model of

参考文献

- Shape and Appearance for Subcortical Brain,” *NeuroImage*, 56(3):907-922, 2011.
- [12] M. Jenkinson and S.M. Smith. “A global optimisation method for robust affine registration of brain images,” *Medical Image Analysis*, 5(2):143-156, 2001.
- [13] M. Jenkinson, P.R. Bannister, J.M. Brady, and S.M. Smith. “Improved optimisation for the robust and accurate linear registration and motion correction of brain images,” *NeuroImage*, 17(2):825-841, 2002.
- [14] 吉田 翔真, “MRI 脳画像からの深層学習による年齢推定モデルの精度向上,” 高知工科大学学士学位論文, 2021.
- [15] M. Lin et al. “NetWork In Network,” 2nd International Conference on Learning Representations, 2014.

付録 A

A.1 12 種類の脳画像を用いた年齢推定の結果

A.1.1 (1) を用いた年齢推定の結果

表 A.1 (1) を用いた年齢推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.7191	0.6670	0.7126	0.7459	0.6177	0.6925

A.1.2 (2) を用いた年齢推定の結果

表 A.2 (2) を用いた年齢推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.6144	0.4972	0.5263	0.7513	0.6610	0.6100

A.1.3 (3) を用いた年齢推定の結果

表 A.3 (3) を用いた年齢推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.5831	0.5619	0.6583	0.6470	0.5148	0.5930

A.1 12種類の脳画像を用いた年齢推定の結果

A.1.4 (4)を用いた年齢推定の結果

表 A.4 (4)を用いた年齢推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.6311	-0.006836	0.5587	0.5721	0.6332	0.4777

A.1.5 (5)を用いた年齢推定の結果

表 A.5 (5)を用いた年齢推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.7226	0.5331	0.6369	0.6018	0.7777	0.6544

A.1.6 (6)を用いた年齢推定の結果

表 A.6 (6)を用いた年齢推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.5569	0.3564	-0.09211	0.7288	0.5872	0.4274

A.1.7 (i)を用いた年齢推定の結果

表 A.7 (i)を用いた年齢推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.5993	0.7773	0.6472	0.7970	0.6308	0.6903

A.1.8 (ii)を用いた年齢推定の結果

表 A.8 (ii)を用いた年齢推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.6391	0.5816	0.5059	0.6966	0.6308	0.6256

A.1 12 種類の脳画像を用いた年齢推定の結果

A.1.9 (iii) を用いた年齢推定の結果

表 A.9 (iii) を用いた年齢推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.1768	0.4702	0.5441	0.6042	0.5043	0.4599

A.1.10 (iv) を用いた年齢推定の結果

表 A.10 (iv) を用いた年齢推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.7455	0.7321	0.7085	0.7064	0.7238	0.7233

A.1.11 (v) を用いた年齢推定の結果

表 A.11 (v) を用いた年齢推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.7348	0.7323	0.7625	0.7618	0.7504	0.7483

A.1.12 (vi) を用いた年齢推定の結果

表 A.12 (vi) を用いた年齢推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.7549	0.6637	0.7565	0.7654	0.7256	0.7332

A.2 BMI 推定の結果

A.2.1 (1) を用いた BMI 推定の結果

表 A.13 (1) を用いた BMI 推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.464	0.466	0.412	0.434	0.493	0.454

A.2.2 (2) を用いた BMI 推定の結果

表 A.14 (2) を用いた BMI 推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	-0.399	-0.243	-0.207	-0.137	-0.534	-0.304

A.2.3 (3) を用いた BMI 推定の結果

表 A.15 (3) を用いた BMI 推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.383	0.557	0.323	0.275	0.331	0.374

A.2.4 (4) を用いた BMI 推定の結果

表 A.16 (4) を用いた BMI 推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	-0.0180	0.0271	-0.115	0.0201	-0.158	-0.0488

A.2 BMI 推定の結果

A.2.5 (5) を用いた BMI 推定の結果

表 A.17 (5) を用いた BMI 推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	-0.0191	-0.0752	-0.00699	-0.0467	-0.0719	-0.0440

A.2.6 (6) を用いた BMI 推定の結果

表 A.18 (6) を用いた BMI 推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	-0.0666	-0.0325	-0.0701	-0.188	-0.116	-0.0947

A.2.7 (i) を用いた BMI 推定の結果

表 A.19 (i) を用いた BMI 推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.359	0.273	0.204	0.318	0.252	0.281

A.2.8 (ii) を用いた BMI 推定の結果

表 A.20 (ii) を用いた BMI 推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	-0.0381	0.118	-0.397	0.111	-0.174	-0.0758

A.2.9 (iii) を用いた BMI 推定の結果

表 A.21 (iii) を用いた BMI 推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.364	0.335	0.130	0.282	0.326	0.287

A.3 48 領域に分割された脳部位を用いた年齢推定の結果

A.2.10 (iv) を用いた BMI 推定の結果

表 A.22 (iv) を用いた BMI 推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.149	0.145	0.0786	0.121	0.236	0.146

A.2.11 (v) を用いた BMI 推定の結果

表 A.23 (v) を用いた BMI 推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.0864	0.156	0.0222	0.119	0.192	0.115

A.2.12 (vi) を用いた BMI 推定の結果

表 A.24 (vi) を用いた BMI 推定の精度 (R^2)

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	avg.
R^2	0.0190	0.110	-0.101	0.157	0.0701	0.0511

A.3 48 領域に分割された脳部位を用いた年齢推定の結果

表 A.25: 48 領域に分割された脳部位を用いた年齢推定の結果

脳領域	R^2	ボクセル数
Frontal Pole	0.4144	33571
Insular Cortex	0.2729	6591
Superior Frontal Gyrus	-0.2289	18946
Middle Frontal Gyrus	0.3079	18250

A.3 48 領域に分割された脳部位を用いた年齢推定の結果

Inferior Frontal Gyrus, pars triangularis	0.08933	7936
Inferior Frontal Gyrus, pars opercularis	0.3662	8301
Precentral Gyrus	-0.3742	29115
Temporal Pole	-0.0006789	11441
Superior Temporal Gyrus, anterior division	0.09045	4345
Superior Temporal Gyrus, posterior division	0.2470	10233
Middle Temporal Gyrus, anterior division	-0.2507	5175
Middle Temporal Gyrus, posterior division	0.06052	11420
Middle Temporal Gyrus, temporooccipital part	0.1210	9735
Inferior Temporal Gyrus, anterior division	-0.5053	5254
Inferior Temporal Gyrus, posterior division	-0.06196	10605
Inferior Temporal Gyrus, temporooccipital part	0.1388	7621
Postcentral Gyrus	0.1927	23716
Superior Parietal Lobule	0.3374	13186
Supramarginal Gyrus, anterior division	0.2591	10691
Supramarginal Gyrus, posterior division	0.4145	14829
Angular Gyrus	-0.1647	13689
Lateral Occipital Cortex, superior division	0.2477	27121
Lateral Occipital Cortex, inferior division	-0.0009446	17294
Intracalcarine Cortex	-0.06318	7134
Frontal Medial Cortex	-0.6258	4160
Juxtapositional Lobule Cortex	-0.1048	5970
Subcallosal Cortex	0.2521	3088
Paracingulate Gyrus	0.2665	9245
Cingulate Gyrus, anterior division	0.1455	9213
Cingulate Gyrus, posterior division	0.05546	10184

A.3 48 領域に分割された脳部位を用いた年齢推定の結果

Precuneous Cortex	0.3059	18119
Cuneal Cortex	-1.046	7889
Frontal Orbital Cortex	-0.2187	11223
Parahippocampal Gyrus, anterior division	0.2348	6083
Parahippocampal Gyrus, posterior division	0.3802	4116
Lingual Gyrus	-0.1951	13210
Temporal Fusiform Cortex, anterior division	-0.08465	4869
Temporal Fusiform Cortex, posterior division	0.006978	9701
Temporal Occipital Fusiform Cortex	0.2613	7485
Occipital Fusiform Gyrus	-2.466	10688
Frontal Operculum Cortex	-0.1678	4204
Central Opercular Cortex	0.2948	7686
Parietal Operculum Cortex	0.02520	6940
Planum Polare	-0.01104	4835
Heschl's Gyrus (includes H1 and H2)	0.02353	4267
Planum Temporale	0.3403	7763
Supracalcarine Cortex	-0.2040	6274
Occipital Pole	-0.1433	15486