

# 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

1255122 安岡 薫 【 知能情報学研究室 】

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

1255122 YASUOKA, Kaoru 【 Intelligent Informatics Lab. 】

### 1 はじめに

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。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多く存在する。先行研究[1]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)による年齢推定が行われており、決定係数 $R^2$ が0.92と高精度で推定されている。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、脳から推定できると報告[1][2]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。

### 2 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、二種類に大別される実験を行った。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。

#### 2.1 データセット

本研究ではIXIデータセットに含まれるT1強調画像を用いる。年齢、BMI推定のそれぞれのデータセットを以下に記述する。

##### 2.1.1 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213/女284)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。

##### 2.1.2 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216/女284)のT1強調画像である。このデータセットのBMIの幅は17.0~49.6となっている。

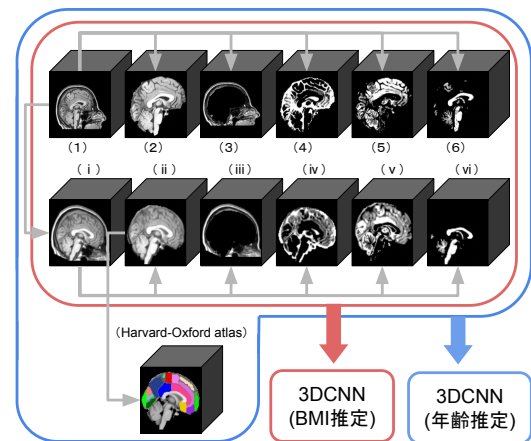


図1 前処理により得られた画像と各推定実験における使用関係

#### 2.2 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手法は脳画像に対し、向きの変更、トリミング、バイアス補正を行ったものを(1)とし、(1)を標準空間(MNI152)に線形レジストレーションしたものを(i)とする。それら(1),(i)から、脳部分、脳以外、脳脊髄液(CSF)、灰白質(GM)、白質(WM)の抽出を行ったものをそれぞれ(2)~(6),(ii)~(vi)とし、これら(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を用いて脳皮質を48領域に分割を行う。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1は上述の前処理手法により得られたデータセットと、各推定実験での使用関係を表している。

#### 2.3 実験手順

実験は、3D-CNNによる年齢、BMIの推定であり、上述の前処理により得られたデータセットを入力画像として用いる。データセットは学習データとテストデータにランダムに4:1の割合で分割し、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、5分割交差検証により行う。それにより得られた決定係数  $R^2$  の平均値を推定精度として用いる。また年齢推定においては、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 結果・考察

#### 3.1 年齢推定の結果・考察

年齢の推定結果を表1に示す。(1)から(2)に変換した結果精度の低下が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った場合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(iii)が(3)と比較して精度が低下した理由として、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、標準化するとそれらの部分の寄与が低下したことが考えられる。(5)と(v)の精度からGMの構造も年齢推定に大きく関連すると考えられる。CSFとWM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)と比較して低いが、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、標準化されたCSF、GM、WMの分布パターンが推定に寄与していると考えられる。

表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つの結果を示している。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。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)なども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おり、縁上回もまた言語要素の処理に関する機能を持つことから、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。

#### 3.2 BMI推定の結果・考察

BMIの推定結果を表3に示す。BMIの推定に関しては(3)の精度が高いことから脳以外が推定に寄与してい

表1 年齢の推定精度 ( $R^2$ )

(1)	(2)	(3)	(4)	(5)	(6)
0.692	0.610	0.593	0.478	0.654	0.427
(i)	(ii)	(iii)	(iv)	(v)	(vi)
0.690	0.625	0.459	0.723	0.748	0.733

表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
$R^2$	0.415	0.414	0.380	0.366	0.340
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)

表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

たとえられる。(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[2]では白質病変とBMIの関係が示唆されたが、本研究では白質を用いた推定の精度が低く、[2]と符号する結果は得られなかった。

### 4 おわりに

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年齢、BMIの推定を行い、さらに年齢に関して部位ごとの推定を行った。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。脳自体の大きさは年齢と無関係ではないが、性別と脳の大きさの関係という要因が交わることで推定に悪影響を及ぼす可能性も考えられるため、CNNを用いる場合は標準空間に位置合わせをし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を得ることができた。BMIに関して、脳以外が推定に寄与しているという結果が得られ、脳部分との関連を得ることができなかった。そのためモデルの構成の改良など、今後の研究が必要である。

### 参考文献

- [1] J.H.Cole et al. "Predicting brain age with deep learning from raw imaging data results in a reliable and heritable biomarker," *NeuroImage*, Vol.163, 2017.
- [2] Kaechang Park et al. "Cerebral White Matter Hyperintensity as a Healthcare Quotient," *Journal of Clinical Medicine*, vol. 8, 2019.