

令和 3 年度
修士学位論文

安静時 fMRI データからの機械学習 を用いた個人属性推定に関する研究

A Study on Prediction of Personal Attributes from
Resting-State fMRI Data Using Machine Learning

1245124 高橋慎也

指導教員 吉田真一

2022 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

安静時 fMRI データからの機械学習 を用いた個人属性推定に関する研究

高橋慎也

高齢者による自動車運転事故が増加が問題となっており、この問題の解決に対する脳科学的なアプローチとして、脳画像と高齢化や交通運転事故との関連を調べる研究が進められている。この活動の一環として期待されているのが、安静時 fMRI(rs-fMRI) を用いた認知機能の調査である。これに対し本研究では、rs-fMRI を用いた運転能力の調査を行うための前提研究として、個人属性の推定を機械学習を用いて行う。このための手法として、4次元データである rs-fMRI から機能的結合による特徴量の抽出を行う、特徴抽出のために、ROI-to-ROI 解析を用いた特徴ベクトルの生成、Seed-to-Voxel 解析を用いた SBC マップという 3 次元データの生成をそれぞれ行い、ロジスティック回帰モデル、3D-CNN モデルをそれぞれに適用することで推定精度の評価を行った。その結果、ロジスティック回帰モデルにおける精度が、性別は 74.2%、年齢は 61.3%の結果が得られ、3D-CNN モデルにおいては、性別は 77.4%、年齢は 64.5%の推定精度が得られた。また、ロジスティック回帰における偏回帰係数から調査された ROI の結果と、従来手法として 2 群間統計解析による ROI の結果を比較した結果、性別においては、もっとも偏回帰係数の絶対値が高かった FOrb(R)×pSTG(L) の組み合わせ等、多くが、どちらの結果にも同様の組み合わせが見られることに対し、年齢においては、偏回帰係数の絶対値が上位 10 組の ROI の組み合わせと、統計解析による結果では、同様の組み合わせが見られなかった。このことから、本研究での提案手法の有意性を示すとともに、従来手法には見られない新しい特徴を得ることができている可能性が示唆された。

キーワード Functional MRI, Resting state fMRI, Functional connectivity, Machine Learning

Abstract

A Study on Prediction of Personal Attributes from Resting-State fMRI Data Using Machine Learning

Shinya Takahashi

With the aging population in Japan, traffic accidents by elderly people have been seriously increasing. Some of studies tackle this problem as a neuroscientific approach. Relationship between brain MRI, aging, and traffic driving accidents has been studied. Resting-state functional MRI (rs-fMRI) is expected to find human cognitive function. In this study, we propose machine learning model which predict personal attributes from rs-fMRI data. We propose a feature extraction from the 4D rs-fMRI data by functional combination, to generate feature vectors using ROI to ROI analysis, and SBC maps using seed-to-voxel analysis as 3D data. The prediction accuracy is evaluated by applying the logistic regression model and the 3D-CNN model to each of them. As a result, the accuracy of the logistic regression model was 74.2% for gender and 61.3% for age, respectively and the accuracy of the 3D-CNN model was 77.4% for gender and 64.5% for age, respectively. Compared with the results of the ROI investigated using the partial regression coefficients in the logistic regression and the results of the ROI from the two-group statistical analysis as the conventional method, the ROI for gender is similar to the conventional method, but there is no common ROI for age. This indicates the significance of the proposed method in this study and suggests that it may be able to obtain new features not found in the conventional method.

key words functional MRI, Functional connectivity, Time Series Analysis,

目次

第 1 章	序論	1
第 2 章	関連研究	3
第 3 章	提案手法	4
第 4 章	実験	6
4.1	データセット	6
4.2	前処理	7
4.3	統計解析による機能的結合の取得	8
4.3.1	RRC 行列	9
4.3.2	SBC マップ	9
4.4	特徴抽出	9
4.5	機械学習	11
4.5.1	ロジスティック回帰	12
4.5.2	3D-CNN	12
4.6	精度評価 (ロジスティック回帰)	12
4.7	偏回帰係数による識別に関わる ROI の特定	12
4.8	精度評価 (3D-CNN)	13
4.9	統計解析との比較	14
第 5 章	結果	15
5.1	ロジスティック回帰による推定	15
5.2	正則化による偏回帰係数の削減	16
5.3	偏回帰係数による識別に関わる ROI の特定	17

目次

5.4	偏回帰係数により最も識別に用いられた ROI の組み合わせの特定	17
5.5	3D-CNN による推定	20
5.6	統計解析による結果	21
第 6 章	考察	23
6.1	ロジスティック回帰における推定精度について	23
6.2	3D-CNN を用いた推定精度について	23
6.3	ロジスティック回帰による結果と統計解析による結果について	24
第 7 章	結論	25
	謝辞	26
	参考文献	27

目次

4.1	性別の分布	6
4.2	年齢の分布	7
4.3	年齢 (クラスタリング後) の分布	8
4.4	SBC マップの例 (被験者 1, Frontal Pole(R) を seed としている)	10
4.5	特徴ベクトルの生成	11
4.6	データの分割について	13
4.7	3D-CNN のモデル	13
5.1	性別での L1 正則化による偏回帰係数	16
5.2	年齢での L1 正則化による偏回帰係数	17
5.3	男女の 2 群間比較の結果	21
5.4	75 歳未満, 75 歳以上の 2 群間比較の結果	22

第 1 章

序論

高齢者のアクセルの踏み間違いや、暴走などによる自動車運転事故が、現在社会問題となっている [1]。さらに日本においては、高齢化は年々進んでいくことから、このような事故は増えていくことが予測される。そこで、加齢による影響と交通事故との因果関係を解明し、加齢への影響を客観的に示し、運転免許の返納や、行政的な支援への基準とすることが期待されている。この問題に対する脳科学的なアプローチとして、MRI などの計測機器によって撮像された脳画像から、加齢や交通事故との関連を調べる研究が進められている。Park ら [2] の研究によると、加齢による脳の萎縮、白質病変と、安全運転のスコア (Driving Safety Performance) の低下に有意な相関が示された。このように、脳の構造画像と交通事故には関連がみられている。しかし、脳の機能画像と交通事故、認知能力との関連は未だに確認されていない。

脳の賦活部位を BOLD (Blood Oxygenation Level-Dependent) 信号として計測し、画像として撮影される fMRI [3] の中でも、安静時 fMRI (rs-fMRI) は、被験者にタスクなどを課さず、極力リラックスして何も考えないように指示して長時間 (5 ～ 10 分以上) 撮像を行う実験計画である [4]。発見初期には、タスク fMRI の結果と比較を行い、タスクに関連して賦活する部位を特定するために用いられていたが、現在では、安静時に有意に賦活する、デフォルトモードネットワーク (DMN) という領域が発見され、アルツハイマー病の罹患者はこの DMN の機能的結合が顕著に低下するなど、疾病や障害の調査に用いられるようになっている [5]。

また、fMRI を用いる脳画像解析において、解剖学的に離れている脳の領域同士での機能的なつながりのことを機能的結合 (Functional connectivity) といい、先に述べた安静時

ネットワークも、この機能的結合である。これを用いることで、タスク中に起こる機能的結合などを算出することで、タスク中に有意に繋がる脳の領域を特定することができる [6]。

Park らの研究による白質病変の容量解析 (VBM) による脳の構造的変化には表れない、加齢による機能的な変化を rs-fMRI データの違いとして見出すことを目的として、本研究では、rs-fMRI と運転能力との関連の調査に対する前提研究として、rs-fMRI から解析的に機能的結合を算出し、機械学習を用いた個人属性の推定を行う。

rs-fMRI から機能的結合を用いた特徴生成によって得られた特徴を、機械学習アルゴリズムを適用した結果、もっとも精度の高かったアルゴリズムでは性別では 77.4%、年齢は 64.5%の精度で推定することができたことから、rs-fMRI を用いた機械学習による個人属性の推定が可能であることを示した。

第 2 章

関連研究

Resting-state fMRI についての先行研究として, Edgar らの研究 [7] について述べる.

安静時 fMRI から, 解析によって機能的結合などの指標を算出し, ADHD や双極性障害などの精神疾患における指標の差異を調査することで, それらの患者と健常者との違いを見出すことができる. しかし, 現在の安静時 fMRI の解析手法においては, 個人の撮影時の状況 (血圧, 心拍数, 食事, 時間帯など) によって個人内の差異が大きく, 再現性が低い可能性があることがわかっている [8][9]. そのため, 疾患に対するバイオマーカーとしての信頼性は低いという点に問題がある. しかし, 個人間の違いにおいては, 強固な違いが認められることから, 個人の識別までできることが示されている [10]. そこで本研究では, 機械学習を用いることで, 個人属性を推定するとともに, 正則化をによる学習を行い, 新規データへの再現性を確保した推定を提案する.

第 3 章

提案手法

本章では、本実験における提案手法について述べる。

本研究では、機械学習を用いた rs-fMRI データからの個人属性の推定を提案する。rs-fMRI データを機械学習に用いるにあたり、問題点として、データのサイズの問題が挙げられる。rs-fMRI データは機能的 MRI を用いて撮影されているため、3 次元脳画像 × 時系列の 4 次元データとなる。このため、現在の 3 次元脳画像を数枚程度までしか学習できない計算資源では、4 次元データとして畳み込みニューラルネットワークなどによる学習は不可能である。そこで、rs-fMRI データを用いた機械学習を行うためには、4 次元データからの特徴選択を行う必要がある。そこで本研究では、rs-fMRI から、機能的結合を用いた特徴抽出を行う。機能的結合とは、rs-fMRI の解析に用いられる方法であり、被験者の 4 次元脳画像のある地点とその他のある地点との時系列的な関連性を数値化するものである。これは、主に統計解析などに用いられるが、この機能的結合を特徴ベクトルとして機械学習に用いることで、rs-fMRI の次元を圧縮し、現在の計算資源での機械学習を可能にし、個人属性の推定を行う。

機能的結合による特徴ベクトルの取り方は、

- ROI-to-ROI 解析

被験者の rs-fMRI から、複数の ROI 同士の相関行列を作成し、対称行列であるその行列から下三角成分だけを抜き出して特徴ベクトルとする

- Seed-to-Voxel 解析

被験者の rs-fMRI から、注目領域 (seed) ごとに seed と全てのボクセルとの相関をマッ

ピングした 3D 画像を特徴ベクトルとする

の 2 通り行う．本実験では，ROI-to-ROI 解析によって生成した特徴ベクトルを用いてロジスティック回帰モデルによる推定を行い，Seed-to-Voxel 解析による 3D 画像を用いて 3D-CNN による推定を行う．

第 4 章

実験

本章では，提案手法を用いた実験，解析の流れを示す．

4.1 データセット

本実験には，高知検診クリニックより提供を受けた 131 人の rs-fMRI データを用いる．データセットの性別，年齢の分布について，図 4.1，図 4.2 にそれぞれ示す．また，年齢については，分類タスクを行うために，運転免許の更新の際に認識機能検査が義務付けられる年齢である 75 歳以上を 0，75 歳未満を 1 の 2 値にクラスタリングを行った．その結果を図 4.3 に示す．




図 4.1 性別の分布

4.2 前処理




図 4.2 年齢の分布

4.2 前処理

本実験では、MATLAB 上で動作する脳画像の統計解析ソフトである SPM をベースとした、fMRI から機能的結合を解析するためのソフトである CONN toolbox を用いて前処理、解析を行う。以下に行った前処理での処理を示す。

1. Functional Realignment & unwarp

fMRI データは数スキャンにわたって撮像されるため、被験者の撮像中の動作などによる影響を受けている。そのため、この処理で動き等の補正を行う。

2. Functional Center to (0,0,0) coordinates

撮像中の姿勢などにより、中心からずれて撮像されている脳データを中心に補正する。

3. Functional Slice-timing correction

スライスごとに時間間隔を空けて撮像されたデータから、その時間間隔に応じた補正を行う。

4.3 統計解析による機能的結合の取得




図 4.3 年齢 (クラスタリング後) の分布

4. Functional Outlier detection

被験者の大きな動きによる外れ値を検出する.

5. Functional Direct Segmentation & Normalization

大きさ, 形状に個人差のある被験者の脳画像を MNI 標準脳に変換し, 白質, 灰白質, 脳髄液にセグメンテーションを行う.

6. Functional Smoothing

最後に, これまでの処理をして残ったノイズや, 個人差の影響を低減するために, ガウスカーネルを用いた畳み込み処理を行い, 脳画像を平滑化する.

4.3 統計解析による機能的結合の取得

本実験において, rs-fMRI から機械学習を行うために, 機能的結合を 2 つの方法で生成する.

4.4 特徴抽出

4.3.1 RRC 行列

被験者の rs-fMRI データから、164 の ROI に対して、それぞれ ROI-to-ROI での解析を行い、それぞれの機能的結合の値を記録した RRC(ROI-to-ROI Connectivity) 行列を次式のように生成する。この時、この行列のサイズは、 164×164 となる。

$$\mathbf{r}(i, j) = \frac{\int \mathbf{R}_i(t) \mathbf{R}_j(t) dt}{(\int \mathbf{R}_i^2(t) dt \int \mathbf{R}_j^2(t) dt)^{1/2}} \quad (4.1)$$

$$\mathbf{Z}(i, j) = \tanh^{-1}(\mathbf{r}(i, j)) \quad (4.2)$$

ここでの $\mathbf{R}_i(t)$ は、 i 番目の ROI の時系列値であり、 \mathbf{r} はそれを用いたピアソン相関の行列である。そして \mathbf{Z} は、 \mathbf{r} の各要素にフィッシャー変換 ($\tanh^{-1}(x)$) を適用した、各 ROI の組み合わせの間の RRC 行列である。

4.3.2 SBC マップ

被験者の rs-fMRI データから、Seed-to-Voxel での解析を行い、それぞれの機能的結合の値を記録した 3D 画像 (Seed-Based Connectivity maps:SBC マップ) を生成する。

$$\mathbf{r}(x) = \frac{\int \mathbf{S}(x, t) \mathbf{R}(t) dt}{(\int \mathbf{S}^2(x, t) dt \int \mathbf{R}^2(t) dt)^{1/2}} \quad (4.3)$$

$$\mathbf{Z}(x) = \tanh^{-1}(\mathbf{r}(x)) \quad (4.4)$$

ここでの $\mathbf{R}(t)$ は、Seed としている ROI の時系列値であり、 $\mathbf{r}(x)$ は座標 x における seed とのピアソン相関である。そして \mathbf{Z} は、 \mathbf{r} の各要素にフィッシャー変換 ($\tanh^{-1}(x)$) を適用した、Seed と全ボクセルの間の SBC マップである。SBC マップの例を、図 4.4 に示す。

4.4 特徴抽出

統計解析によって得られた RRC 行列から、ロジスティック回帰に用いる特徴ベクトルを生成する。図 4.5 のように、対称行列となっている RRC 行列の下三角行列を 1 列にリサ

4.4 特徴抽出




図 4.4 SBC マップの例 (被験者 1, Frontal Pole(R) を seed としている)

4.5 機械学習

イズすることで特徴ベクトルに変換する。この時、このベクトルは $164 \times 164/2 - 164/2 = 13366$ 次元となる。このベクトルを、RRC ベクトルとする。

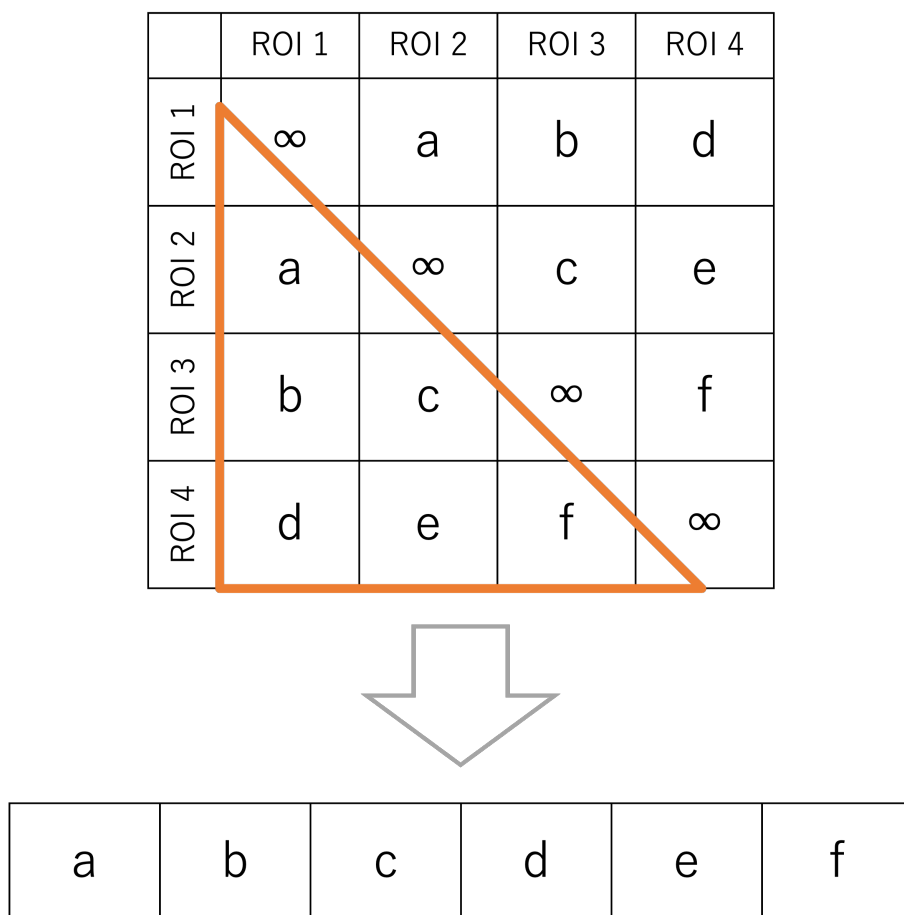


図 4.5 特徴ベクトルの生成

4.5 機械学習

ここまで作成した特徴データから機械学習モデルを用いて学習、精度評価を行う機械学習モデルには、ロジスティック回帰と 3 次元畳み込みニューラルネットワーク (3D-CNN) を用いる。実験の流れとして、まずロジスティック回帰を用いて RRC ベクトルから精度評価を行った後に、ロジスティック回帰の偏回帰係数から、分類に関わった ROI を特定する。その ROI を Seed とした SBC マップから 3D-CNN を用いて精度評価を行う。

4.6 精度評価 (ロジスティック回帰)

4.5.1 ロジスティック回帰

ロジスティック回帰モデルは、Python3.6 のライブラリ scikit-learn によって実装する。本実験では、正則化手法として L1 正則化、L2 正則化、正則化なしの 3 種類のモデルの比較を行い、正則化のあるモデルについては、正則化項の重みの逆数である C についてそれぞれ訓練データ内での層化抽出 k 分割交差検証法によってパラメータ探索を行い、最も良かったパラメータをそのモデルのパラメータとして採用する。

4.5.2 3D-CNN

3D-CNN は、Python3.6 のライブラリ、tensorflow.keras を用いて実装する。

4.6 精度評価 (ロジスティック回帰)

ロジスティック回帰を用いてクラスの予測を行い、精度評価を行う。本実験では精度評価のために、層化抽出した 31 個のデータをテストデータとし、残りの 100 個のデータを訓練データとする。また、訓練データ内での層化抽出 k 分割交差検証法によって最適なパラメータの探索を行う。その後、交差検証にて最も良かったパラメータを用いて訓練データでの学習を行い、テストデータのクラスを予測し、精度を算出する。(図 4.6)。

4.7 偏回帰係数による識別に関わる ROI の特定

ロジスティック回帰の学習の結果得られる偏回帰係数より、推定に関わった ROI を特定する。L1 正則化を用いるロジスティック回帰によってスパースになった偏回帰係数を、RRC 行列の形に再度マッピングする。そして行ごとに絶対値の総和を算出することで、ROI ごとのその ROI が関わった偏回帰係数の総和が算出できる。それにより、ロジスティック回帰における識別にもっとも用いられた ROI の目安を算出できる。

また、偏回帰係数の絶対値が高い値が得られた機能的結合がどの ROI と ROI の組み合わせ

4.8 精度評価 (3D-CNN)

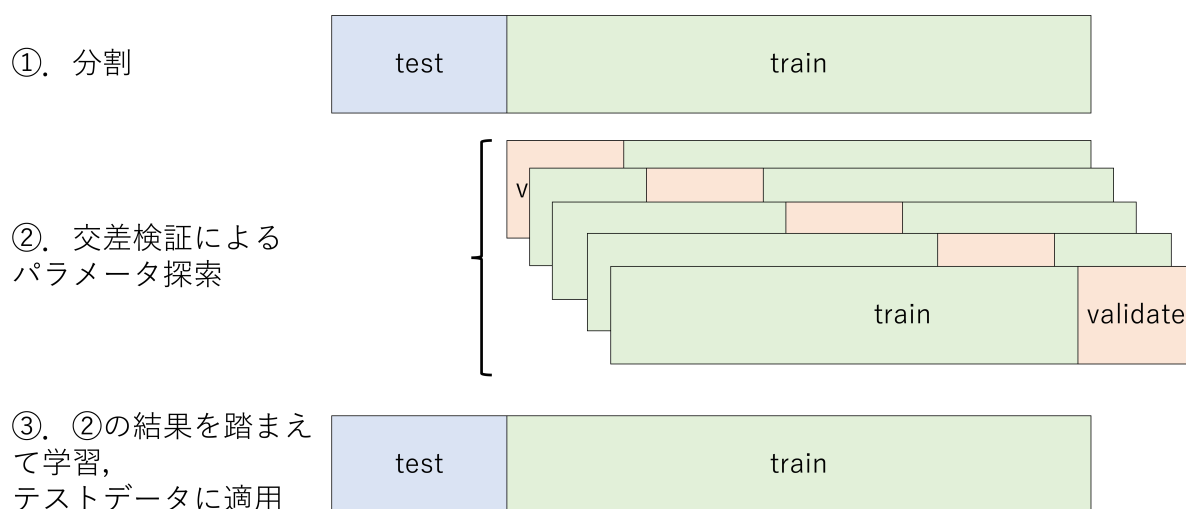


図 4.6 データの分割について

せの相関によるものかを調査する．それによって，最も識別に貢献した ROI と ROI の組み合わせを求めることができる．

4.8 精度評価 (3D-CNN)

手順 4.7 によって得られた ROI を Seed として，SBC マップから 3D-CNN を用いたクラスの予測を行い，精度評価を行う．これによって，脳機能局在性に基づいて，局所的な機能的結合のパターンによるクラスの分類を行い，検証する．

本実験で用いた 3D-CNN のモデルを図 4.7 に示す．




図 4.7 3D-CNN のモデル

4.9 統計解析との比較

手順 4.7 によって得られた ROI の結果と、既存手法として CONN を用いた集団解析によるグループ間比較の結果を比較し、提案手法の有用性についての検討を行う。

第 5 章

結果

本章では，本実験における結果を示す．

5.1 ロジスティック回帰による推定

ロジスティック回帰の 3 つのモデルによる性別，年齢の分類精度を表 5.1，表 5.2 にそれぞれ示す．性別，年齢どちらの分類においても，L1 正則化を用いたモデルが最も精度が高い結果となった．

表 5.1 ロジスティック回帰を用いた性別の推定精度

	L1 正則化	L2 正則化	正則化なし
性別推定精度	74.2%	71.0%	61.3%
パラメータ (C)	10^2	10	-

表 5.2 ロジスティック回帰を用いた年齢の推定精度

	L1 正則化	L2 正則化	正則化なし
年齢推定精度	61.3%	54.8%	51.6%
パラメータ (C)	10^5	0.1	-

5.2 正則化による偏回帰係数の削減

ロジスティック回帰の L1 正則化での偏回帰係数を昇順に並べ替えたものを図 5.1, 図 5.2 にそれぞれ示す. 性別ではおよそ 98%, 年齢ではおよそ 73%の偏回帰係数を削減している.




図 5.1 性別での L1 正則化による偏回帰係数

5.3 偏回帰係数による識別に関わる ROI の特定




図 5.2 年齢での L1 正則化による偏回帰係数

5.3 偏回帰係数による識別に関わる ROI の特定

また、最も高い精度が得られたロジスティック回帰の L1 正則化を用いたモデルの偏回帰係数の絶対値の総和をスコアとし、識別に用いられた ROI の上位 10 個を、性別、年齢それぞれ表 5.3、表 5.4 に示す。

5.4 偏回帰係数により最も識別に用いられた ROI の組み合わせの特定

L1 正則化による偏回帰係数の絶対値を参照し、推定に用いられた ROI についての結果を表 5.5、表 5.6 に性別、年齢についてそれぞれ示す。

5.4 偏回帰係数により最も識別に用いられた ROI の組み合わせの特定

表 5.3 性別の推定に用いられた ROI

	ROI の名前	スコア
1	atlas.pMTG r (Middle Temporal Gyrus, posterior division Right)	9.26
2	atlas.Caudate r	6.66
3	atlas.FOrb r (Frontal Orbital Cortex Right)	6.39
4	atlas.toMTG l (Middle Temporal Gyrus, temporooccipital part Left)	5.67
5	atlas.Thalamus r	4.48
6	atlas.pSTG l (Superior Temporal Gyrus, posterior division Left)	4.39
7	networks.Salience.RPFC (R) (32,46,27)	4.25
8	networks.Cerebellar.Posterior (0,-79,-32)	4.14
9	atlas.toITG r (Inferior Temporal Gyrus, temporooccipital part Right)	3.65
10	atlas.PO l (Parietal Operculum Cortex Left)	3.65

表 5.4 年齢の推定に用いられた ROI

順位	ROI の名前	スコア
1	atlas.Ver10 (Vermis 10)	12.4
2	atlas.Brain-Stem	11.1
3	atlas.sLOC r (Lateral Occipital Cortex, superior division Right)	9.85
4	networks.DefaultMode.LP (R) (47,-67,29)	9.67
5	atlas.Amygdala l	9.3
6	atlas.AC (Cingulate Gyrus, anterior division)	9.26
7	atlas.Cereb3 r (Cerebellum 3 Right)	9.17
8	atlas.FP l (Frontal Pole Left)	9.17
9	atlas.aPaHC r (Parahippocampal Gyrus, anterior division Right)	9.13
10	atlas.pPaHC r (Parahippocampal Gyrus, posterior division Right)	8.9

5.4 偏回帰係数により最も識別に用いられた ROI の組み合わせの特定

表 5.5 性別の推定に用いられた ROI の組み合わせ

順位	1 つめの ROI	2 つめの ROI	スコア
1	atlas.FOrb r	atlas.pSTG l	-2.8
2	atlas.PO l	atlas.pMTG r	-2.37
3	atlas.OP r	atlas.pMTG r	2.37
4	networks.Salience.ACC	atlas.Thalamus l	2.12
5	networks.Cerebellar.Posterior	atlas.Ver10	-1.83
6	atlas.Cereb9 r	atlas.pTFusC l	-1.8
7	networks.SensoriMotor.Lateral (R)	atlas.toITG r	-1.7
8	atlas.Caudate r	atlas.aITG r	1.64
9	atlas.Caudate r	atlas.SFG r	1.61
10	networks.FrontoParietal.LPFC (L)	networks.Salience.RPFC (R)	1.56

表 5.6 年齢の推定に用いられた ROI の組み合わせ

順位	1 つめの ROI	2 つめの ROI	スコア
1	atlas.Ver10	atlas.Caudate r	-2.91
2	atlas.pPaHC r	atlas.FP l	2.58
3	atlas.Brain-Stem	atlas.OP r	2.3
4	atlas.FO r	atlas.OFusG r	-2.29
5	atlas.Cereb6 r	atlas.Pallidum l	2.14
6	atlas.Cereb3 r	atlas.toMTG l	1.92
7	atlas.aPaHC r	atlas.sLOC r	1.85
8	atlas.Cereb6 l	atlas.MedFC	-1.84
9	atlas.Cereb7 r	atlas.iLOC l	-1.84
10	networks.SensoriMotor.Lateral (L)	atlas.Brain-Stem	-1.7

5.5 3D-CNN による推定

ロジスティック回帰の偏回帰係数によって得られた ROI を seed とした SBC マップを用いて 3D-CNN によって学習させた結果を、表 5.7, 表 5.8 にそれぞれ示す.

表 5.7 性別の推定に関わる偏回帰係数の絶対値の総和が高い ROI と CNN の精度

	pMTG(R)	Caudate(R)	FOrb(R)
精度 (CNN)	48.4%	77.4%	71.0%

表 5.8 年齢の推定に関わる偏回帰係数の絶対値の総和が高い ROI と CNN の精度

	Vermis 10	Brain-Stem	sLOC(R)
精度 (CNN)	54.8%	54.8%	64.5%

ここで seed とした 6 つの ROI について以下に示す.

- pMTG(Middle temporal gyrus): 中側頭回
物体視覚に関わる部位
- Caudate: 尾状核
学習や記憶において重要な役割を担う, 恋愛などの際には優位に賦活する.
- FOrb(Frontal orbital cortex): 前頭眼窩野
情動・動機づけやヒューリスティックな意思決定に関わっている.
- Vermis 10: 小脳虫部第 X 小葉
反射的眼球運動, 前庭反射としての姿勢などの制御に関わる.
- Brain-stem: 脳幹
呼吸や心拍などの生命維持に関わる不随意運動を司る部位.
- sLOC(lateral occipital cortex, superior division): 外側後頭葉の上部
視覚野の一部, 視覚情報による空間形成や色, 運動の識別に関わる.

5.6 統計解析による結果

Figure 1 illustrates the brain network diagram showing ROI-to-ROI effects. The central circular diagram displays a dense network of connections between 100 brain regions, color-coded by ROI-to-ROI effects from -5.50 (blue) to 5.50 (red). Surrounding the central diagram are 12 brain slices (axial, sagittal, and coronal views) showing the spatial distribution of these effects. A color bar at the top indicates the scale from -5.50 to 5.50.

– 21 –

5.6 統計解析による結果




図 5.4 75 歳未満, 75 歳以上の 2 群間比較の結果

第 6 章

考察

この章では、本実験によって得られた結果について考察し、提案手法の有用性について述べる。

6.1 ロジスティック回帰における推定精度について

ロジスティック回帰を用いて個人属性の分類を行った結果、性別、年齢の両条件において最も高い推定精度が得られたのは、性別を 74.2%、年齢を 61.3%の精度で推定できた、L1 正則化を行うモデルであった。これは、提案手法において入力される特徴ベクトルが 13366 次元と大きいものであったことから、学習・推定には不要な説明変数が多い可能性が考えられる。それに対して L1 正則化を用いることで、性別ではおよそ 98%、年齢ではおよそ 78% の次元を削減できており、これによって推定に有用な説明変数だけを残すことで高い精度が得られたためだと考えられる。

6.2 3D-CNN を用いた推定精度について

ロジスティック回帰によって算出された偏回帰係数によって得られた、特に関わる偏回帰係数の総和が高かった 3 つの ROI を seed とした SBC マップを用いてそれぞれ 3D-CNN による学習、推定を行ったところ、性別においては 77.4%、年齢においては 64.5%の推定精度を得ることができた。これはいずれにおいてもロジスティック回帰を用いた結果より高い結果となっており、ロジスティック回帰を用いた ROI の選択によるさらなる推定精度の向上が見込まれる結果となった。

6.3 ロジスティック回帰による結果と統計解析による結果について

また、3D-CNN を用いた結果の中で、最も精度の高かった SBC マップの seed は、性別・年齢どちらにおいてもその個人属性との関連があるとされている部位であることから、個人属性と関わりがあるとされる部位においては、単純な脳の機能局在性だけでなく、相関による機能的結合をマッピングした画像にも識別に関わる情報が保持されている可能性が示していると考えている。また、その他の seed では推定精度がチャンスレベルを下回っていたことから、従来までの手法では、未だ見つかっていないような、局所的な特徴によらない機能的結合をロジスティック回帰を用いることで算出できている可能性が考えられる。

6.3 ロジスティック回帰による結果と統計解析による結果について

ロジスティック回帰による偏回帰係数によって求められた、推定に用いられた ROI の組み合わせと、統計解析による 2 群間比較によって求められた、対照群と比較して有意に結合が見られる ROI の組み合わせを比較する。性別においては、もっとも偏回帰係数の絶対値が高かった FOrb(R)×pSTG(L) の組み合わせ等、多くが、どちらの結果にも同様の組み合わせが見られることから、性別の推定において、ロジスティック回帰を用いることの有意性が示された。一方、年齢の推定を行った結果では、偏回帰係数の絶対値が上位 10 組の ROI の組み合わせと、統計解析による結果では、同様の組み合わせが見られない。これは、年齢の推定精度が高くはないことから、年齢においては有用な特徴を選択できていない可能性が考えられる。しかし、今後データの増加等の影響により推定精度が向上した際にも、ROI の結果がこのままである場合、既存の手法による機能的結合ではない新しい特徴が選択できている可能性が考えられる。

第 7 章

結論

本研究では、安静時 fMRI(rs-fMRI) を用いて個人属性を推定する手法についての提案を行った。

rs-fMRI データから機械学習により個人属性を推定するために、機能的結合を用いた特徴データの生成を行った。ROI-to-ROI 解析による特徴ベクトルを用いたロジスティック回帰による個人属性の推定では、L1 正則化を行うモデルが最も性能が良く、推定精度が、性別では 74.2%、年齢では 61.3%という結果が得られた。このことから、rs-fMRI データを用いるロジスティック回帰による個人属性の推定の有用性が示された。

また、ロジスティック回帰によって得られた偏回帰係数から推定に用いられた ROI を特定し、それを seed とした SBC(Seed-based Connectivity) マップを用いた 3D-CNN による個人属性の推定においては、性別では 77.4%、年齢では 64.5%の推定精度が得られた。このことから、脳の機能的結合においても、機能局在性が示唆され、3D-CNN の個人属性の推定において有効であることが示された。

ロジスティック回帰の偏回帰係数による推定に用いられた ROI と、2 群間比較統計解析における結果を比較することで、性別の推定における、ロジスティック回帰の有用性を示したとともに、年齢の推定における、統計解析などでは判明しない未知の機能的結合が示唆された。

将来への展望として、本研究において、年齢を推定するためにクラスとして年齢による分割を行った際、データの量の問題から最頻値の付近で分割することになり、それが推定精度の向上の妨げになった可能性が考えられる。このことから、年齢の分布が一様であるデータセットを用いることで、より正確な推定精度の検証を行うことができると考えられる。

謝辞

本研究に際しまして、高知工科大学情報学群 吉田真一教授には心よりの感謝を申し上げます。吉田先生の研究室でなければ、きっと無事に卒業することは出来なかったと思います。優しくご指導いただき本当にありがとうございました。

四宮友貴助教には、真面目な研究の相談であったりくだらない僕達の雑談にもお付き合い頂き、誠にありがとうございました。四宮先生のおかげで更によりよい研究ができました。

また、本研究の副査をお受け頂きました高知工科大学情報学群 岩田誠教授、並びに中原 潔教授からは、研究に対するアドバイスを多角的な知見から頂き、そのおかげでより良い研究になったと思います。深く感謝いたします。

本研究に貴重なデータを提供頂きました、高知検診クリニック・高知工科大学客員教授 朴 啓彰博士に感謝いたします。

4年という長い間、ともに研究室活動を過ごしてきた研究室の同期の方々にも感謝を申し上げます。私にご迷惑をかけることも多々あったと思いますが、もう卒業するので時効です。一緒に社会人生活を頑張っていきましょう。

また、研究室の後輩方にも、研究のサポートや日々の生活のお手伝いをいただきましてありがとうございました。そのおかげで楽しい学生生活を送ることができました。僕を半面教師として頑張って研究に励んでください。

最後にはなりますが、今まで24年間の僕の生活を支えていただいた両親にも深く感謝を述べさせていただきます。

参考文献

- [1] 警視庁, “平成 29 年中の交通事故の発生状況,” 2018.
- [2] Kaechang Park, Kazumi Renge, Yoshinori Nakagawa, Fumio Yamashita, Masahiro Tada, and Yasuhiko Kumagai. “Aging brains degrade driving safety performances of the healthy elderly,” *Frontiers in Aging Neuroscience*, Vol. 13, 2022.
- [3] S. Ogawa, T. M. Lee, A. R. Kay, and D. W. Tank, “Brain magnetic resonance imaging with contrast dependent on blood oxygenation,” *Proceedings of the National Academy of Sciences*, Vol. 87, No. 24, pp. 9868–9872, 1990.
- [4] V. M. Haughton, J. S. Hyde, B. Biswal and F. Z. Yetkin, “Functional connectivity in the motor cortex of resting human brain using echo-planar mri,” *Magn Reson Med*, Vol. 34, No. 4, pp. 537–541, 1995.
- [5] 小野田圭一, 山口修平, “安静時 fmri の臨床応用のための基礎と展望,” 日本老年医学学会誌 Vol.52, No.1, pp.12–17, 2015.
- [6] Michelle Hampson, Naomi Driesen, Jennifer K. Roth, John C. Gore, and R. Todd Constable, “Functional connectivity between task-positive and task-negative brain areas and its relation to working memory performance,” *Magnetic Resonance Imaging*, Vol. 28, No. 8, pp. 1051–1057, 2010.
- [7] Edgar Canario, Donna Chen, and Bharat Biswal, “A review of resting-state fMRI and its use to examine psychiatric disorders,” *Psychoradiology*, Vol. 1, No. 1, pp. 42–53, 2021.
- [8] Bing Chen, Ting Xu, Changle Zhou, Luoyu Wang, Ning Yang, Ze Wang, Hao-Ming , Zhi Yang, Yu-Feng Zang, Xi-Nian Zuo and Xu-Chu Weng, “Individual variability and test-retest reliability revealed by ten repeated resting-state brain scans over one month,” *PLoS One*, Vol. 10, No. 12, pp. 537–541, 2015.

参考文献

- [9] Karsten Specht, “Current challenges in translational and clinical fmri and future directions,” *Frontiers in Psychiatry*, Vol. 10, 2020.
- [10] Emily S. Finn, Xilin Shen, Dustin Scheinost, Monica D. Rosenberg, Jessica Huang, Marvin M. Chun, Xenophon Papademetris and R. Todd Constable, “Functional connectome fingerprinting: identifying individuals using patterns of brain connectivity,” *Nature Neuroscience*, Vol. 18, 2015.