

令和3年度
修士学位論文

3D-CNNを用いた拡散テンソル画像から の個人属性推定に関する研究

A Study on Personal Attribute Prediction from
Diffusion Tensor Image Data Using 3D-CNN

1245133 新田 雄一郎

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

3D-CNN を用いた拡散テンソル画像からの個人属性推定に関する研究

新田 雄一郎

本研究では脳 MRI 構造画像のうち、拡散テンソル画像 (DTI) に対して機械学習を用いた個人属性推定モデルを提案する。DTI は、各ボクセルが多数の方向成分として拡散の大きさを持ち T1, T2 強調画像と比較して多くの情報を含んでいる。しかし、T1 強調画像などの MRI 脳構造画像では、3次元畳み込みニューラルネットワーク (3D-CNN) を用いた研究が行われているが、DTI は 4次元構造を持つ画像であり、3D-CNN に直接入力できない他、仮に入力できたとしても畳み込み演算で有効な特徴量が抽出できるか明らかでないこともあり、機械学習での研究はあまり行われていない。そこで本研究では、DTI による個人属性推定能力を明らかにすることを目的に各拡散方向成分画像を独立したチャンネルに入れるモデルに加え、DTI の拡散異方性画像を CNN に入力するモデル、トラクトグラフィーを算出し、その統計値を機械学習を用いて推定するモデルを提案する。拡散異方性 (固有値・固有ベクトル) は拡散成分を要約しており、トラクトグラフィーは拡散異方性が作る大域的なネットワーク構造であり、それぞれの特徴抽出にあたりと考える。DTI では脳の大きさについての標準化に考慮すべき点が多いため、脳の大きさのみの情報を持つ脳領域抽出用 Mask 画像との比較をしている。実験結果より、拡散異方性画像において Mask 画像より 5 ポイント程度高い識別率となり、拡散異方性において性別・年齢の情報があると考えられる。また、トラクトグラフィー統計値の結果では特定の ROI において拡散異方性画像を用いた結果と同等程度の識別率を示している。これは、トラクトグラフィーが識別のための特徴量となりうること、またそれと同

等の特徴量は拡散異方性画像からの CNN でも得られている可能性を示している。さらにトラクトグラフィー化後は CNN を使う必要がなく、学習コストを大きく削減できることが分かった。

キーワード 拡散テンソル画像, トラクトグラフィー, 3D-CNN, SVM, ロジスティック回帰

Abstract

A Study on Personal Attribute Prediction from Diffusion Tensor Image Data Using 3D-CNN

Yuichiro NITTA

In this study, we propose a model for estimating personal attributes using machine learning for MRI diffusion tensor images (DTIs) of brain. In DTIs, each voxel has the magnitude of diffusion as many directional components and contains more information than T1- and T2-weighted images. However, while 3D convolutional neural networks (3D-CNNs) have been used to study MRI brain structure images such as T1-weighted images, DTIs cannot be directly input to 3D-CNNs because they are 4D data, and thus have not been studied in machine learning. In this study, we propose a model that inputs the diffusion anisotropic image of DTI to a CNN, and a model which learns the graph-statistical information from the tractography, in addition to in addition to a model that inputs each diffusion direction image directly into an independent channel, in order to clarify the ability of DTI to estimate personal attributes.

The experimental results show that the prediction accuracy of the diffusion anisotropic image is about 5 points higher than that of the Mask image, suggesting that the diffusion anisotropic contains information about gender and age. In addition, the results of tractography statistics show that the prediction accuracy of specific ROIs is comparable to that of diffusion anisotropy images, indicating the possibility of reducing the learning cost by focusing on ROIs.

key words Diffusion tensor image, Tractography, 3D-CNN, SVM, Logistic Re-

gression

目次

第 1 章	序論	1
1.1	研究背景	1
1.2	研究目的	1
第 2 章	拡散テンソル画像	3
2.1	拡散テンソル画像	3
2.2	白質の拡散現象	4
2.2.1	拡散の異方性	4
2.2.2	拡散テンソル	4
2.3	トラクトグラフィ	6
第 3 章	機械学習手法	8
3.1	3D-Convolutional Neural Network(3D-CNN)	8
3.1.1	CNN の基本構造	9
3.1.2	チャンネル	9
3.2	Support Vector Machine(SVM)	10
3.3	Logistic Regression(ロジスティック回帰)	10
3.4	機械学習モデルの評価	11
3.4.1	混同行列	11
3.4.2	K-分割交差検証法	11
第 4 章	モデルの提案	13
4.1	提案手法	13
第 5 章	前処理	15

目次

5.1	FSL	15
5.2	DSI-studio	16
第 6 章	実験	24
6.1	識別する属性	24
6.2	データセット	24
6.3	実験環境	25
6.4	標準化	25
6.5	3D-CNN を用いたモデル (a)・モデル (b)	25
6.6	SVM・ロジスティック回帰を用いたモデル (c)	26
第 7 章	結果	29
7.1	3D-CNN を用いたモデル (a)・モデル (b)	29
7.2	SVM・ロジスティック回帰を用いたモデル (c)	30
第 8 章	考察	35
8.1	3D-CNN を用いたモデル (a)・モデル (b)	35
8.2	SVM・ロジスティック回帰を用いたモデル (c)	36
8.3	学習コスト	36
8.4	トラクトグラフィー	37
第 9 章	結論	38
	謝辞	39
	参考文献	40

目次

2.1	1 被験者の DTI データ	4
2.2	左右方向に走行する神経繊維における水分子の拡散	5
2.3	水槽の中の水分子の拡散	5
2.4	ボクセルにおいて連続する拡散異方性	6
2.5	トラクトグラフィ画像の例	7
3.1	3D-CCN の基本構造	9
3.2	交差検証法	12
4.1	提案する 3 つの識別モデルのデータフロー	14
5.1	DTI 画像	16
5.2	Mask 画像	16
5.3	FA 画像	16
5.4	Tensor 画像	16
5.5	各固有値画像	17
5.6	各固有ベクトル画像	17
6.1	男女比率	26
6.2	年齢分布	27
6.3	年齢における男女比率	27
6.4	3DCNN モデル	28
7.1	年齢における 5 分割交差検証法の平均・標準偏差	30
7.2	性別における 5 分割交差検証法の平均・標準偏差	31

表目次

3.1	混同行列	11
5.1	FSL 実行環境	18
5.2	DSI-studio 実行パラメータ	18
5.3	DSI-studio 実行環境	19
5.4	DSI-studio 実行環境	19
5.5	DSI-studio によって出力される stat.txt に含まれる情報	20
5.6	DSI-studio によって分けられる関心領域 (ROI)	21
6.1	各モデルのシミュレーション実行環境	28
7.1	年齢・性別における 5 分割交差検証法の平均・標準偏差	29
7.2	標準化した年齢・性別における 5 分割交差検証法の平均・標準偏差	30
7.3	年齢の平均識別精度 (%) が高かった上位 5 部位と該当部位でトラクトグラフィ ャーが算出された被験者数 (N)	32
7.4	性別の平均識別精度 (%) が高かった上位 4 部位と該当部位でトラクトグラフィ ャーが算出された被験者数 (N)	33
7.5	年齢・性別の平均識別精度 (%) が高かった上位 5 部位における標準化偏 回帰係数	34

第 1 章

序論

1.1 研究背景

医用画像認識は、病変の検出や認識を目的として発展し、近年は機械学習やニューラルネットワークを使ったものも多い。病変の検出のみでなく、健常者の状態や属性 [1][2]、特性 [3][4]、将来の病気の予測などへの活用も試みられている。取り掛かりとして、本研究では脳 MRI 構造画像のうち、拡散テンソル画像 (DTI) に対して機械学習を用いた個人属性推定について識別器の性能を比較する。DTI は、各ボクセルが多数の方向成分として拡散の大きさを持ち T1、T2 強調画像と比較して多くの情報を含んでいる [5]。しかし、T1 強調画像などの MRI 脳構造画像では、3次元畳み込みニューラルネットワーク (3D-Convolutional Neural Network:3D-CNN) を用いた研究が行われているが、DTI は 4次元構造を持つ画像であり、3D-CNN に直接入力できない他、仮に入力できたとしても畳み込み演算で有効な特徴量が抽出できるか明らかでないこともあり、機械学習での研究はあまり行われていない。

1.2 研究目的

本研究では、DTI による個人属性推定能力を明らかにすることを目的に DTI の拡散方向画像・拡散異方性画像・トラクトグラフィ統計値における機械学習を用いた推定結果を比較する。DTI に対し FSL を用いた前処理を行い、拡散の情報を要約している拡散異方性 FA 値や固有値、固有ベクトルを画像として求め、その画像を 3D-CNN による識

1.2 研究目的

別を行う。また、DTI に対して DSI-studio を用いてトラクトグラフィーを生成しトラクトグラフィーの統計値 30 種類を説明変数として、機械学習による識別を行う。手法としてサポートベクトルマシン (SVM) とロジスティック回帰による識別を行う。

第 2 章

拡散テンソル画像

本章では本研究で扱う拡散テンソル画像と拡散異方性について説明する。

2.1 拡散テンソル画像

拡散テンソル画像 (DTI:Diffusion Tensor Image) とは MRI によって撮像される白質繊維の拡散の大きさを持った画像である。ボクセルごとに単に拡散の大きさのみを画像化する拡散強調画像 (DWI:Diffusion Weighted Image) と異なり, 拡散の方向 16~64 ごとの拡散の大きさを別々に撮像する画像を DTI と呼ぶ。ここから拡散異方性 (FA:Fractional Anistoropy) を算出する。拡散異方性とは様々な拡散方向に対す DWI を用いて水分子の動きを定量化することで得られる。一人の被験者において各方向 16~64 枚で構成され, 一枚の画像から一方向情報が得られる (図 2.1)。各ボクセルにおいてスカラー値のみを保持する T1 強調画像や T2 強調画像に比べて, DTI は各ボクセルがテンソル情報を持つため, 情報量の多い画像となっている [5]。平面での可視化の際には, 水分子が拡散する方向分を楕円形に類似したもので表現される。体内の組織内を流れる水分子の動きを捉えることができるため, 主に神経繊維における神経方向を可視化することができ, 異常が発生していないかを診断することができる。アルツハイマーにおいては脳の特定位において拡散異方性が低下しており, 精神病において関係性が高いとされている。脳だけでなく体の様々な部位において撮像することができるため, 神経障害や痛みを可視化・定量化し, 治療における効果についても定量的に判定することができるようになっている。

2.2 白質の拡散現象

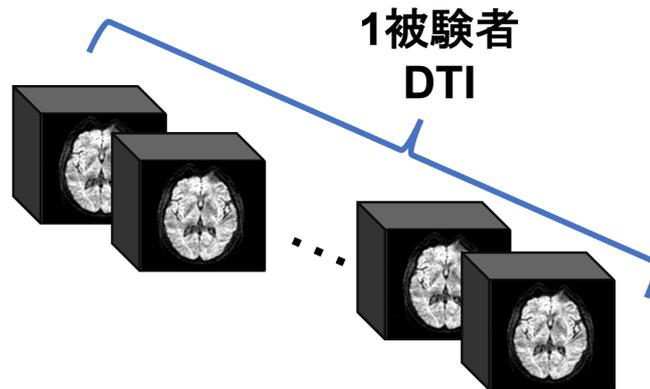


図 2.1: 1 被験者の DTI データ

2.2 白質の拡散現象

白質における拡散現象について説明する。

2.2.1 拡散の異方性

拡散の異方性とは方向ごとに拡散速度が異なることであり、神経繊維においては繊維に沿った方向に強い拡散があるが、繊維と直交する方向には拡散が弱い。図 2.2 のように左右に走行する神経繊維では左右の拡散は速く、上下や前後方向への拡散は遅い。対して拡散の等方性とは拡散が全方向に同一なことであり、脳においては脳脊髄液が各方向において同じ速さで拡散されているので等方的であると表現される。図 2.3 のように水槽の中の均一な水分子は球状に拡散している。

2.2.2 拡散テンソル

拡散を表現する手法としてテンソルを用いられることが多く、拡散テンソルとして式 (2.1) で表現される。 D_{xx} , D_{xy} , D_{xz} , D_{yy} , D_{yz} , D_{zz} は拡散係数を示している。

$$D = \begin{pmatrix} D_{xx} & D_{xy} & D_{xz} \\ D_{xy} & D_{yy} & D_{yz} \\ D_{xz} & D_{yz} & D_{zz} \end{pmatrix} \quad (2.1)$$

2.2 白質の拡散現象

この拡散係数を画像表現されたのが Tensor 画像となっている。拡散テンソル D を対角化することで式 (2.2) と表現でき、 $\lambda_1, \lambda_2, \lambda_3$ は拡散テンソルの固有値を示す値である。

$$\begin{pmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{pmatrix} \quad (2.2)$$

これらの固有値を画像表現されたのが L1, L2, L3 画像となっている。同時に固有値 $\lambda_1, \lambda_2, \lambda_3$ に対応する固有ベクトル $\mathbf{v}_1, \mathbf{v}_2, \mathbf{v}_3$ が求められる。この時、 \mathbf{v}_1 は神経繊維の方向を示し、 $\mathbf{v}_2, \mathbf{v}_3$ は神経繊維に直交する方向を示す。これらの固有ベクトルを画像表現されたのが V1, V2, V3 画像となっている。ADC は拡散の大きさそのもののみを示す指標であり、FA は異方性の強さを示す指標の一つであり、拡散テンソルの特徴を捉えるためのパラメータである。ADC と FA は固有値を用いて式 2.3 と式 2.4 と表現される。

$$ADC = \frac{\lambda_1 + \lambda_2 + \lambda_3}{3} = \langle D \rangle \quad (2.3)$$

$$FA = \sqrt{\frac{3}{2} \frac{\sqrt{(\lambda_1 - \langle D \rangle)^2 + (\lambda_2 - \langle D \rangle)^2 + (\lambda_3 - \langle D \rangle)^2}}{\sqrt{\lambda_1^2 + \lambda_2^2 + \lambda_3^2}}} \quad (2.4)$$

この FA を画像表現した FA 画像となっている。

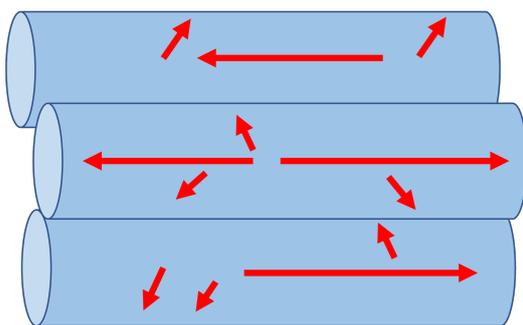


図 2.2: 左右方向に走行する神経繊維における水分子の拡散

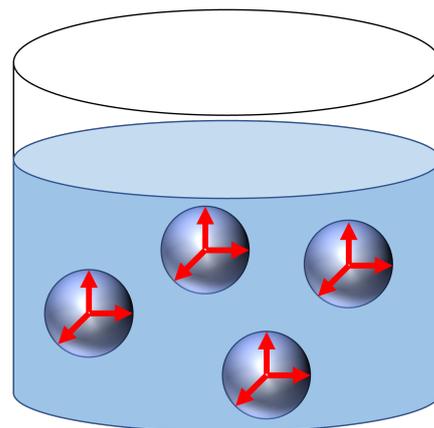


図 2.3: 水槽の中の水分子の拡散

2.3 トラクトグラフィー

トラクトグラフィー (Tractography) は脳白質路のような繊維を 3 次元的に描出する手法である。白質内のボクセルが保持する拡散異方性のデータを用いて、図 2.4 のように連続するものをつなげることで神経路を描出することができる。本学の MRI において描出されたトラクトグラフィーを図 2.5 に示す。

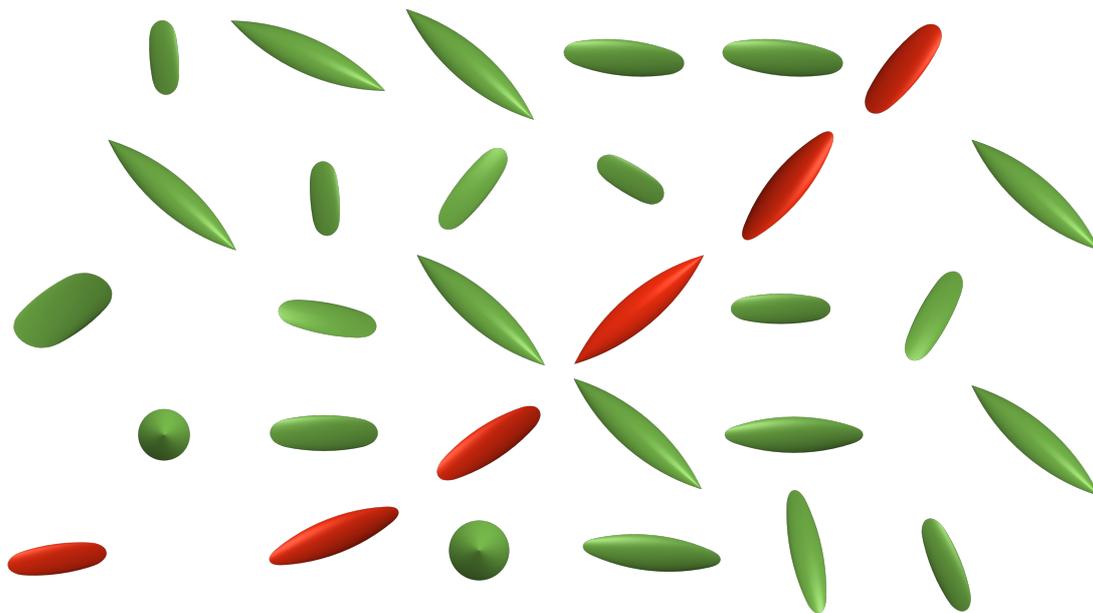


図 2.4: ボクセルにおいて連続する拡散異方性

2.3 トラクトグラフィ

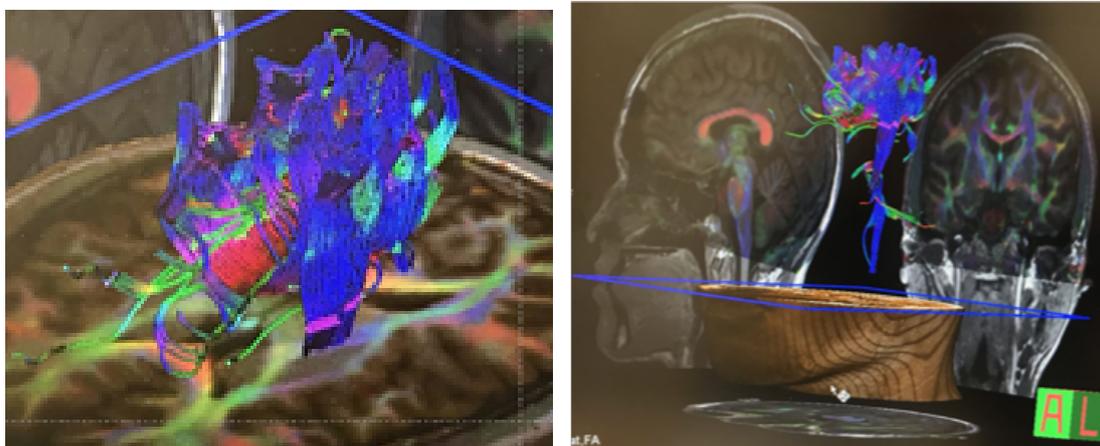


図 2.5: トラクトグラフィ画像の例
[高知工科大学 MRI 装置で撮像・描出]

第 3 章

機械学習手法

本章では本研究で用いる機械学習手法について示すとともに、機械学習モデルの評価方法について示す。本研究で用いるデータは 3 次元画像であり、これらの画像から年齢・性別を識別する 3D-CNN を構築する。本研究で用いる画像は 3 次元画像に加えて、拡散異方性、ベクトル方向等の情報を持っている。そのため、このチャンネルにこれらの情報を入力することで学習を行い、3 次元画像より多くの情報を持った入力として実験を行う。トラクトグラフィ統計値については画像ではないため、SVM とロジスティック回帰を機械学習アルゴリズムとして用いる。SVM は 2 クラス分類に特化しており、識別能力が高い。それに対してパラメータの調整や結果の解釈が難しいという短所があげられるため、ロジスティック回帰によるクラス分類も同様に行う。ロジスティック回帰を用いることで、説明変数の偏回帰係数を出力することができるため、識別に影響を与える説明変数とその重みを示すことができる。これらの 2 種類の機械学習モデルを使うことで年齢・性別へ影響がある ROI や説明変数を明確にする。

3.1 3D-Convolutional Neural Network(3D-CNN)

3 次元畳み込みニューラルネットワーク (3D-CNN) は畳み込みニューラルネットワーク (CNN) を元に 2 次元情報に奥行きなどのさらなる情報を加えた 3 次元データを処理することを目的として提案されたモデルである。

3.1 3D-Convolutional Neural Network(3D-CNN)

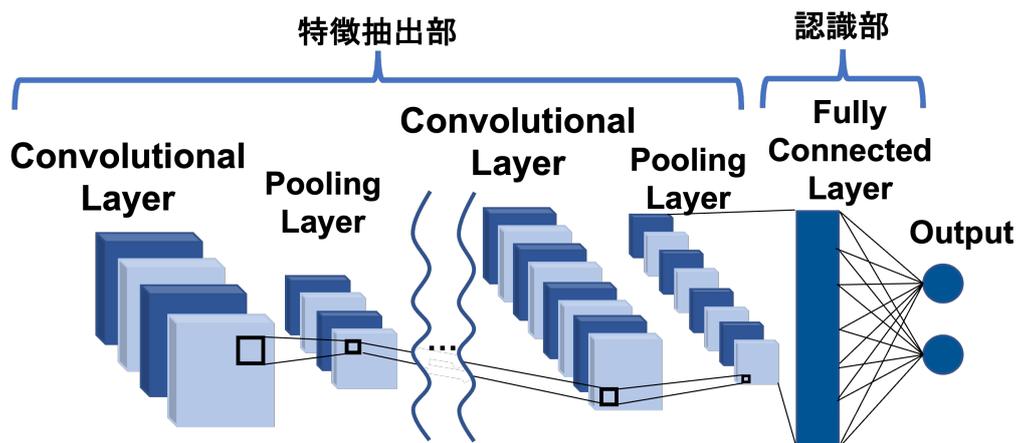


図 3.1: 3D-CNN の基本構造

3.1.1 CNN の基本構造

CNN の基本構造として 3D-CNN の概略図を図 3.1 に示す。CNN は主に特徴抽出部と認識部の 2 つで構成されている。特徴抽出部は畳み込み層とプーリング層で構成され、局所的な特徴マップを算出する。認識部では、全結合層にて特徴抽出部で得た特徴マップを用いて最終的な識別を行う。

3.1.2 チャンネル

入力される画像には大きくモノクロ画像とカラー画像があり、これらは 3D-CNN における「チャンネル数」が異なる。モノクロ画像やグレースケール画像は白黒の濃淡で表現されているため、1 チャンネルと指定する必要がある。MRI 脳構造画像においては T1 強調画像・T2 強調画像が例として挙げられる。カラー画像は Red, Green, Blue(RGB) の組み合わせで表現されているため、3 チャンネルが必要とされる。学習を行う際、このチャンネル間の畳み込みは行われなため、チャンネルごとで独立して行われる。このチャンネルは 3 次元情報に加えてもう一つの次元データを扱うことのできるとして擬似 4D-CNN として扱われることもある [6]。

3.2 Support Vector Machine(SVM)

SVMとはクラス間の境界線と各データとの距離を指すマージンをデータにおいて最大化することでクラス分類を行う手法である。ガウシアン・多項式・線形といった選択肢からカーネル関数を指定し、 C (誤分類コスト)・ γ (境界線の複雑さ)を層化抽出交差検証法を用いて、パラメータ探索による最適化を行う。

3.3 Logistic Regression(ロジスティック回帰)

ロジスティック回帰は多変量解析の一つで、複数の説明変数間の関連性を標準化偏回帰係数を比較することで分析する手法である。本実験では、過学習を防ぐため3種類の正則化を行ったモデルを用いる。 $\mathbf{w} = [w_0, w_1, \dots, w_n]^T$ を回帰係数とし、L1ノルム・L2ノルム・損失関数 $f(x)$ を用いて式 3.1 のように表される。 $\alpha = 1$ とすることでL1ノルムのみの正則化項を加えたモデルをLasso(式 3.2)[7]と表記する。Lassoは偏回帰係数のいずれかを0と推定する事で影響のない説明変数を取り除くことができ、 λ の値を大きくすることで0と推定される偏回帰係数の数は増える。 $\alpha = 0$ とすることでL2ノルムのみの正則化項を加えたモデルをRidge(式 3.3)[8][9]と表記される。Ridgeは偏回帰係数の値を制限するための引数であり、 λ の値を大きくすることで偏回帰係数の絶対値は小さくなる。 $0 < \alpha < 1$ とすることで、L1ノルムとL2ノルムの両方の正則化項を加えたモデルをElasticNet[10]と表記し、式 3.1 となる。ElasticNetはL1ノルムとL2ノルムの両項が残るため、LassoとRidgeの両方の性質を備えている。LassoとRidgeでは λ 、ElasticNetでは λ と α を層化抽出交差検証法を用いて、パラメータ探索による最適化を行う。

$$\min\{-l(\mathbf{w}) + \sum_{j=1}^n \lambda(\alpha\|w_j\| + (1-\alpha)\|w_j\|^2)\} \quad (3.1)$$

$$\min\{-l(\mathbf{w}) + \sum_{j=1}^n \lambda\|w_j\|\} \quad (3.2)$$

3.4 機械学習モデルの評価

表 3.1: 混同行列

		機械学習モデルの予測	
		1	2
実際のクラス	1	TP(True Positive)	FN(False Negative)
	2	FP(False Positive)	TN(True Negative)

$$\min\{-l(\mathbf{w}) + \sum_{j=1}^n \lambda \|w_j\|_2^2\} \quad (3.3)$$

3.4 機械学習モデルの評価

3.4.1 混同行列

クラス分類での性能評価として混同行列を用いられることが多い。混同行列とはモデルによる予測値と正解である真の値を比較しラベルごとに分類した時の表 3.1 を指す。本研究においてはこの混同行列をデータセットごとに表示し、クラスにおける偏りがな
いことを確認する。また、式 3.4 によって求められる *Accuracy* を用いて汎化性能を評
価する。

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (3.4)$$

3.4.2 K-分割交差検証法

学習モデルの汎化性能を評価する手法として K-分割交差検証法 (K-Fold Cross Validation: CV) が挙げられる。K-分割交差検証法とはデータセット全体を K 分割し、そのうちの 1 個をテストデータ、残りの K-1 個を学習用データとし、学習・テストを行い、分割されたデータが 1 回ずつテストデータとして扱われる。この流れを全 K 数回行う実験手法のことである (図 3.2)。分割する際に、クラスにおけるデータ比率が変わらないように層化抽出法を用いた K-分割交差検証を行う手法がよく取り入れられている。K 回のテ

3.4 機械学習モデルの評価

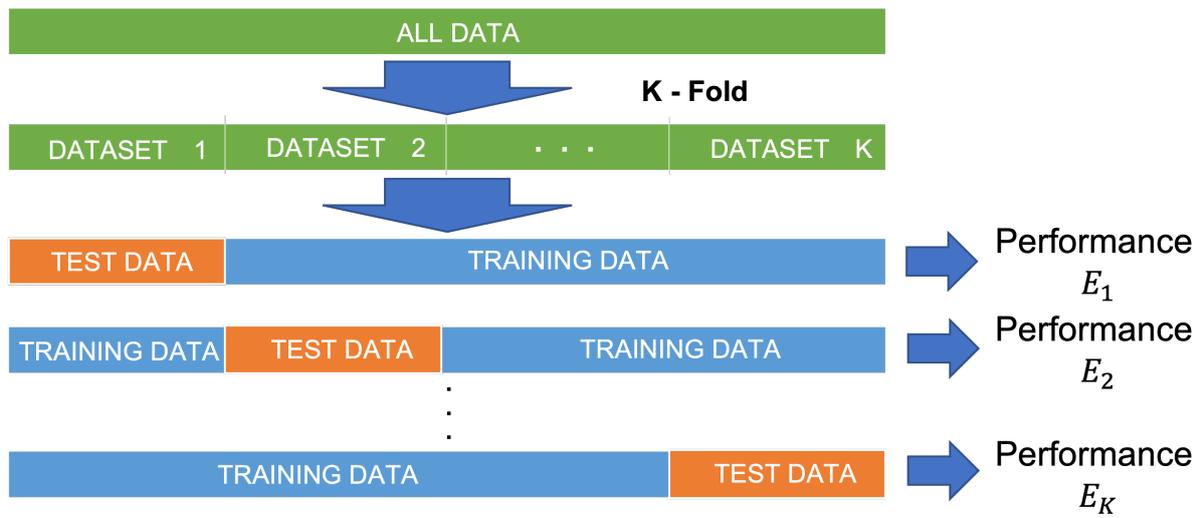


図 3.2: 交差検証法

ストで出力される混同行列を用いて推定精度の平均をとり，モデルの性能とする。

第 4 章

モデルの提案

本章では本研究において提案する識別モデルについて示す。

4.1 提案手法

本研究では、性別・年齢を識別する対象の属性とする。これらを拡散テンソルから推定するために、次の 3 つの手法を提案する。

- (a) DTI の 16 方向の成分を 3D-CNN の 16 のチャンネルに直接入力による推定
- (b) DTI に対して FSL 前処理を行った固有値・固有ベクトル画像を用いた 3D-CNN による推定
- (c) 脳の 56 種類の関心領域ごとにおけるトラクトグラフィ統計値を用いた SVM とロジスティック回帰による推定

これらの識別モデルのデータの流れを図 4.1 に示す。本研究で用いる DTI は被験者ごとに 3 次元の脳構造像画像が 16 枚ある。3D-CNN においてそれぞれの拡散方向の画像を 16 の異なる入力チャンネルに格納することで学習を行う。モデル (b) での入力画像においても 3 次元の構造画像に加えて方向成分を持った画像があり、DTI と同様に入力チャンネルに格納することで学習を行う。

4.1 提案手法

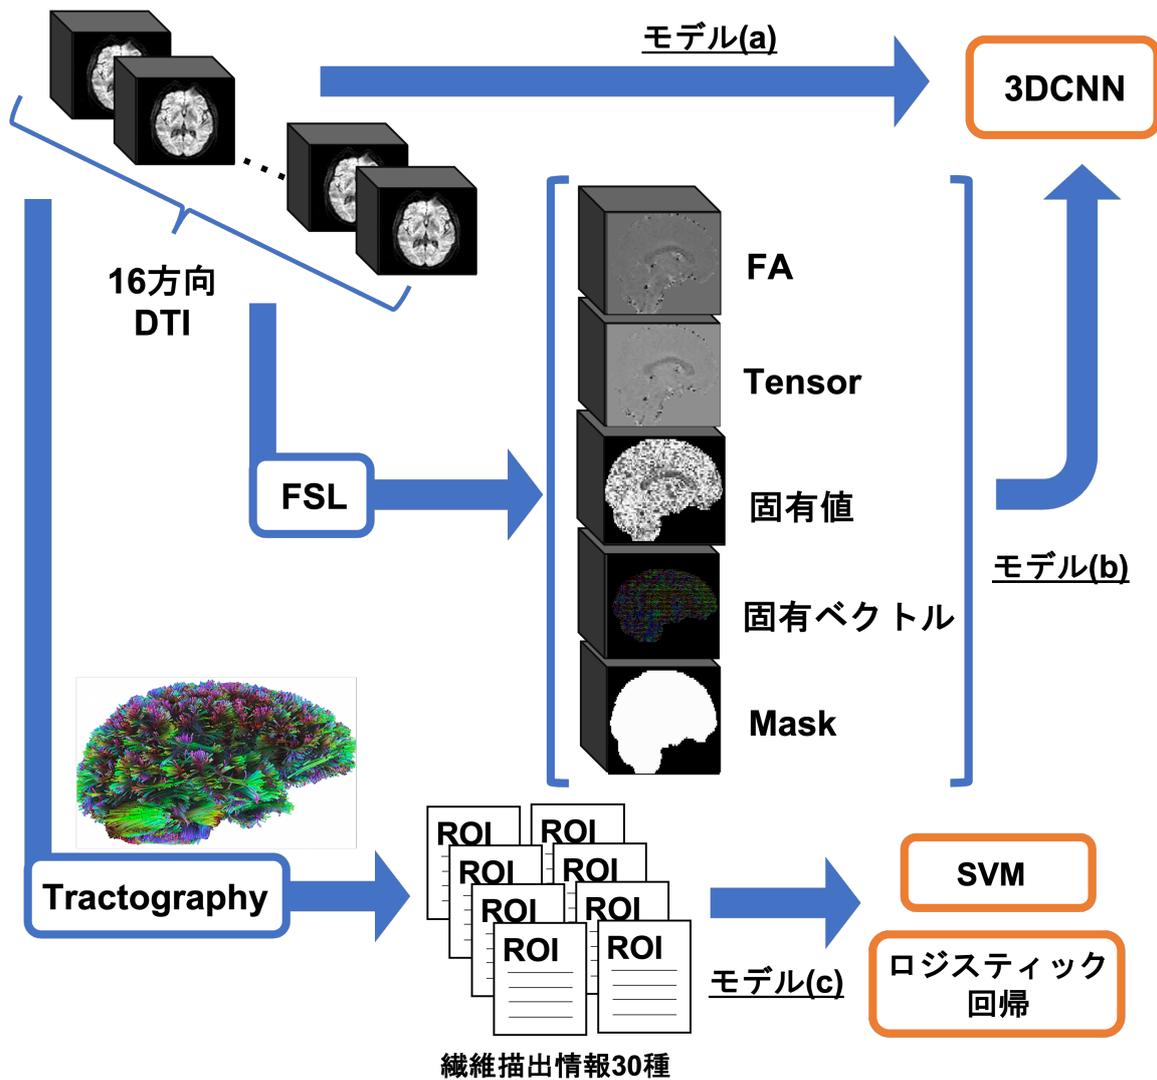


図 4.1: 提案する 3 つの識別モデルのデータフロー

第 5 章

前処理

本章では実験に用いる入力に対する前処理について示す。

5.1 FSL

DTI の前処理の一つとして FMRIB Software Library(FSL)[11] を用いる。FSL とはオックスフォード大学によって作成された FMRI, MRI, DTI の脳画像データを分析するためのツールである。DTI に対して FSL による前処理を行うことで DTI の拡散の異方性情報画像を生成することを目的とする。各被験者の 0 番目の 3 次元 DTI 画像 1 枚を入力として [BET] コマンド [12] を使用し、脳全体の画像から脳組織部のみを抽出・脳表面の輪郭を示す Mask 画像を生成する。各被験者 1~16 番目の 3 次元 DTI 画像 16 枚を入力として [EDDY] コマンド [13] を使用し、過電流によって引き起こされる歪みや被験者の動きを補正を行う。Mask 画像と歪み補正された画像に加えて b 値情報、b ベクトル情報を入力として [DTIFIT] コマンドを使用し、拡散テンソルのフィッティングを行う。この処理により各固有ベクトル・各固有値・拡散係数値・部分異方性による FA(Fractional Anisotropy) 値画像を生成する。DTI 画像, Mask 画像, FA 画像, Tensor 画像, 各固有ベクトル画像, 各固有値画像を FSLeyes[14] を用いて表示されたものを図 5.1, 図 5.2, 図 5.3, 図 5.4, 図 5.5, 図 5.6 に示す。また、これらの FSL による処理の実行環境を表 5.1 に示す。

Lip ら [15] によって DTI での被験者間での頭を合わせる方法として T1 へ合わせる方法を選択したが、このノーマライズのステップは今後改善される必要があると述べられ

5.2 DSI-studio

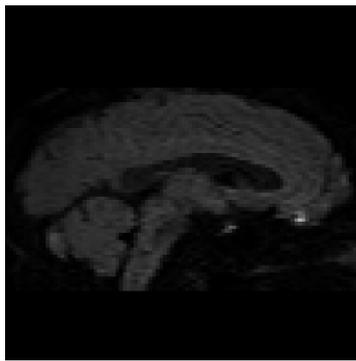


図 5.1: DTI 画像



図 5.2: Mask 画像

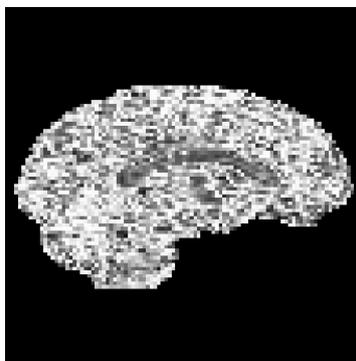


図 5.3: FA 画像

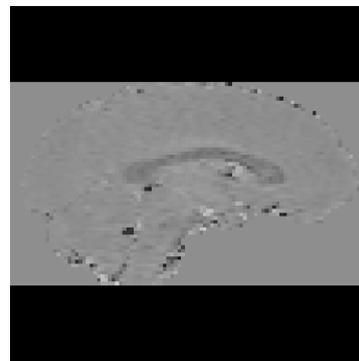


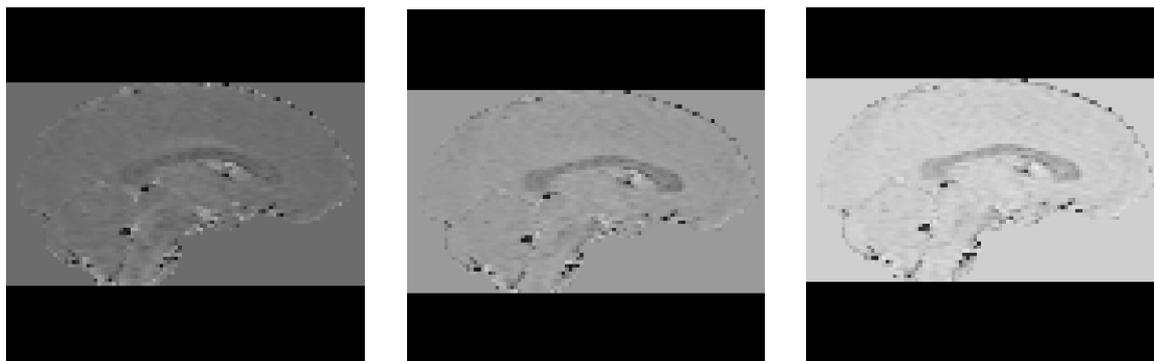
図 5.4: Tensor 画像

ており、必ずしも良い方法とは認識されていない [16][17][18]. そのため、本研究では一般的なノーマライズ手順が確立されていないという理由から、被験者間のノーマライズ処理は行っていない画像を用いる. ノーマライズを行っていないため、脳の大きさによる影響が考えられる. そのため、脳の Mask 画像を入力し、識別率のベースラインとして比較を行う.

5.2 DSI-studio

拡散テンソル画像を入力として DSI-studio を用いてトラクトグラフィーの統計値を出力する. 統計値は DSI-studio による Shape-analysis[19] に従い、トラクトグラフィーに関するトラッキング統計・形状特徴情報を出力する.

5.2 DSI-studio

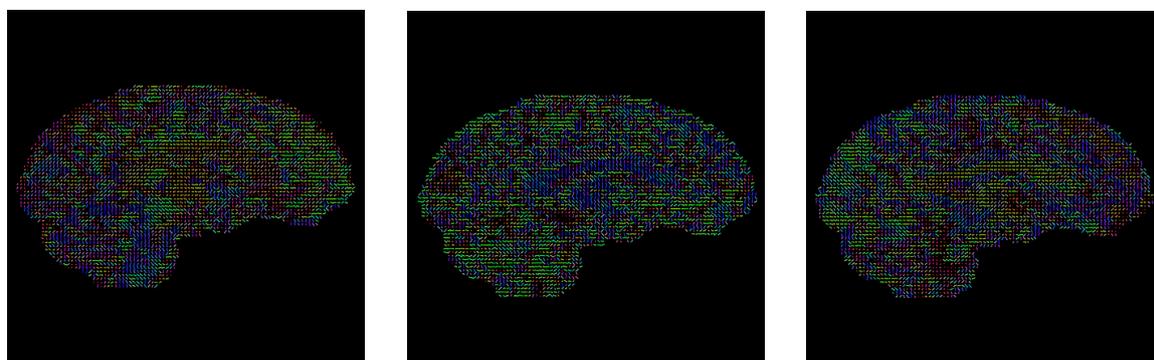


(a) L1 画像

(b) L2 画像

(c) L3 画像

図 5.5: 各固有値画像



(a) V1 画像

(b) V2 画像

(c) V3 画像

図 5.6: 各固有ベクトル画像

1. 被験者ごとの拡散データ (NIFTI) を SRC ファイルに変換
2. 問題のあるデータを除外するために SRC ファイルの品質管理
3. 自動ファイバートラッキングによるトラッキング統計と形状特徴の出力

SRC ファイルを用いて各被験者画像において同様の勾配方向を持つ低 bDWI ボリュームの相関係数である「隣接する DWI 相関」を計算する。品質管理によって隣接する DWI 相関が低い被験者データを求め、「低品質の外れ値」のラベルをつける。これらは本研究においては除外している。また、自動ファイバートラッキングを行った際のパラメータ等を表 5.2 に示す。各データにおいてトラッキングの信頼性が低いと判定された部位

表 5.1: FSL 実行環境

Property	Detail
CPU	Core i9-9900K CPU @ 3.60GHz x16
GPU	GeForce RTX 2080 Ti
OS	Ubuntu 18.04.2

表 5.2: DSI-studio 実行パラメータ

Recommended List	Association Pathways
	Projection Pathways
	Commissural Pathways
GQI Length Ratio	1.25
Tract/Voxel Ratio	2.0 per voxel
Tolerance	16,18,20 mm
Output	Statistics
	Tractography

は描出されず、統計情報も存在しない。そのため、全被験者に対して DSI-studio による処理を行ったが、統計値データを出力される ROI が被験者によって異なったため、各 ROI での被験者総数は異なる。出力された被験者において性別・年齢共に ROI ごとのクラスの割合は母集団とほとんど変わらないことを確認している。これらの DSI-studio による処理の実行環境を表 5.3 と表 5.4 に示す。これら 4 つのサーバーの CPU を用いて並列処理で行なった。サーバーによっては Ubuntu のバージョンが異なっているが、DSI-studio は全て同じバージョンを使用している。

5.2 DSI-studio

表 5.3: DSI-studio 実行環境

	1	2
CPU	Ryzen Threadripper 2950X 16-Core Processor x32	Ryzen Threadripper 2950X 16-Core Processor x32
GPU	A10	GeForce RTX 2070 x2
OS	Ubuntu 20.04.1	Ubuntu 20.04.1

表 5.4: DSI-studio 実行環境

	3	4
CPU	Ryzen Threadripper 3990X 64-Core Processor x64	EPYC 7742 64-Core Processor
GPU	NVIDIA GeForce RTX 2070 SUPER	
OS	Ubuntu 20.04.3	Ubuntu 20.04.3

5.2 DSI-studio

出力される stat.txt にある情報内容を表 5.5 に示す。

表 5.5: DSI-studio によって出力される stat.txt に含まれる情報

number of tracts	トラクト総数
mean length(<i>mm</i>)	平均長
span(<i>mm</i>)	2つの端部領域間の距離
curl	曲がり度合い
elongation	伸び
diameter(<i>mm</i>)	直径
volume(<i>mm</i> ³)	体積
trunk volume(<i>mm</i> ³)	幹の体積
branch volume(<i>mm</i> ³)	枝の体積
total surface area(<i>mm</i> ²)	表面積
total radius of end regions(<i>mm</i>)	端部の総半径
total area of end regions(<i>mm</i> ²)	端部の総面積
irregularity	表面の不規則性
area of end region 1	端点面積 1
radius of end region 1	端点領域半径 1
irregularity of end region 1	末端領域の不規則性 1
area of end region 2	端点面積 2
radius of end region 2	端点領域半径 2
irregularity of end region 2	末端領域の不規則性 2
qa	定量的異方性
nqa	正規された QA 値
dti_fa	異方性の強さ
md	平均拡散係数

5.2 DSI-studio

ad	軸方向拡散係数
rd	放射状方向拡散係数
iso	等方性拡散
rdi	制限された拡散
nrdi02L	0.2 拡散サンプリング長比での非制限拡散
nrdi04L	0.4 拡散サンプリング長比での非制限拡散
nrdi06L	0.6 拡散サンプリング長比での非制限拡散

DSI-studio において分けられる関心領域 (ROI) を 5.6 に示す.

表 5.6: DSI-studio によって分けられる関心領域 (ROI)

ROI NAMES	関心領域
Arcuate_Fasciculus_L	左側弓状束
Arcuate_Fasciculus_R	左側弓状束
Cingulum_Frontal_Parahippocampal_L	左側前海馬傍回帯
Cingulum_Frontal_Parahippocampal_R	右側前海馬傍回帯
Cingulum_Frontal_Parietal_L	左側前頭頂帯
Cingulum_Frontal_Parietal_R	右側前頭頂帯
Cingulum_Parahippocampal_L	左側海馬帯状束
Cingulum_Parahippocampal_Parietal_L	左側海馬傍頭頂部帯状束
Cingulum_Parahippocampal_Parietal_R	右側海馬傍頭頂部帯状束
Cingulum_Parahippocampal_R	右側海馬帯状束
Cingulum_Parolfactory_L	左側嗅覚帯
Cingulum_Parolfactory_R	右側嗅覚帯
Corpus_Callosum_Body	脳梁
Corpus_Callosum_Forceps_Major	脳梁主鉗子

5.2 DSI-studio

Corpus_Callosum_Forceps_Minor	腦梁副鉗子
Corpus_Callosum_Tapetum	腦梁皮膜
Corticobulbar_Tract_L	左側皮質延髓路
Corticobulbar_Tract_R	右側皮質延髓路
Corticospinal_Tract_L	左側皮質脊髓路
Corticospinal_Tract_R	右側皮質脊髓路
Corticostriatal_Tract_Anterior_L	左側皮質線路前方
Corticostriatal_Tract_Anterior_R	右側皮質線路前方
Corticostriatal_Tract_Posterior_L	左側皮質線路後方
Corticostriatal_Tract_Posterior_R	右側皮質線路後方
Corticostriatal_Tract_Superior_L	左側皮質線路上級
Corticostriatal_Tract_Superior_R	右側皮質線路上級
Fornix_L	右側腦弓
Fornix_R	左側腦弓
Frontal_Aslant_Tract_L	左側前方斜方路
Frontal_Aslant_Tract_R	右側前方斜方路
Inferior_Fronto_Occipital_Fasciculus_L	左側後頭束
Inferior_Fronto_Occipital_Fasciculus_R	右側後頭束
Inferior_Longitudinal_Fasciculus_L	右側下側縱束
Inferior_Longitudinal_Fasciculus_R	右側下側縱束
Middle_Longitudinal_Fasciculus_L	左側中縱隔筋膜
Middle_Longitudinal_Fasciculus_R	右側中縱隔筋膜
Optic_Radiation_L	左側視覺路經路
Optic_Radiation_R	右側視覺路經路
Parietal_Aslant_Tract_L	左側頭頂斜方路
Parietal_Aslant_Tract_R	右側頭頂斜方路

5.2 DSI-studio

Superior_Longitudinal_Fasciculus1_L	左側上縱束 1
Superior_Longitudinal_Fasciculus1_R	右側上縱束 1
Superior_Longitudinal_Fasciculus2_L	左側上縱束 2
Superior_Longitudinal_Fasciculus2_R	右側上縱束 2
Superior_Longitudinal_Fasciculus3_L	左側上縱束 3
Superior_Longitudinal_Fasciculus3_R	右側上縱束 3
Thalamic_Radiation_Anterior_L	左側視床下部放線前方
Thalamic_Radiation_Anterior_R	右側視床下部放線前方
Thalamic_Radiation_Posterior_L	左側視床下部放線後方
Thalamic_Radiation_Posterior_R	右側視床下部放線後方
Thalamic_Radiation_Superior_L	左側視床下部放線上方
Thalamic_Radiation_Superior_R	右側視床下部放線上方
Uncinate_Fasciculus_L	左側鉤狀束
Uncinate_Fasciculus_R	右側鉤狀束
Vertical_Occipital_Fasciculus_L	左側垂直後頭葉
Vertical_Occipital_Fasciculus_R	右側垂直後頭葉

第 6 章

実験

本章では本研究で行った実験について示す。

6.1 識別する属性

本研究では、性別・年齢を識別する対象の属性とする。性別では「男性」「女性」、年齢ではデータセットの中央値から閾値を決め、「55 歳未満」「55 歳以上」の 2 クラス分類として実験を行う。年齢を 55 で分けたのはデータセットでの中央値付近であるためである。

6.2 データセット

本研究では IXI データセット [20] を用いる。IXI データセットはロンドンの 3 つの病院で 1.5T と 3T の MRI を用いて撮像された健康な被験者 600 人の MRI 画像を集めたものとなっている。本研究では DTI のみを使用するが、推定課題である性別情報・年齢情報・画像情報が全被験者において揃っていない。そこで画像に加えて 3 つの情報が全て揃っている被験者のみを使用するため総被験者は 20～86 歳の 388 人となり、この被験者を用いて実験を行う。男性は 175 名、女性は 213 名の構成となっている。年齢においては 2 クラスに分けたときにクラス内の数に偏りができるだけ出ないように閾値を決定した。年齢の分布を確認し、本データセットにおいては 55 歳未満 (189 名) と 55 歳以上 (199 名) の 2 クラスに分けた。使用するデータセットの男女比率、年齢分布を図 6.1 と図 6.2 に示す。55 歳未満のクラスにおける男性の人数は 98 名、女性の人数は 91 名、55

6.3 実験環境

歳未満のクラスにおける男性の人数は 77 名，女性の人数は 122 名となっている．また，年齢における男女比率を図 6.3 に示す．

6.3 実験環境

全てのモデルにおいて Keras(Tensorflow backend) を用いた．3D-CNN を用いたモデル (a)，モデル (b) と SVM・ロジスティック回帰を用いたモデル (c) のシミュレーションを行なった環境を表 6.1 に示す．

6.4 標準化

入力されるデータが広い範囲の測定単位で構成，またはデータでの測定単位範囲が大きく異なる場合，学習において分布の形状が大きく変化してしまうなど，影響する可能性がある．そこで本研究では，元のデータ X の平均 μ と標準偏差 σ を用いて式 (6.1) のように計算を行い，平均 0，標準偏差 1 にやつ用に標準化を行う．

$$z = \frac{X - \mu}{\sigma} \quad (6.1)$$

6.5 3D-CNN を用いたモデル (a)・モデル (b)

本研究で用いる全 7 層の 3D-CNN の構成を図 6.4 に示す．特徴抽出部では Convolution3D, BatchNormalization, Activation(relu), MaxPooling3D を 1 層として 5 回繰り返す．得られた特徴マップを認識部に入力することで性別・年齢の識別を行う．DTI に加え FSL によって前処理された計 10 種類の画像を入力とする．最適化，学習率は交差検証法を用いて画像ごとに決定し，評価には交差検証法を用いて識別率の平均と標準偏差を用いて比較を行う．

6.6 SVM・ロジスティック回帰を用いたモデル (c)

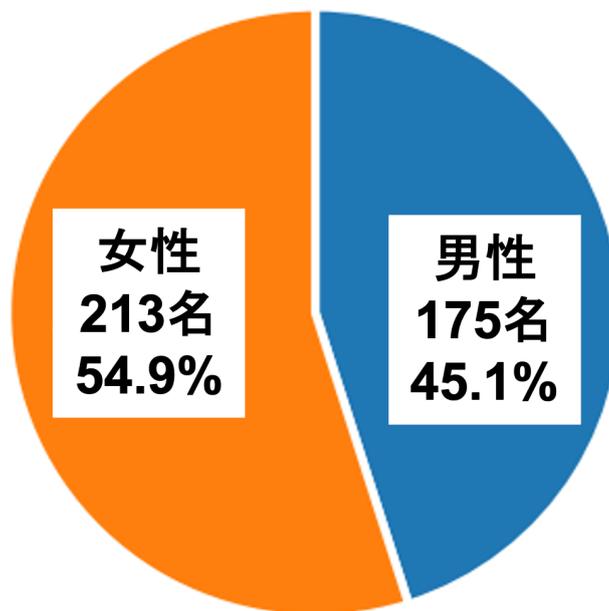


図 6.1: 男女比率

6.6 SVM・ロジスティック回帰を用いたモデル (c)

SVM・ロジスティック回帰を用いて DSI-studio によって前処理されたトラクトグラフィ統計値を ROI ごとに分け、出力される stat ファイルの中身を説明変数とし、年齢・性別を目的変数として入力する。カーネル関数、正則化方法、ハイパーパラメータの探索を交差検証法を用いて行い、識別率を用いて比較を行う。

6.6 SVM・ロジスティック回帰を用いたモデル (c)

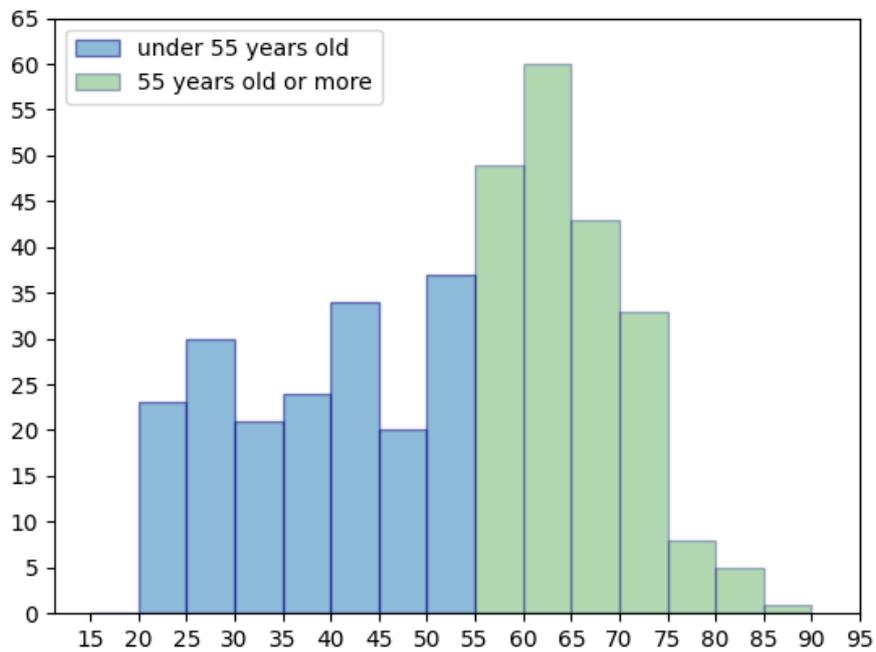


図 6.2: 年齢分布

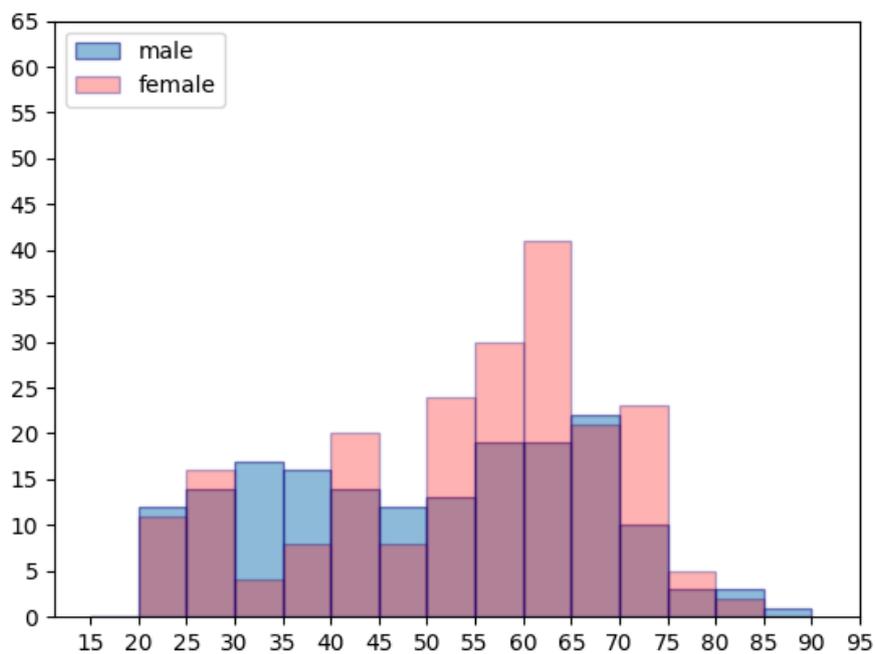


図 6.3: 年齢における男女比率

6.6 SVM・ロジスティック回帰を用いたモデル (c)

表 6.1: 各モデルのシミュレーション実行環境

Property	モデル (a)	モデル (c)
	モデル (b)	
CPU	E5-2698 v4 @ 2.20GHz x80	Ryzen Threadripper 2950X 16-Core Processor x32
GPU	Tesla V100-SXM2-32GB	A10
OS	Ubuntu 16.04.4	Ubuntu 20.04.1

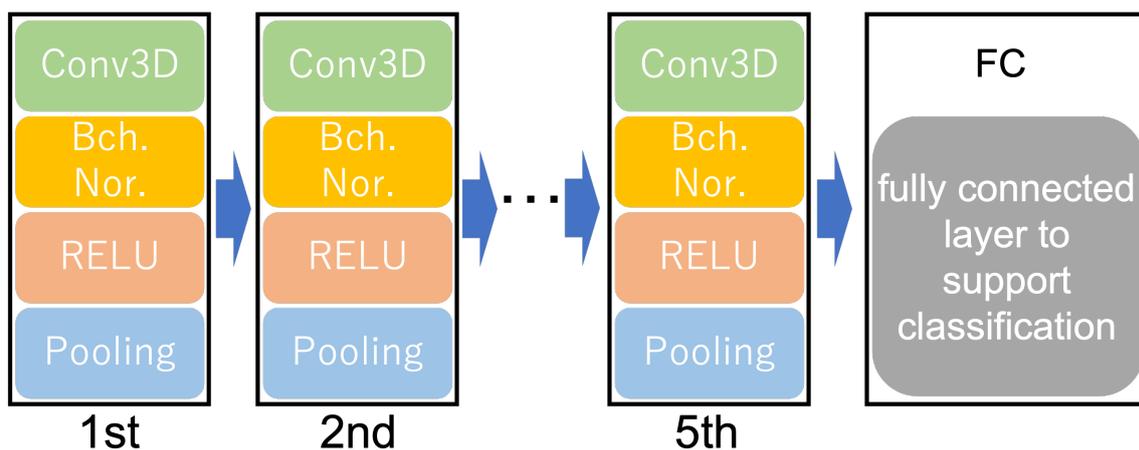


図 6.4: 3DCNN モデル

第7章

結果

本章では本研究で行った実験の結果を示す。

7.1 3D-CNN を用いたモデル (a) ・モデル (b)

3D-CNN を用いて行なったモデル (a) ・モデル (b) の結果を識別率における 5 分割交差検証法の平均・標準偏差を表 7.1 に示し、グラフ化したものを図 7.1, 図 7.2 に示す。グラフには Mask 画像の識別率をベースラインとして示している。fsl により標準化を行なった FA 画像・固有値・固有ベクトル・Tensor 画像の 3D-CNN の結果を 7.2 に示す。年齢・性別共にモデル (a) の識別率が高い結果となった。年齢では DTI と同等に Tensor 画像の識別率が高い結果となった。性別においては DTI に続いて、FA 画像と L1 画像の識別率が高い結果となった。

表 7.1: 年齢・性別における 5 分割交差検証法の平均・標準偏差

	DTI	Mask	FA	L1	L2	L3	V1	V2	V3	Tens
Age ave.	80.2	73.2	70.0	76.1	79.6	76.8	75.0	69.3	71.1	80.7
std.	4.52	3.81	5.04	4.08	4.52	1.36	2.29	2.72	3.66	4.40
Gender ave.	88.9	78.5	82.2	82.6	79.5	77.2	78.4	77.6	78.1	78.1
std.	2.6	4.82	3.77	2.76	4.66	4.69	2.46	3.17	4.26	3.63

7.2 SVM・ロジスティック回帰を用いたモデル (c)

表 7.2: 標準化した年齢・性別における 5 分割交差検証法の平均・標準偏差

	DTI	Mask	FA	L1	L2	L3	V1	V2	V3	Tens
Age ave.	-	-	75.6	67.8	59.3	75.0	57.7	68.3	53.6	59.0
std.	-	-	7.70	5.48	3.75	3.60	4.63	3.30	3.42	5.39
Gender ave.	-	-	72.4	76.0	61.9	74.0	57.0	68.8	50.3	57.2
std.	-	-	3.46	2.87	1.32	4.78	4.04	5.59	3.16	7.67

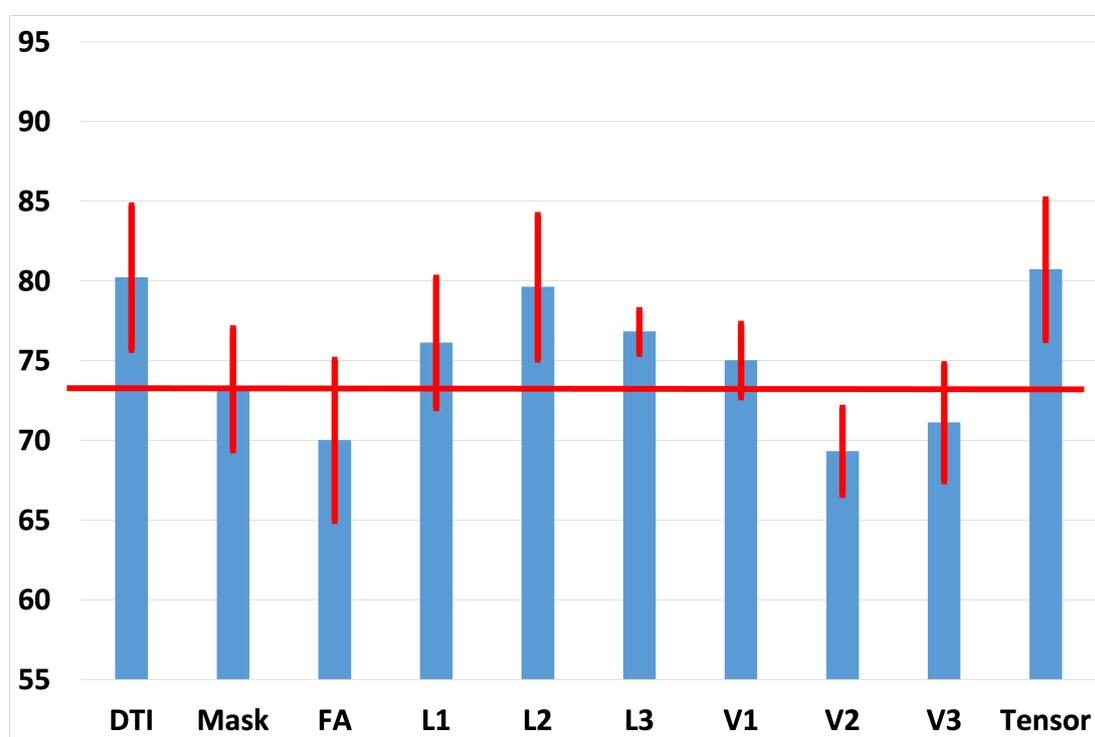


図 7.1: 年齢における 5 分割交差検証法の平均・標準偏差

7.2 SVM・ロジスティック回帰を用いたモデル (c)

SVM・ロジスティック回帰を用いて行なったモデル (c) の年齢の結果を表 7.3, 性別の結果を表 7.4 に示す. また, 表 7.5 にロジスティック回帰による標準化偏回帰係数を示す. 年齢では右側脳弓, 左側脳弓, 左側海馬帯状束, 性別では右側後頭束, 右側皮質延髄路に対して両手法で高い識別率を示した. ロジスティック回帰で識別率の高かった ROI

7.2 SVM・ロジスティック回帰を用いたモデル (c)

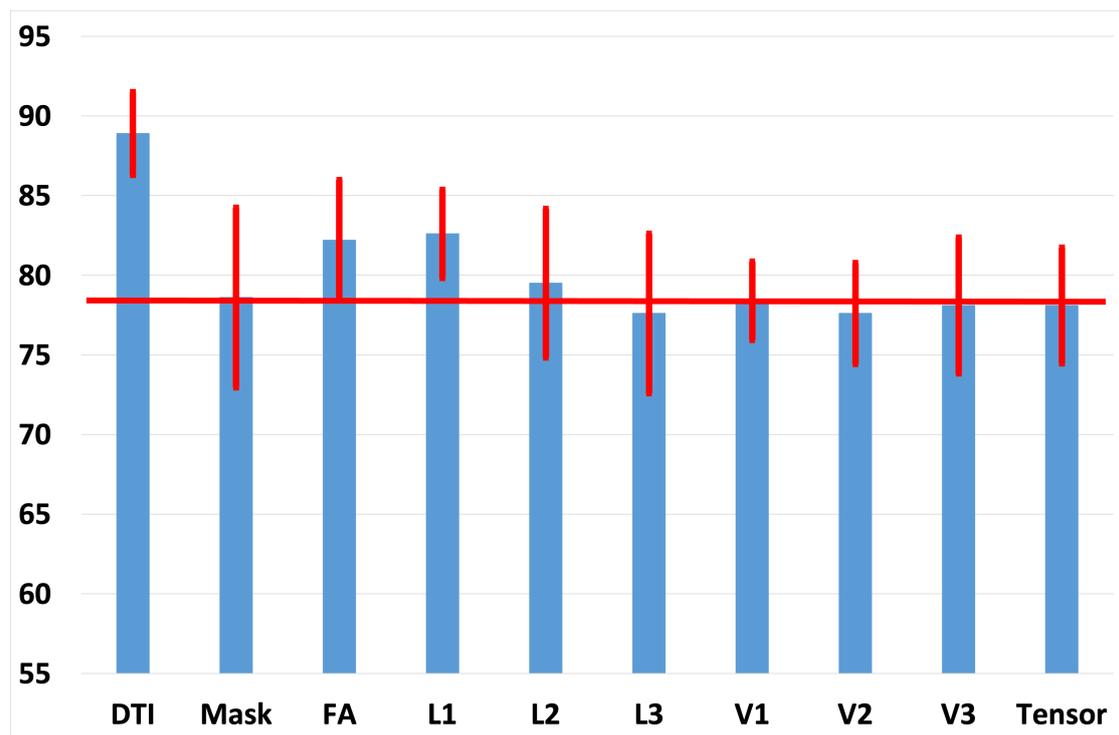


図 7.2: 性別における 5 分割交差検証法の平均・標準偏差

の標準化偏回帰変数が大きい説明変数を示す。年齢モデルの左側海馬帯状束, 右側脳弓, 性別モデルの右側後頭束, 海馬頭頂部帯状束では突出した値は見られなかった。年齢では左側脳弓の直径・繊維終端の面積・半径で-2.21, 4.37, -2.34, 性別では右側皮質延髄路のトラクト数・繊維終端の面積で 2.38, -4.26 となった。また, 年齢・性別共に高い識別率を示す ROI でのロジスティック回帰では Lasso もしくは ElasticNet が使用されていた。

7.2 SVM・ロジスティック回帰を用いたモデル (c)

表 7.3: 年齢の平均識別精度 (%) が高かった上位 5 部位と該当部位でトラクトグラフィーが算出された被験者数 (N)

SVM	FR* ¹	FL* ²	CPL* ³	UFR* ⁴	SLF1L* ⁵
Acc	87.5	85.7	82.4	75.9	73.5
Subject	36	66	85	143	168
Logistic	CPL	FR	FL	CCB* ⁶	SLF1L
Acc	88.2	87.5	78.6	76.9	73.5
Subject	85	36	66	195	168

(*1:Fornix_R(右側脳弓),

*2:Fornix_L(左側脳弓),

*3:Cingulum_Parahippocampal_L(左側海馬帯状束),

*4:Uncinate_Fasciculus_R(右側鉤状束),

*5:Superior_Longitudinal_Fasciculus1_L(左側上縦束 1),

*6:Corpus_Callosum_Body(脳梁))

7.2 SVM・ロジスティック回帰を用いたモデル (c)

表 7.4: 性別の平均識別精度 (%) が高かった上位 4 部位と該当部位でトラクトグラフィーが算出された被験者数 (N)

SVM	IFOFR* ¹	CPPR* ²	CbTR* ³	TRSR* ⁴
Acc	76.7	71.4	70.0	70.0
Subject	83	101	48	350
Logistic	IFOFR	VOFL* ⁵	CbTR	CbTL* ⁶
Acc	76.5	72.7	70.0	66.7
Subject	83	53	48	30

(*1:Inferior_Fronto_Occipital_Fasciculus_R(右側後頭束),

*2:Cingulum_Parahippocampal_Parietal_R(海馬傍頭頂部帯状束),

*3:Corticobulbar_Tract_R(右側皮質延髄路),

*4:Thalamic_Radiation_Superior_R(右側視床下部放射線上級),

*5:Vertical_Occipital_Fasciculus_L(左側垂直後頭葉),

6:Corticobulbar_Tract_L(左側皮質延髄路))

7.2 SVM・ロジスティック回帰を用いたモデル (c)

表 7.5: 年齢・性別の平均識別精度 (%) が高かった上位 5 部位における標準化偏回帰係数

	Age					Gender				
	CPL	FR	FL	CCB	SLF1L	IFOFR	VOFL	CbTR	CbTL	CsTL
number of tracts	-0.7	0.31	-1.16	0.23	0.16	0.05	0.09	2.38	0.12	0.0
mean length	-0.39	0.48	0.0	-0.19	0.39	-0.35	0.69	-1.44	-0.76	-0.66
span	-0.38	0.44	0.0	-0.34	0.48	-0.27	0.73	-1.47	-0.75	-0.68
curl	-0.04	0.31	0.02	0.0	0.37	-0.55	-0.55	1.36	-0.63	2.3
elongation	0.33	-0.22	-0.02	0.1	-0.64	0.0	-0.72	-1.4	1.15	-2.49
diameter	1.72	0.07	-2.21	0.0	0.14	0.0	-0.16	0.03	-0.86	0.0
volume	-1.11	0.0	0.0	0.0	-0.01	0.0	-0.7	0.18	-0.7	-0.61
trunk volume	-1.56	-0.19	0.0	-0.05	-0.21	0.0	-0.66	0.51	-1.41	-0.3
branch volume	-0.39	0.64	-0.74	0.02	0.25	-0.39	-0.13	-0.08	1.25	-2.02
total surface area	2.25	0.0	0.0	0.0	-1.09	0.0	-0.41	0.42	-1.27	-0.91
total radius of end regions	-0.29	-0.07	0.0	0.0	0.04	0.64	0.13	-0.4	1.72	0.15
total area of end regions	0.45	-0.07	1.3	0.0	0.15	0.0	-0.12	-0.85	1.01	0.03
irregularity area of end region 1	-0.77	-0.37	-1.27	0.53	1.06	-0.41	0.23	0.63	-2.07	0.25
radius of end region 1	1.58	0.0	0.0	0.0	-2.0	0.0	-0.18	1.37	0.29	-0.26
irregularity of end region 1	-1.88	-0.12	1.41	-0.3	-0.61	0.18	0.13	-1.08	1.37	0.01
area of end region 2	0.98	0.13	0.87	-0.13	0.42	0.0	-0.5	0.0	-0.04	-0.46
radius of end region 2	-0.3	-0.27	4.37	0.0	2.53	0.0	-0.05	-4.26	1.62	0.81
irregularity of end region 2	1.59	-0.0	-2.34	0.0	0.66	0.14	0.13	0.0	1.45	0.24
qa	-0.45	-0.67	0.0	0.0	-0.37	0.0	-0.05	0.25	0.54	0.0
nqa	1.53	0.12	0.03	0.25	-1.24	0.0	0.17	0.6	0.4	0.0
dti_fa	1.12	0.0	-0.16	0.1	0.78	0.22	-0.22	1.33	0.27	-0.67
md	0.69	0.73	1.57	0.0	0.58	0.33	0.38	1.68	0.77	-3.88
ad	0.54	0.0	1.34	0.0	-0.98	0.0	0.3	-0.39	0.59	0.0
rd	-0.51	0.0	1.41	0.46	-2.03	0.32	0.33	-0.86	0.74	-0.31
iso	2.01	0.25	0.98	0.0	2.62	0.0	0.27	0.0	0.33	0.43
rdi	-1.12	0.0	0.0	0.0	1.12	0.0	0.16	-0.13	0.49	-0.55
nrDi02L	0.78	0.12	1.14	0.0	-0.76	0.0	0.24	0.16	0.5	-0.04
nrDi04L	0.22	0.08	0.66	0.0	-0.44	0.0	0.17	0.0	0.45	-0.18
nrDi06L	-0.24	0.04	0.16	0.0	-0.12	0.0	0.11	0.0	0.41	-0.33
	-2.04	0.0	0.0	0.0	0.79	0.0	-0.11	0.0	0.24	-0.86

第 8 章

考察

8.1 3D-CNN を用いたモデル (a) ・ モデル (b)

識別率の結果からは、年齢については L2 も DTI の元情報と同等の識別精度であることから、固有値・固有ベクトルによる異方性の要約情報には DTI と同等の情報が含まれていると推察できる。更に、Tensor 画像についても同様に、年齢識別に必要な情報が失われていないと考えられる。特に DTI と Tensor 画像の識別率が高い結果となったことから、Tensor 画像は拡散テンソルにおける拡散係数を示しており、拡散係数に年齢の違いがあると考えられる。Hasan ら [21] は脳の特定部位での拡散係数は年齢において有意に減少しているとしており、部位の特定はできていないが、3D-CNN においても拡散係数の特徴から識別ができていると考えられる。また、Hus ら [22] は特定部位において FA 値が年齢において相関があるとしているが、本研究での FA 画像からは Mask 画像以上の識別率を示さなかったため、3D-CNN においては他の部位を特徴として見ようとしているのではないかと考える。

FA 画像・V2 画像・V3 画像においては年齢推定では Mask 画像より識別率が低いため、それぞれの持つ画像情報が脳の大きさ情報よりも識別に不確定要素として影響を大きく与えているのではないかと考える。

性別推定では DTI に続いて、FA 画像と L1 画像の識別率が高い結果となった性別はそこまでではないものの、L1 画像と FA 画像はベースラインより少し高い傾向にあるので、やや情報がある可能性があると考えられる。FA は拡散テンソルの異方性の強さを示す指標であり、L1 は FA を構成する拡散テンソルの固有値を指す画像であるため、

8.2 SVM・ロジスティック回帰を用いたモデル (c)

3D-CNN において男女識別は拡散テンソルの異方性の大きさの違いを見ていると考える。D.Pal ら [23] は全ての白質領域における FA 値の男女差があるとしており、画像認識において識別できていると考える。

標準化した画像の結果より、FA 画像と L3 画像においては、データセットにおけるチャンスレベルを大きく上回る識別率を示しており、異方性情報における年齢・性別の識別情報があると考えられる。

8.2 SVM・ロジスティック回帰を用いたモデル (c)

ロジスティック回帰モデルでの標準化偏回帰係数からは、右側海馬帯状束の表面積・放射状方向拡散係数が大きく、0.6 拡散サンプリング長比での非制限拡散が小さく、右側脳弓では異方性の強さ・枝の体積が大きく、末端領域の不規則性²が小さいほど年齢が高いと考えられる。左側脳弓では端点面積²の標準化偏回帰係数の重みが特に大きく、値が大きければ大きいほど年齢が高いと考えられる。性別においては、右側前方射方路の端部の総半径が大きく、曲がり度合いが小さいほど女性の特徴を持つと考えられる。また、左側垂直後頭葉の端部領域間距離と平均長が大きく、幹の体積が小さいほど女性の特徴を持つと考えられる。右側皮質延髄路では端点面積²の標準化偏回帰係数の重みが特に大きく、値が小さければ小さいほど男性の特徴を持つと考えられる。

8.3 学習コスト

学習にかかる時間は、モデル (a) では 6~7 時間、モデル (b) は約 2 時間、モデル (c) では約 5 分となった。3D-CNN を用いたモデル (b) はモデル (a) と比較して約 1/3 倍で学習を行え、モデル (c) では GPU を必要とせず学習ができ、モデル (a) と同程度の識別率を出すことができた。よって、モデル (c) を用いることで学習コストを大幅に下げることができるのではないかと考える。

8.4 トラクトグラフィー

本研究では DSI-studio を用いてトラクトグラフィーを数値データとして出力したが、描出されないなど多くの欠損となり、ROI によっては学習に必要なデータ数を集められなかった。撮像時の MRI 環境設定や自動ファイバートラッキングのパラメータ設定等が影響していると考えられるため、今後の研究が必要である。また、トラクトグラフィーそのものを 3 次元画像として出力することができればモデル (a)・モデル (b) との比較してより議論できるのではないかと考える。

第9章

結論

本研究では DTI を用いて白質の拡散異方性情報による性別・年齢の個人属性推定を 3D-CNN, SVM, ロジスティック回帰の機械学習を用いて行った。3D-CNN では異方性情報を持った画像が Mask 画像より高い識別率であるため、異方性情報を用いることでより高精度に性別・年齢を推定することができる。また、DTI をそのまま入力した場合と同程度の識別率を FSL 処理画像やトラクトグラフィ統計値から出すことができ、計算コストを少なく学習できることがわかった。ただし、特徴抽出に必要な時間が別途 (b):1 分 (c):6 時間/画像かかる。また、トラクトグラフィは被験者により描出される場所が異なるため、学習器で必要な部位が描出されないデータでは、識別ができないという問題があり (信頼性が低ければ描出自体は可能)、今後の研究が必要である。

謝辞

本研究を進めるにあたり、ご指導いただいた高知工科大学情報学群吉田真一教授に心から感謝いたします。本研究はトラクトグラフィ画像を生成するということができず、様々なソフトウェアを使ってみるなど試行錯誤の連続で進捗が全く生まれないこともありましたが、最後までご相談に乗ってくださり、サポートしていただいたおかげで論文として形にできました。吉田先生の知識の広さ、深さにはただただ尊敬の念でいっぱいです。学部の研究を活かした内容を修士でも行うことができ、強い興味を持って取り組むことができました。また、国際学会での発表を通して、とても貴重な経験をさせていただきました。深く感謝申し上げます。

高知工科大学情報学群濱村昌則教授、ならびに門田宏准教授には学部からの研究に引き続き、本研究の副査をして頂きました。お二方にはお忙しい中、中間発表ができなかったなどご迷惑をおかけしましたが、梗概や発表での至らない点などをご教授いただき、研究をより深いものとすることができました。深く感謝申し上げます。

また、四宮友貴助教にも、本研究の内容についても多くの助言をいただき、とても感謝しています。研究の基本的な考え方ははじめとする様々な場面でご教授いただき、またサポートしていただきました。深く感謝申し上げます。また、私たち同様に高知を飛び立つと伺っております。新天地でのご活躍を心よりお祈り申し上げます。

吉田研究室の皆様にも大変お世話になりました。研究室でとても楽しく過ごすことができたのは皆様のおかげです。本当に感謝しております。

4年間の大学生活に加え、2年間の大学院における様々な支援をしてくれた家族に深く感謝いたします。

最後に、これまで支えてくださった先生や友人、研究に協力していただいた方へ、6年間関わってきた全ての皆様へ、心からの感謝の気持ちと御礼を申し上げたく、謝辞に変えさせていただきます。

参考文献

- [1] Xinyang Feng, Zachary C Lipton, Jie Yang, Scott A Small, Frank A Provenzano, Alzheimer’s Disease Neuroimaging Initiative, Frontotemporal Lobar Degeneration Neuroimaging Initiativeほか. Estimating brain age based on a uniform healthy population with deep learning and structural magnetic resonance imaging. *Neurobiology of aging*, Vol. 91, pp. 15–25, 2020.
- [2] Takenobu Sasatani Kaechang Park. Shinichi Yoshida, Yuki Shinomiya. Prediction of human characteristics from brain structural mri using cnn. *International Symposium on Frontier Technology(ISFT-2019)*, pp. 529–533, 2019.
- [3] Yasuyuki Taki, Benjamin Thyreau, Shigeo Kinomura, Kazunori Sato, Ryoji Goto, Ryuta Kawashima, and Hiroshi Fukuda. Correlations among brain gray matter volumes, age, gender, and hemisphere in healthy individuals. *PloS one*, Vol. 6, No. 7, p. e22734, 2011.
- [4] Lixian Cao, Yanchun Liang, Wei Lv, Kaechang Park, Yasuhiro Miura, Yuki Shinomiya, and Shinichi Yoshida. Relating brain structure images to personality characteristics using 3d convolution neural network. *CAAI Transactions on Intelligence Technology*, Vol. 6, No. 3, pp. 338–346, 2021.
- [5] Cyril Poupon Chris A. Clark Sabina Pappata Nicolas Molko Hughes Chabriat Le Bihan MD, Jean - François Mangin. Diffusion tensor imaging: concepts and applications. *Journal of Magnetic Resonance Imaging*, No. 13(4).
- [6] Yunlong Wang, Fei Liu, Kunbo Zhang, Zilei Wang, Zhenan Sun, and Tieniu Tan. High-fidelity view synthesis for light field imaging with extended pseudo 4dcnn. *IEEE Transactions on Computational Imaging*, Vol. 6, pp. 830–842, 2020.
- [7] Robert Tibshirani. Regression shrinkage and selection via the lasso. *Journal of the*

参考文献

- Royal Statistical Society: Series B (Methodological)*, Vol. 58, No. 1, pp. 267–288, 1996.
- [8] Craig Saunders, Alexander Gammerman, and Volodya Vovk. Ridge regression learning algorithm in dual variables. 1998.
- [9] Arthur E Hoerl and Robert W Kennard. Ridge regression: applications to nonorthogonal problems. *Technometrics*, Vol. 12, No. 1, pp. 69–82, 1970.
- [10] Hui Zou and Trevor Hastie. Regularization and variable selection via the elastic net. *Journal of the royal statistical society: series B (statistical methodology)*, Vol. 67, No. 2, pp. 301–320, 2005.
- [11] B. Patenaude M. Chappell S. Makni T. Behrens C. Beckmann M. Jenkinson S.M. Smith. M.W. Woolrich, S. Jbabdi. Bayesian analysis of neuroimaging data in fsl. *NeuroImage*, No. 45.
- [12] S.M. Smith. Fast robust automated brain extraction. *Human Brain Mapping*, No. 17(3).
- [13] Jesper L. R. Andersson and Stamatios N. An integrated approach to correction for off-resonance effects and subject movement in diffusion mr imaging. *NeuroImage*, No. 125.
- [14] Paul McCarthy. Fsleyes, October 2021.
- [15] Ilona Lipp, Greg D. Parker, Emma C. Tallantyre, Alex Goodall, Steluta Grama, Eleonora Patitucci, Phoebe Heveron, Valentina Tomassini, and Derek K. Jones. Tractography in the presence of multiple sclerosis lesions. *NeuroImage*, Vol. 209, p. 116471, April 2020.
- [16] Robert Smith, David Raffelt, Jacques-Donald Tournier, and Alan Connelly. Quantitative streamlines tractography: methods and inter-subject normalisation. Technical report, OSF Preprints, July 2020. type: article.
- [17] Nagesh Adluru, Hui Zhang, Do P. M. Tromp, and Andrew L. Alexander. Effects

参考文献

- of DTI spatial normalization on white matter tract reconstructions. In *Medical Imaging 2013: Image Processing*, Vol. 8669, pp. 59–73. SPIE, March 2013.
- [18] Clint Greene, Matt Cieslak, and Scott T. Grafton. Effect of different spatial normalization approaches on tractography and structural brain networks. *Network Neuroscience*, Vol. 2, No. 3, pp. 362–380, September 2018.
- [19] Fang-Cheng Yeh. Shape analysis of the human association pathways. *bioRxiv*, 2020.
- [20] Biomedical Image Analysis Group. Ixi-dataset.
- [21] Khader M Hasan, F Gerard Moeller, and Ponnada A Narayana. Dti-based segmentation and quantification of human brain lateral ventricular csf volumetry and mean diffusivity: validation, age, gender effects and biophysical implications. *Magnetic resonance imaging*, Vol. 32, No. 5, pp. 405–412, 2014.
- [22] Jung-Lung Hsu, Alexander Leemans, Chyi-Huey Bai, Cheng-Hui Lee, Yuh-Feng Tsai, Hou-Chang Chiu, and Wei-Hung Chen. Gender differences and age-related white matter changes of the human brain: a diffusion tensor imaging study. *Neuroimage*, Vol. 39, No. 2, pp. 566–577, 2008.
- [23] Deepa Pal, Richa Trivedi, Sona Saksena, Abhishek Yadav, Manoj Kumar, Chandra M Pandey, Ram Kishore S Rathore, and Rakesh K Gupta. Quantification of age-and gender-related changes in diffusion tensor imaging indices in deep grey matter of the normal human brain. *Journal of Clinical Neuroscience*, Vol. 18, No. 2, pp. 193–196, 2011.