

平成 30 年度  
修士学位論文

機械学習による脳構造 MRI からの  
個人属性の推定

Prediction of Personal Property by  
applying Machine Learning  
from Brain Structural Magnetic Resonance Imaging

1215085 笹谷 健文

指導教員 吉田 真一

2019/2/27

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

## 機械学習による脳構造 MRI からの 個人属性の推定

笹谷 健文

近年、世界全体で高齢化が急速に進展しており、その中でも日本の高齢化の進行は急速である。そのため、日本では医療・健康診断が普及しており、中でも MRI などの脳に重点を置いた脳ドックと呼ばれる健康診断が普及しつつある。このような健康診断の普及により、医療データがビッグデータ化しており、それに対して画像認識技術や機械学習を用いた診断支援が数多く提案されているが、腫瘍や出血など目視で認識できる疾患の認識タスクが主であった。しかし、健康診断はリスクや兆候を検出・認知することが目的であるため、従来のような特徴工学による画像認識手法では、有効な検出機の構成が困難である。一方で、表面的には分かりづらい細かな健康状態・性質・体質の違いや、その未来予測等が長い時間をかけて脳にも影響し、見えにくい形ではあるものの、脳の解剖学的形態や構造に表れているという考え方がある。そこで、本研究では、人の状態や性質について脳の構造画像から予測する判別器を、機械学習を用いてデータから構成することを目指す。そのための最初の課題として、人の最も基礎的な性質の違いである、性別と年齢を対象として、脳構造 MRI 画像から推定する判別器を構築する。将来的には、健康状態や生まれ持った性質や生活習慣の推定までできることを目標とする。また、より高次元属性として、生活習慣と関係のある喫煙習慣の推定を脳構造 MRI から推定する。男女 358 人の MRI 構造画像から、Convolutional Neural Network(CNN) の中でも、2次元空間で特徴抽出を行なう 2D-CNN と 3次元空間で特徴抽出を行なう 3D-CNN の 2つのモデルで識別率を検証する。その結果、性別推定では、97.00%と高い識別率を持つモデルが 2D-CNN で構築され、3D-CNN においても

97.01%で識別可能なため性別に寄与する局所特徴が存在することを示す。灰白質部分のみの画像で同様のモデルを構築した場合、2D-CNN では 85.32%、3D-CNN では 83.71%と灰白質部分に性別の特徴があることを示す。年齢推定・喫煙推定では、学習データの loss と検証データの loss に乖離があるため、これらに寄与する明確な特徴が全脳画像・灰白質画像では検出できないことを示す。また、解剖学的区分である Brodmann Area を用いて性別推定を行った結果、思考・認知に関わる前頭回、視覚・聴覚に関わる側頭回で 75%を超える高精度な男女の識別が可能であるため、これらの部位及び脳機能で男女差があることが脳構造的な特徴から証明できることを示す。

キーワード 核磁気共鳴画像, 畳み込みニューラルネットワーク, 脳構造画像, T1 画像,  
ブロードマンエリア

# Abstract

## Prediction of Personal Property by applying Machine Learning from Brain Structural Magnetic Resonance Imaging

Takenobu SASATANI

In recent years, the aging population of the world is increasing. In Japan, particularly, in the case of countryside area the situation is tremendously serious. Therefore, in order to maintain the level of people's health, medical and health checkup is performed many scenes. Also brain checkup using MRI (magnetic resonance imaging) becomes popular in Japan, which is called brain dock. Due to the spread of such medical checkups, medical data is becoming big data, and there are many studies for diagnosis using image recognition techniques with traditional feature engineering. Conventional studies mainly aim at the recognition task of visually recognizable diseases such as tumor and bleeding. However, since health checks are aimed at detecting and recognizing future risks and signs of diseases, and there is not a clear image feature, it is more difficult to detect them using conventional image recognition. On the other hand, some researchers think that human internal health state and longtime life and foods affect human body including the anatomical shape and structure of brain. Therefore, in this research, we aim at estimation of human internal state using machine learning model. As the first step, we construct a predict model using machine learning to predict gender and age, which are the most fundamental property among people's characteristics from brain structural MRI. Furthermore, as a higher-order attribute, estimation of smok-

ing habit related to lifestyle habit is estimated from brain structural MRI. From the 358 MRI structural image, the accuracy is verified with 2 models of 2D-CNN, which extracts features in two-dimensional space and 3D-CNN, which extracts features in three-dimensional space in Convolutional Neural Networks (CNN). As a result, for the gender estimation, a model with accuracy of 97.00% is constructed using 2D-CNN and it can be predicted using 3D-CNN at 97.01%, indicating that local features contributing to gender exist. When constructing a similar model with an image of only gray matter part, accuracy of 2D-CNN is 85.32%, and that of 3D-CNN is 83.71%, which derive that the gray matter part has characteristics of gender. In prediction age and smoking, since there is a divergence in the loss between the learning data and the validation data, it is shown that definite features contributing to them can not be detected with whole brain image and gray matter image. In addition, as a result of gender using Brodmann Area which is an anatomical division, it is possible to predict male and female with a high accuracy exceeding 75% in the frontal gyrus related to thinking and cognition, the temporal gyrus related to vision and hearing. As a conclusion, it is possible to predict male and female from a brain structural image and there may exist some pattern or features to discriminate the distinction of sex in our brain anatomical structure.

***key words*** Magnetic Resonance Imaging, Convolutional Neural Network, Structural Brain Image, T1-weighted image

# 目次

第 1 章	序論	1
第 2 章	関連研究	3
第 3 章	機械学習による脳画像からの 患者要素推定	5
3.1	データセット	6
3.1.1	灰白質画像	6
3.1.2	Brodmann Area 画像	6
3.2	機械学習における前処理	7
3.2.1	スライスの補間	7
3.2.2	正規化	7
3.2.3	交差検証法によるデータ分割	8
3.3	シミュレーション実行環境	8
3.4	推定タスク	9
3.4.1	性別推定	9
3.4.2	年齢推定	10
3.4.3	喫煙量推定	10
第 4 章	MRI 脳画像の前処理	12
4.1	Resampling: 標準化	12
4.2	Segmentation: 分割化	13
4.3	機能領域ごとの分割化	13
4.3.1	IBASPM — Individual Brain Atlases using Statistical Parametric Mapping	14

## 目次

4.3.2	Brodmann Area . . . . .	14
<b>第 5 章</b>	<b>機械学習手法</b>	<b>15</b>
5.1	Convolutional Neural Network (CNN) . . . . .	15
5.1.1	基本構造 . . . . .	15
	畳み込み層 — Convolutional Layer . . . . .	16
	プーリング層 — Pooling Layer . . . . .	17
	全結合層 — Full Connection Layer . . . . .	18
5.1.2	3D-CNN . . . . .	19
5.1.3	過学習制御機構 . . . . .	20
	Dropout . . . . .	20
	Batch Normalization . . . . .	21
5.1.4	特徴可視化手法 . . . . .	22
	中間層の出力の可視化 . . . . .	22
	Grad-CAM . . . . .	22
5.2	Passive Aggressive Classifier . . . . .	23
<b>第 6 章</b>	<b>推定モデル</b>	<b>25</b>
6.1	2D-CNN モデル . . . . .	25
6.1.1	3次元 MRI データへの適用 . . . . .	25
6.1.2	ネットワーク構成 . . . . .	25
6.1.3	評価値の算出方法 . . . . .	26
6.2	3D-CNN モデル . . . . .	26
6.2.1	ネットワーク構成 . . . . .	27
<b>第 7 章</b>	<b>推定結果</b>	<b>30</b>
7.1	性別推定 . . . . .	30

## 目次

7.1.1	3D-CNN の乱数による影響 . . . . .	31
7.1.2	男女間における特徴マップ . . . . .	31
	中間層の出力 . . . . .	32
	Grad-CAM . . . . .	41
7.2	年齢推定 . . . . .	41
7.3	喫煙量推定 . . . . .	42
<b>第 8 章</b>	<b>Brodmann Area 別の推定結果</b>	<b>46</b>
8.1	性別推定 . . . . .	46
8.2	高精度な領野を全て用いた学習 . . . . .	47
<b>第 9 章</b>	<b>まとめ</b>	<b>50</b>
	<b>参考文献</b>	<b>52</b>
	<b>謝辞</b>	<b>55</b>
付録 A	交差検証法での各検証結果	58
付録 B	性別推定における特徴マップ	61

# 目次

2.1	既存研究と本研究の違い . . . . .	4
3.1	推定モデル概要 . . . . .	5
3.2	スライス補間 . . . . .	7
3.3	K 分割交差検証法 . . . . .	8
3.4	検診者の性別分布 . . . . .	9
3.5	検診者の年齢分布 . . . . .	10
3.6	健診者の喫煙分布 . . . . .	11
4.1	Resampling 処理 . . . . .	12
4.2	Segmentation 処理 . . . . .	13
4.3	Brodmann Area . . . . .	14
5.1	CNN の基本構造 . . . . .	16
5.2	左:畳み込み層, 右:畳み込み処理 . . . . .	17
5.3	プーリング層 . . . . .	18
5.4	3DCNN の畳み込み処理 . . . . .	19
5.5	Dropout . . . . .	20
5.6	Batch Normalization 概要 . . . . .	21
5.7	CAM & Grad-CAM の構成 . . . . .	23
5.8	Passive Aggressive Algorithm の概要 . . . . .	24
6.1	各断面画像における, 2次元畳み込み . . . . .	26
6.2	Neural Network モデルの評価方法 . . . . .	28
7.1	第1プーリング層の特徴マップ — 男性 — Sagittal . . . . .	35

## 目次

7.2	第1 プーリング層の特徴マップ — 女性 — Sagittal . . . . .	36
7.3	第1 プーリング層の特徴マップ — 男性 — Coronal . . . . .	37
7.4	第1 プーリング層の特徴マップ — 女性 — Coronal . . . . .	38
7.5	第1 プーリング層の特徴マップ — 男性 — Horizontal . . . . .	39
7.6	第1 プーリング層の特徴マップ — 女性 — Horizontal . . . . .	40
7.7	Grad-Cam による特徴マップ . . . . .	43
7.8	結果: 年齢推定の真値と予測値の散布図 . . . . .	44
7.9	結果: 学習過程 — 喫煙推定 — 2D-CNN . . . . .	45
8.1	Brodmann Area ごとの性別推定結果 . . . . .	47
8.2	学習が収束しない場合の学習推移 . . . . .	49
8.3	Brodmann Area 27 . . . . .	49
B.1	第2 プーリング層の特徴マップ — 男性 — Sagittal . . . . .	62
B.2	第3 プーリング層の特徴マップ — 男性 — Sagittal . . . . .	62
B.3	第2 プーリング層の特徴マップ — 女性 — Sagittal . . . . .	63
B.4	第3 プーリング層の特徴マップ — 女性 — Sagittal . . . . .	63
B.5	第2 プーリング層の特徴マップ — 男性 — Coronal . . . . .	64
B.6	第3 プーリング層の特徴マップ — 男性 — Coronal . . . . .	64
B.7	第2 プーリング層の特徴マップ — 女性 — Coronal . . . . .	65
B.8	第3 プーリング層の特徴マップ — 女性 — Coronal . . . . .	65
B.9	第2 プーリング層の特徴マップ — 男性 — Horizontal . . . . .	66
B.10	第3 プーリング層の特徴マップ — 男性 — Horizontal . . . . .	66
B.11	第2 プーリング層の特徴マップ — 女性 — Horizontal . . . . .	67
B.12	第3 プーリング層の特徴マップ — 女性 — Horizontal . . . . .	67

# 表目次

3.1	データセット概要 . . . . .	6
3.2	シミュレーション実行環境 . . . . .	9
3.3	喫煙に関する問診内容 . . . . .	11
6.1	ネットワーク構成 1 — 2D-CNN . . . . .	27
6.2	ネットワーク構成 — 3D-CNN . . . . .	29
6.3	ネットワーク構成 — Cole’s . . . . .	29
7.1	結果: 性別推定 — 2D-CNN . . . . .	31
7.2	結果: 性別推定 — 2D-CNN — 灰白質 . . . . .	32
7.3	結果: 性別推定 — 3D-CNN . . . . .	32
7.4	結果: 性別推定 — 3D-CNN — 灰白質 . . . . .	33
7.5	5-Fold 交差検証法による性別推定の結果 — Passive Agressive Classifier — Whole Brain . . . . .	33
7.6	5-Fold 交差検証法による性別推定の結果 — 3DCNN — Whole Brain . . . . .	33
7.7	Down Scaling での 2D, 3D-CNN モデルの出力サイズ & パラメータ数 . . . . .	34
7.8	3D-CNN における, 各 Fold での識別率の標準偏差 . . . . .	34
7.9	3D-CNN における, モデルの初期値シード値ごとの識別率の標準偏差 . . . . .	34
7.10	結果: 年齢推定 — 2D-CNN . . . . .	41
7.11	結果: 年齢推定 — 3D-CNN . . . . .	42
7.12	結果: 喫煙推定 — 2D-CNN . . . . .	45
8.1	75%以上の精度で性別識別可能な Brodmann Area 領野 . . . . .	48
8.2	高精度な Brodmann Area を用いた性別推定 . . . . .	48

## 表目次

A.1	5-Fold 交差検証法による性別推定の評価 — 2DCNN — Whole Brain . . .	59
A.2	5-Fold 交差検証法による性別推定の評価 — 2DCNN — Gray Matter . . .	60

# 第 1 章

## 序論

世界全体で高齢化が急速に進展している。世界の総人口に占める 65 歳以上の割合は、1950 年の 5.1%から 2015 年には 8.3%まで上昇し、2060 年には 17.8%まで増加すると見込まれている。さらに、日本の現状として、2017 年の 65 歳以上人口は 3,515 万人と総人口の 27.7%を占める高齢化社会となっている。それに対して、日本における医師の総数は 2016 年時点で 319,480 人、2014 年からの増減率が 2.7%と急速な高齢化の推移に追いついていない [1]。また、高知県のような地方では、高齢化が都市部よりも進んでいる上、医師不足も深刻である [2]。この問題の一つの解決案として、画像処理技術などの工学的手法によって、診断や検査を自動化する取り組みが行われている。

MRI 等の画像診断の自動化に関する研究は、CAD(Computer-Aided Diagnosis, コンピュータ支援診断)のように画像認識技術を用いた診断支援から始まり、近年では機械学習を用いた診断の自動化が研究されている。これらは、腫瘍や出血、形態異常など目で見てわかるものの認識が主である [3]。

脳の MRI 構造画像について、明確な画像特徴がないものについても、多くの脳画像データから、VBM(Voxel Based Morphometry)を用い、全脳から灰白質・白質の容積比を算出し、統計的にそれらとアルツハイマー型認知症 (AD) の関係性を導くものが提案・実用化されている。また、機械学習を用いた脳機能画像 (fMRI) と精神疾患との関係として、サポートベクターマシン (Support Vector Machine) を用いて、統合失調症・双極性障害と健康体の 3 クラス分類を行い、統合失調症と健康体が 90%、統合失調症と双極性障害が 88%、健康体と双極性障害が 60%の精度で分類可能であるという報告がある [4]。更には、知覚、認知、認識状態との関係を導く脳情報復号 (ブレインデコーディング) も研究されている。

このように、画像診断として明確な画像特徴を定義するものから始まり、近年は大量に蓄積された画像データと機械学習を用いて画像診断を行なうものの研究が進んでいる。これらの研究は、患者の病変を見つけ、診断することを目的とするものが多いが、近年は、未病の患者の健康状態、更に未来の健康状態予測が望まれている。人の性質、性格、嗜好は遺伝的な形質と、生育環境で後天的に得てきたものの両者の影響を受けると考えられ、それらのうち一部は、脳の構造にも影響を与えると考えることも可能である [5].

そこで本研究では、人の性質として最も根源的な、性別と年齢を対象として、データと機械学習のみでそれを予測することができるか、そして、更に難しいテーマとして、喫煙といった日常行動を導くことができるかを研究する。

## 第 2 章

# 関連研究

MRI 等の画像診断の自動化に関する研究には様々なものがある。CAD(Computer-Aided Diagnosis, コンピュータ支援診断)のように画像認識技術を用いた診断支援から始まり、近年では機械学習を用いた診断の自動化が研究されている。これらは、腫瘍や出血、形態異常など目で見てわかるものの認識が主であった [3]。

脳の MRI 構造画像について、明確な画像特徴がないものについても、多くの脳画像データから、VBM(Voxel Based Morphometry) を用い、全脳から灰白質・白質の容積比を算出し、統計的にそれらとアルツハイマー型認知症 (AD) の関係性を導くものが提案・実用化されている。また、機械学習を用いた脳機能画像 (fMRI) と精神疾患との関係として、サポートベクターマシン (Support Vector Machine) を用いて、統合失調症・双極性障害と健康体の 3 クラス分類を行い、統合失調症と健康体が 90%、統合失調症と双極性障害が 88%、健康体と双極性障害が 60%の精度で分類可能であるという報告がある [4]。更には、知覚、認知、認識状態との関係を導く脳情報復号 (ブレインデコーディング) も研究されている。このように、画像診断として明確な画像特徴を定義するものから始まり、近年は大量に蓄積された画像データと機械学習を用いて画像診断を行なうものの研究が進んでいる。

これらの研究は、患者の病変を見つけ、診断することを目的とするものが多いが、近年は、未病の患者の健康状態、更に未来の健康状態予測が望まれている。人の性質、性格、嗜好は遺伝的な形質と、生育環境で後天的に得てきたものの両者の影響を受けると考えられ、それらのうち一部は、脳の構造にも影響を与えると考えることも可能である [5]。

そこで本研究では、図 2.1 に示すように、人の性質として最も根源的な、性別と年齢を対象として、データと機械学習のみでそれを予測することができるか、そして、更に難しい

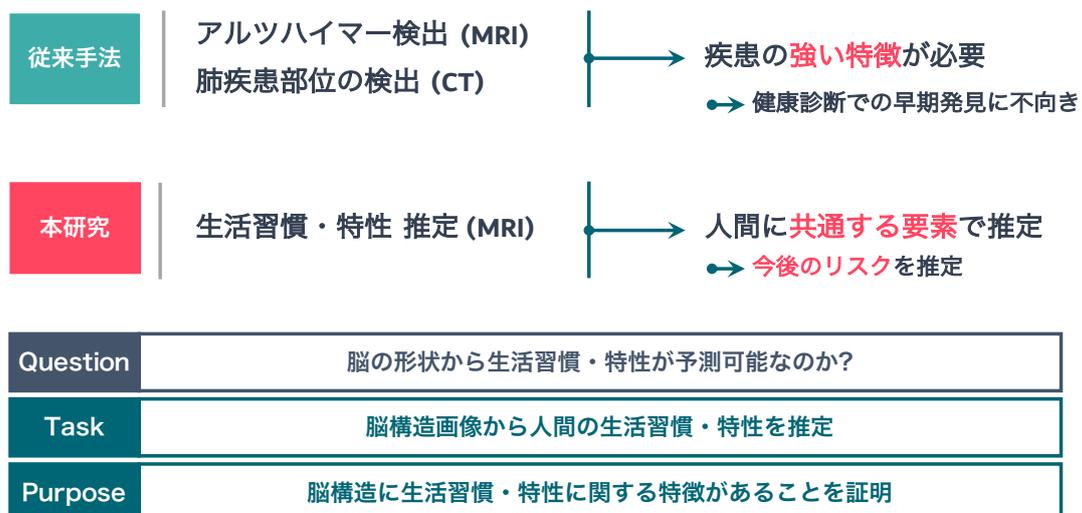


図 2.1: 既存研究と本研究の違い

テーマとして、喫煙といった日常行動を導くことができるかを研究する。

# 第 3 章

## 機械学習による脳画像からの 患者要素推定

本章では、MRI 構造画像から被験者の属性要素を推定に用いた環境及び推定手法について論ずる。図 3.1 に本研究の全体像を示す。脳構造情報から、各属性要素を推定するモデルを構築することで、属性要素と脳構造の間に相関があることを証明する。撮像された全脳画像や灰白質、白質など神経細胞の種類で定義された領域における構造情報から各属性推定モデルを構築する。

また、Brodmann Area や IBASPM など解剖学・脳機能的区分で定義された領域のみを用いたモデルの構築によって、各属性と各領域での相関を検証する。

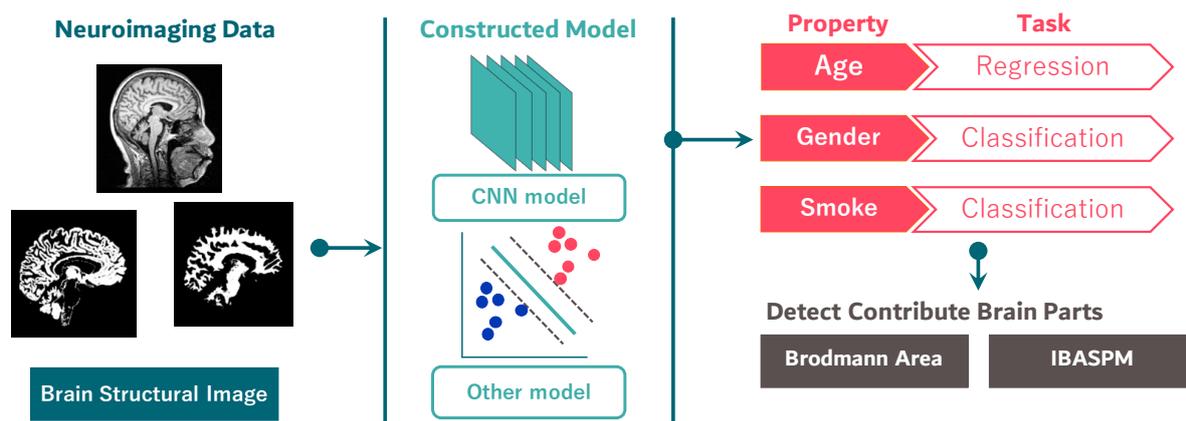


図 3.1: 推定モデル概要

### 3.1 データセット

表 3.1: データセット概要

検診者人数	368 人
男女比	210 : 158

## 3.1 データセット

データセットは、実際の脳ドック検診者のデータを用いた。データラベルの構成要素は表 3.1 に示す。

脳ドックに検診において、様々な部位の画像を異なる方法で撮像するが、各要素推定には、頭部の T1 構造画像を用いる。また各推定タスクにおいて、ラベルや T1 画像の存在しない検診者は除外する。また、MRI で撮像したそのままのデータである全脳画像の他に、Resampling 処理を行った Resampled 画像、Segmentation 処理によって生成した灰白質画像、Brodmann Area 画像での各タスクの推定を行なう。

### 3.1.1 灰白質画像

まず、Resampling 処理で脳の形状を標準化した後に、Tissue Probability Maps によって灰白質部分のみを抽出した灰白質画像を学習に用いることで、頭蓋骨などの余分な情報を除去し、灰白質において各タスクに寄与している部位があるのかを検証する。また、MNI space に変換しているため、スライス数を含めデータの形は統一されている。

### 3.1.2 Brodmann Area 画像

Brodmann Area で定義された 47 の領域の各部位のみで学習を行い、各推定タスクにおいて精度の高い部位を特定することで、寄与している部位の特定を行なう。

## 3.2 機械学習における前処理

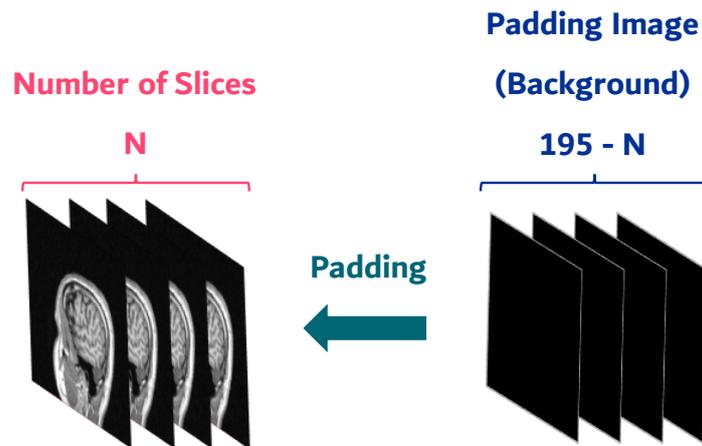


図 3.2: スライス補間

## 3.2 機械学習における前処理

### 3.2.1 スライスの補間

MRI 構造画像のスライス数は、被験者の頭部の大きさによって異なる。しかし CNN では入力画像のサイズを合わせる必要がある。一般的には、Resampling 処理でサイズを合わせるが、アフィン変換によって一部の脳構造が変化してしまうため、局所的特徴を抽出する CNN では影響がある可能性がある。そこで、図 3.2 のように背景画像 (Pixel 値: 0) のスライスを後頭部から後に補間することで、頭部の形状を変化させることなく CNN に学習させることを可能にしている。

### 3.2.2 正規化

本実験で用いた NIFTI フォーマットは 32bit で保存されており、今回用いるデータセットでは  $[0, 1900]$  の範囲のボクセル値となる。しかし、Segmentation 処理によって抽出された各部位の画像は、 $[0, 1]$  に変換されている。機械学習アルゴリズムでは、正確なパラメータ更新を行なうため特徴空間を  $[0, 1]$  で正規化する。これにより、異なる尺度の特徴同士を同じ空間で計算することができる。本研究では min-max 正規化を用いる。

### 3.3 シミュレーション実行環境

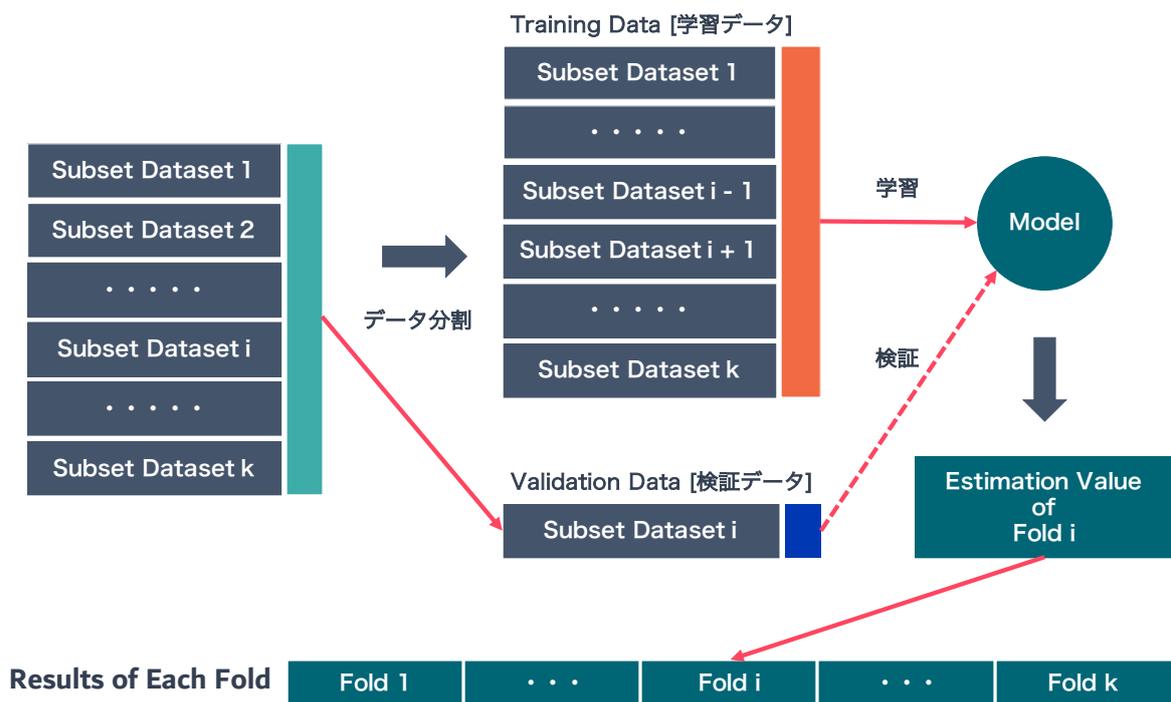


図 3.3: K 分割交差検証法

#### 3.2.3 交差検証法によるデータ分割

生成した推定モデルの評価として、K-分割交差検証法 (K-Fold Cross-Validation : CV) を用いて図 3.3 のように K 等分に分割し、各分割データが必ず 1 度検証データになるように学習データと検証データに分割する。これによって、学習データの偏りによる汎化性能の低下を抑制することが可能となる。また、各エポックにおいて学習データと検証データで精度に乖離が生じた場合に過学習が行われていると判断できるため、検証データでの精度の推移による学習の早期停止 (Early Stopping) を行なうことで、学習モデルの汎化性能を維持することが期待できる。

### 3.3 シミュレーション実行環境

2D-CNN モデル及び 3D-CNN モデルは Keras(Tensorflow backend) を用い、表 3.2 の環境でシミュレーションを行った。

## 3.4 推定タスク

表 3.2: シミュレーション実行環境

Property	Detail
CPU	Intel(R) Xeon(R) CPU E5-2620 v4 @ 2.1GHz
GPU	GeForce GTX 1080 Ti
OS	Ubuntu 16.04 LTS
Deep Learning Frameworks	Keras, Tensorflow

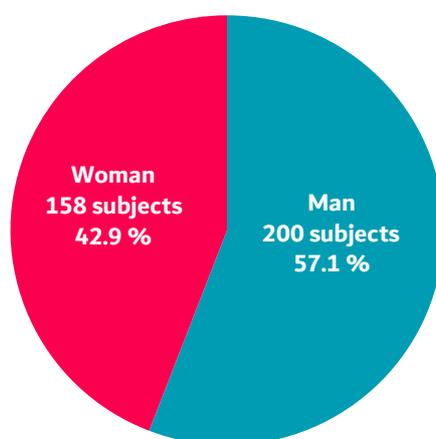


図 3.4: 検診者の性別分布

## 3.4 推定タスク

### 3.4.1 性別推定

検診者の性別を推定するタスクを“Man”と“Woman”の2クラス分類タスクとして推定実験を行う。各要素の分布は図 3.4 に示す。

推定モデルの評価は、式 (3.1) で算出した精度 (Accuracy) にて行う。

$$\text{Accuracy} = \frac{\text{正しい推定をした被験者データ数}}{\text{全被験者データ数}} \quad (3.1)$$

### 3.4 推定タスク

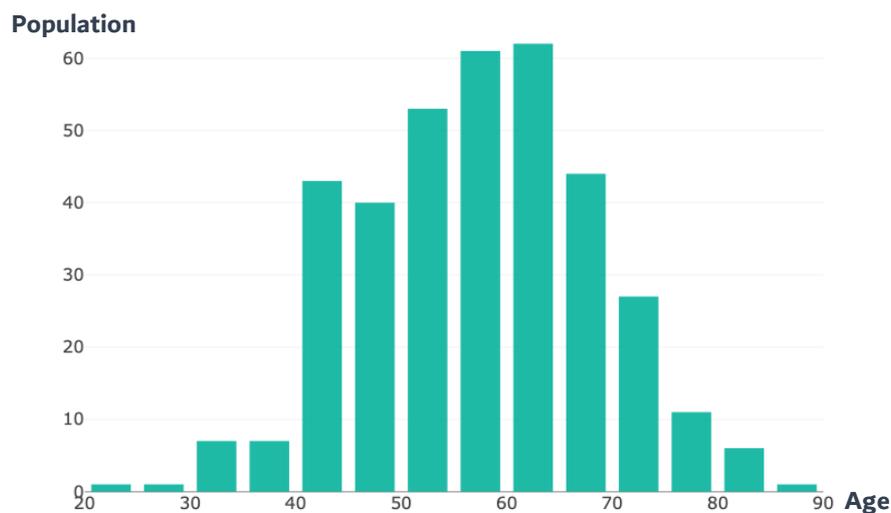


図 3.5: 検診者の年齢分布

#### 3.4.2 年齢推定

健診者の年齢を推定するタスクを回帰推定タスクとして推定実験を行う。各年齢の分布は図 3.5 に示す。

推定モデルの評価は、式 (3.2) で算出した平均 2 乗誤差 (Mean Squared Error) にて評価を行なう。

$$\text{MSE} = \frac{1}{\text{全被験者データ数}} \sum (\text{推定年齢} - \text{実際の年齢})^2 \quad (3.2)$$

#### 3.4.3 喫煙量推定

喫煙状態の推定には、まず“喫煙中”、“禁煙中”、“未経験”の 3 クラス分類を行なうことで、喫煙における脳構造の変化が生じるかを検証する。各クラスの定義は、脳ドックの間診調査票の内容を参照し、以下の質問に対する回答内容をクラスラベルに用いる。また、図 3.6 は各喫煙クラスの分布を表示している。

推定モデルの評価は、式 (3.1) で算出した精度 (Accuracy) にて評価を行なう。

### 3.4 推定タスク

表 3.3: 喫煙に関する問診内容

質問内容	解答欄
タバコは吸いますか?	はい or いいえ or やめた
1日何本何年間? (はいの場合)	1日 $x$ 本 $y$ 年間
どの期間? 1日何本? (やめたの場合)	$a - b$ 歳 1日 $x$ 本

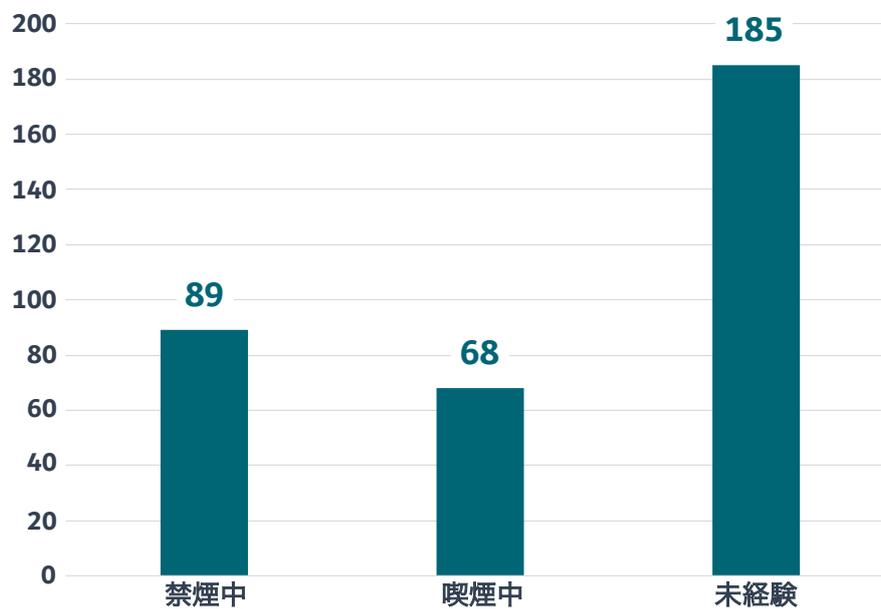


図 3.6: 健診者の喫煙分布

## 第 4 章

# MRI 脳画像の前処理

MRI 画像には、各被験者間に頭部の大きさや撮像時の微細な動きによって、個人差やノイズが生じる。機械学習においてノイズは誤識別の要因となるため削除または軽減する必要がある。そのため、本研究では脳解析で一般的に用いられる、Resampling 処理と Segmentation 処理を行う。今回はこの処理を SPM12 上で実行した。

### 4.1 Resampling: 標準化

頭部の大きさや形状による個人差を軽減するために、各被験者の T1-MRI 画像をアフィン変換によって標準脳と呼ばれるテンプレート画像に合わせる。一連の流れを図 4.1 に示す。

本研究では、MNI space テンプレートを用いて Resample 処理を行う。

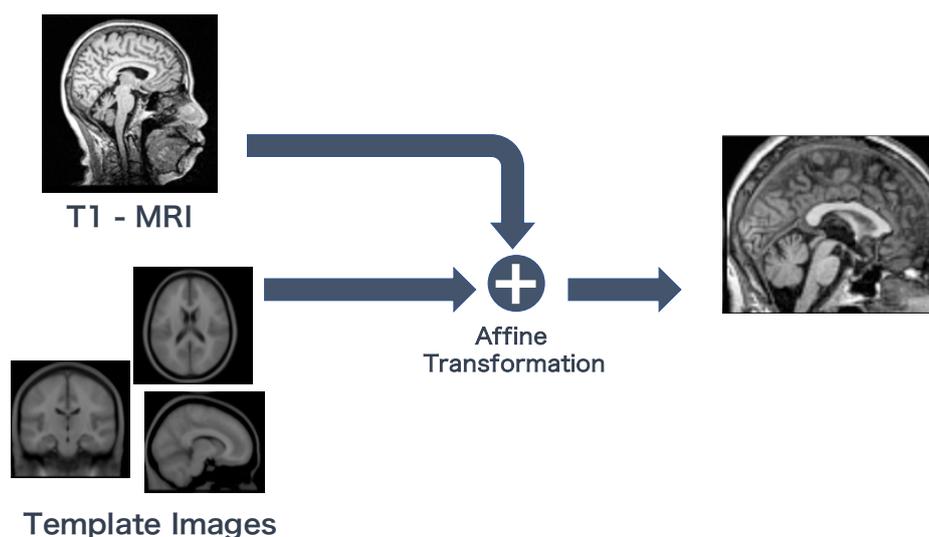


図 4.1: Resampling 処理

## 4.2 Segmentation: 分割化

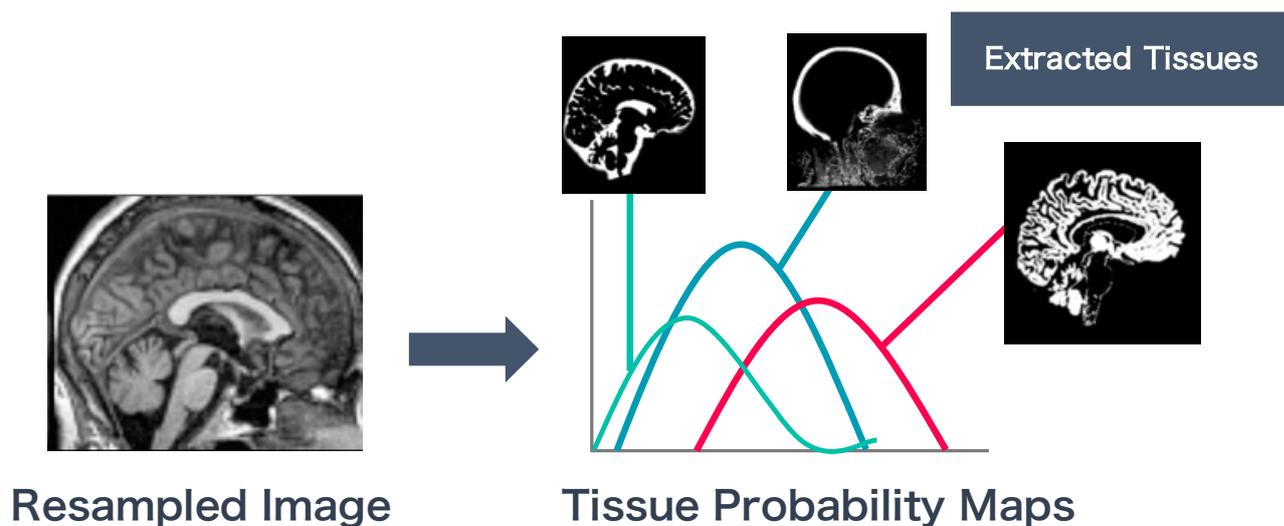


図 4.2: Segmentation 処理

## 4.2 Segmentation: 分割化

被験者間の各脳部位の占める割合による個人差を軽減するために、MRI 画像の領域分割 (Segmentation) は非常に重要な処理の一つであり、図 4.2 に示すような Tissue Probability Map という各ボクセルを領域ごとの確率マップにマッチングさせる統計的推定によって全脳画像から灰白質・白質・頭蓋骨・脳脊髄液・脳外軟部組織に分割する。Segmentation 処理は以下の手順で行われる [6]:

- Resampling 処理で個人差の軽減.
- 生成済みの混合分布モデルによって、各ボクセルの確率分布を算出し、領域を決定.
- 剛体変換を用いて各脳部位の領域を Resampling 処理に再登録.

## 4.3 機能領域ごとの分割化

Tissue Probability Map による分割は、大域的な部位でしか分割できないため細かな部位の解析が困難となる。そこで神経科学の分野で定義された、脳領域をマスク処理によって抽出し、脳を領域分割する。本研究では、IBASPM(Individual Brain Atlases using

### 4.3 機能領域ごとの分割化

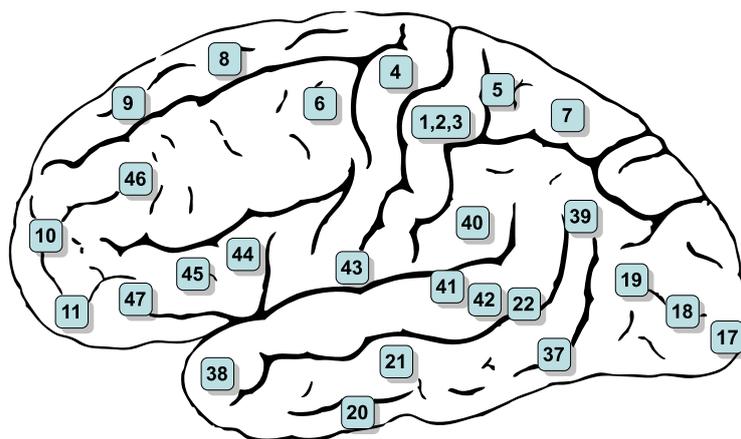


図 4.3: Brodmann Area

Original :<https://commons.wikimedia.org/wiki/File:Gray726-Brodman.svg>

Statistical Parametric Mapping) と Brodmann area によって定義された脳領域で分割処理を行なう。各脳領域のマスク画像生成には、WFU Pickatlas を使用する [7][8]。

#### 4.3.1 IBASPM — Individual Brain Atlases using Statistical Parametric Mapping

脳解析ソフトウェアの SPM(Statistical Parametric Mapping) によって独自に定義されたマッピング手法で、解剖学的構造における分割を Registration 処理ベースで行うことで、各領域を定量的に定義することができる [9]。

#### 4.3.2 Brodmann Area

1909 年に解剖学的構造に基づいて脳機能を区別できるように、Korbinian Brodmann によって公開された細胞構築マップであり、大脳皮質を 47 の異なる領域に分割したものである [10]。本研究では、各部位のみを学習させて、各推定タスクに寄与している部位の特定を試みる。

## 第 5 章

# 機械学習手法

### 5.1 Convolutional Neural Network (CNN)

Convolutional Neural Network (畳み込みニューラルネットワーク) は、画像分類をはじめ、様々な認識タスクにおいて高精度な識別が可能なニューラルネットワークである。福島らは 1980 年代に人間の受容体の視覚認識構造を数理モデル化した Neocognitron を提案し、教師なし学習として特徴抽出モデルを提案した [11]。この Neocognitron を教師あり学習に改良したものが Yann らによって提案された CNN である [12]。CNN は Neocognitron のモデルを誤差逆伝搬法による勾配計算によって教師あり学習を実現している。

#### 5.1.1 基本構造

CNN は特徴抽出部と識別部の 2 つから構成されており、特徴抽出部は入力データの局所特徴を抽出する機構であり、画像内の部分領域において特徴的な勾配を算出するフィルタをかける畳み込み層 (Convolutional Layer) と畳み込み層の特徴をより不変的な特徴にするために平均や最大値などで統合するプーリング層 (Pooling Layer) の 2 つから構成され、SIFT(Scale Invariant Feature Transform) などの局所特徴の計算と基本的に同じ構造で局所的な特徴マップ (Feature Map) として算出する [13]。

識別部は、特徴抽出部で抽出した特徴マップを用いて、最終的な識別を行なう機構である。隣接層間のノードすべてを結合した層である全結合層 (Fully Connected Layer) によって特徴マップの特徴を任意の出力層へ写像する結合を行なう。CNN の基本構造を図 5.1 に示す。

## 5.1 Convolutional Neural Network (CNN)

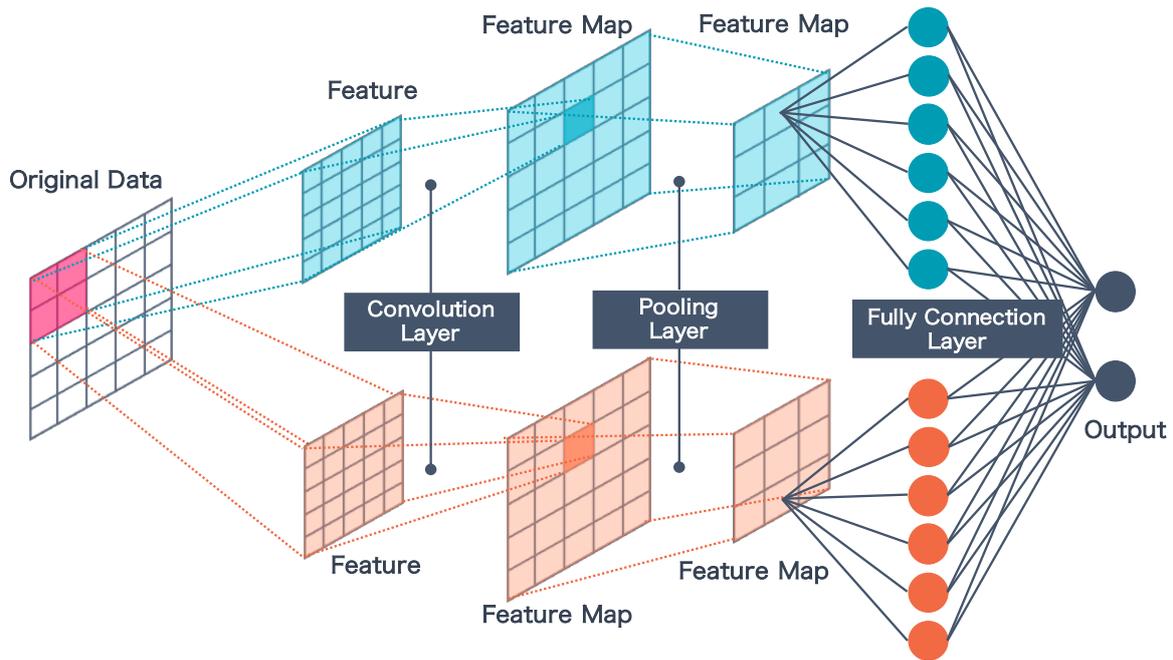


図 5.1: CNN の基本構造

### 畳み込み層 — Convolutional Layer

図 5.2 は、畳み込み層におけるフィルタ処理を示す。左図のように解像度  $S * S$  のチャンネル数  $C$  の入力画像 (Original Image) に対して、フィルタを畳み込む処理を行なう。これは、一般的な画像処理でのフィルタを適応して、画像を平滑化、エッジ検出することと基本的に同じである [14]。入力画像の各チャンネルに任意のサイズのフィルタを畳み込み、全チャンネルの畳み込み結果を加算する。2D-CNN の場合、この計算結果は 1 チャンネルの画像形式をとる。特徴マップ  $u_{ij}$  はフィルタを  $w_{ijk} ((i, j, k) \in [0, L - 1] \times [0, L - 1] \times [1, N])$  と書くと、

$$u_{ij} = \sum_{k=1}^N \left[ \sum_{(p,q) \in P_{ij}} x_{pqk} w_{p-i,q-j,k} \right] + b_k \quad (5.1)$$

のように計算する。また、 $P_{ij}$  は画像中の画素  $(i, j)$  を頂点とするサイズ  $L \times L$  画素の正方形領域である。

$$P_{ij} = [(i + i', j + j') | i' = 0, \dots, L - 1, j' = 0, \dots, L - 1] \quad (5.2)$$

また、ネットワークの表現力を向上させるために、カーネルによる畳み込み処理によって抽出された特徴マップに活性化関数 (Activation Function) を適応する。これにより、

## 5.1 Convolutional Neural Network (CNN)

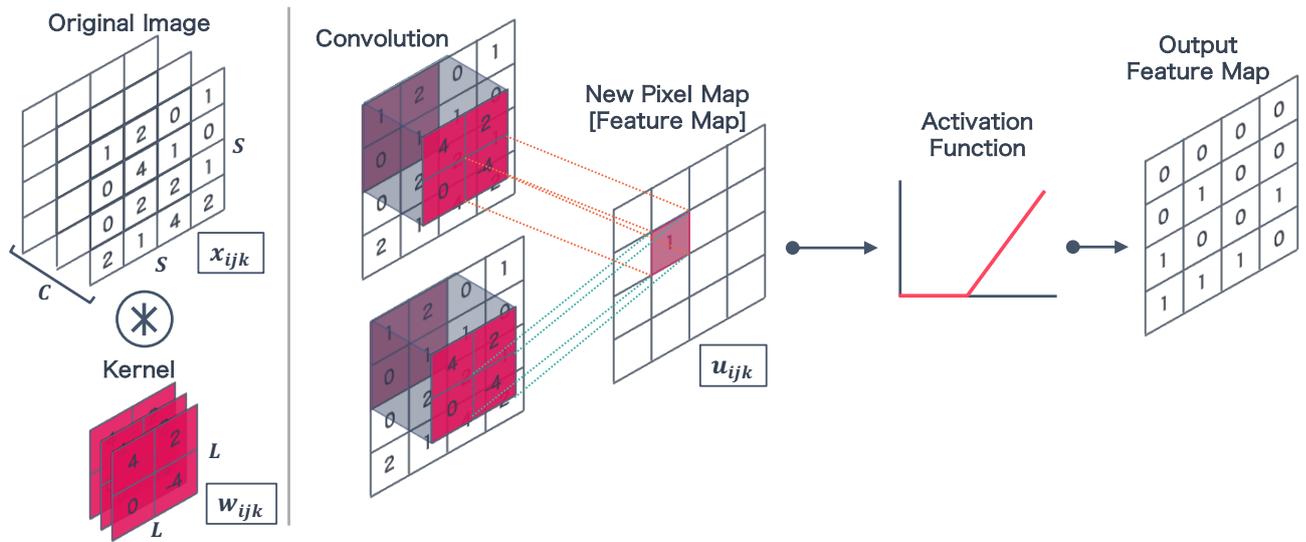


図 5.2: 左:畳み込み層, 右:畳み込み処理

線形関数で近似できない複雑な特徴表現を学習することが可能になる [14]. 本研究では, ReLU(Rectified Linear Unit) 関数を主に用いる. この関数は,

$$\alpha_{\text{ReLU}}(x) = \log(1 + \exp(x)) \simeq \max(0, x) \quad (5.3)$$

により高速に出力計算, 勾配計算が可能となる. また,  $\max(0, x)$  という関数の性質上, 多くの値が 0 のスパースな出力・勾配となり, ネットワーク自体がスパースな構成となる. これによって, 深層ネットワークになっても誤差が消失せず伝搬するため, 通常の誤差逆伝搬法で勾配消失問題が抑制できる [15]. 以上の計算によって, 人間の受容野における局所的な神経反応を重み共有によって実現している.

### プーリング層 — Pooling Layer

プーリング層では, 畳み込み層で算出された特徴マップにおけるフィルタ応答の情報を一部捨てることで, 画像内に現れる特徴の微小な変化に対する不変性を確保することを目的としている. 図 5.3 では, プーリング処理の例を表している. 畳み込み層から出力された特徴マップの一部の領域内にある出力値を 1 つにまとめる処理を行なう. 図のようにストライド  $s$  を 2 に設定すると, プーリング層によって特徴マップのサイズが半分になり, 特徴をより

## 5.1 Convolutional Neural Network (CNN)

### Convolutional Layer Output

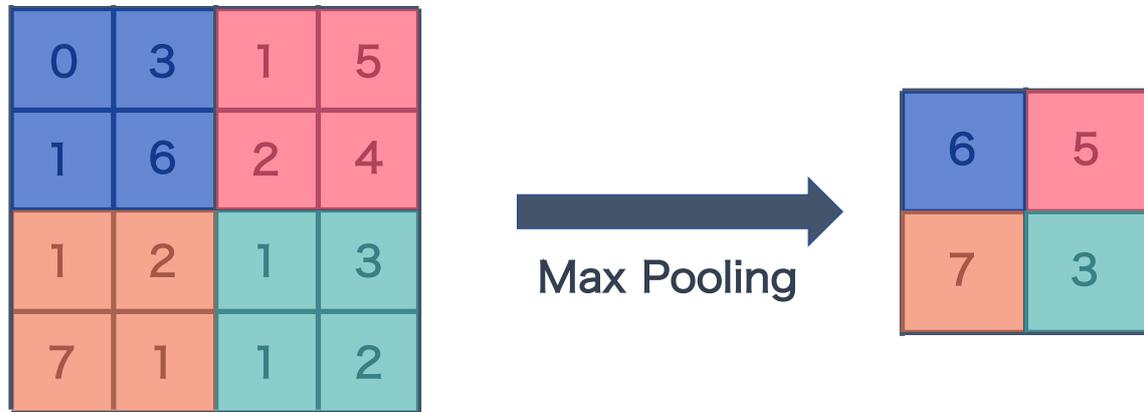


図 5.3: プーリング層

抽象的に表現することが可能となる。

プーリングには、主に2つの方法がある。1つはある領域内の出力の平均を取る平均プーリング (Average Pooling) で、もう1つはある領域内の出力の最大値を取る最大プーリング (Max Pooling) がある。これらによって、情報の圧縮を行なう。また畳み込み層と異なりプーリング層には学習するパラメータが存在しない、その上、プーリング層からの出力に活性化関数を適用しないのが一般的である。本研究では、一般的に精度の向上が期待できる最大プーリングを主に使用する [16]。

### 全結合層 — Full Connection Layer

畳み込み層とプーリング層にて、抽出・抽象化された特徴を用いて識別を行なう役割を担う層である。隣接層間のノードすべてを結合した層であり、出力層とプーリング層の間に配置される。全結合層の出力に活性化関数を適用することで、分類・回帰問題として解釈可能な出力に変換される。分類問題は Softmax 関数を用い、定義された各クラスのノードに確率変数が割り当てられる出力となる。回帰問題は正規化したデータの場合、Logistic 関数を用いることでノード1つの出力層から回帰推定値が算出されるように設計される [14]。

## 5.1 Convolutional Neural Network (CNN)

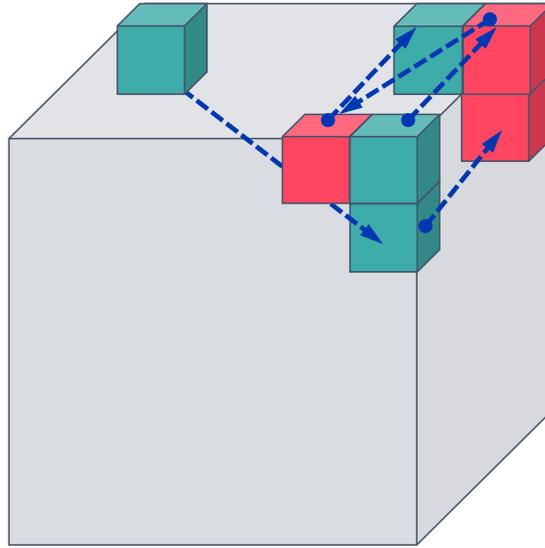


図 5.4: 3DCNN の畳み込み処理

### 5.1.2 3D-CNN

一般的に CNN は 2 次元の画像を対象にしたニューラルネットワークの構成をしているが, [17] や [18] のように動画データの場合, 2 次元画像+フレームの 3 次元構成となる. また, フレーム間の情報には関係性があり, 3 次元空間で特徴設計することが有意であるため, 2 次元画像 + 1 次元の付加特徴を追加した 3 次元のデータを対象にした 3D-CNN による推定器を用いた研究がなされている.

図 5.4 に, 3D-CNN における畳み込み処理を示す. 3 次元の畳み込みカーネルを  $x, y$  軸の 2 次元方向にストライドしていき, 最後の局所領域まで畳み込みを行ったあと, 残った  $z$  軸 1 次元の方向にストライドして, また  $x, y$  の方向に畳み込み処理を行なう (式 5.4).

本研究で用いる MRI 構造画像は 3 次元の画像データであり, 上記の応用データと異なり, 3 次元の密なデータであるため, 3 次元局所空間での特徴抽出が非常に重要になるため, 3D-CNN を用いた推定器も検証する,

$$u_{ijk} = \sum_{k=1}^N \left[ \sum_{(p,q,r) \in P_{ij}} x_{pqrk} w_{p-i,q-j,r-l,k} \right] + b_k \quad (5.4)$$

## 5.1 Convolutional Neural Network (CNN)

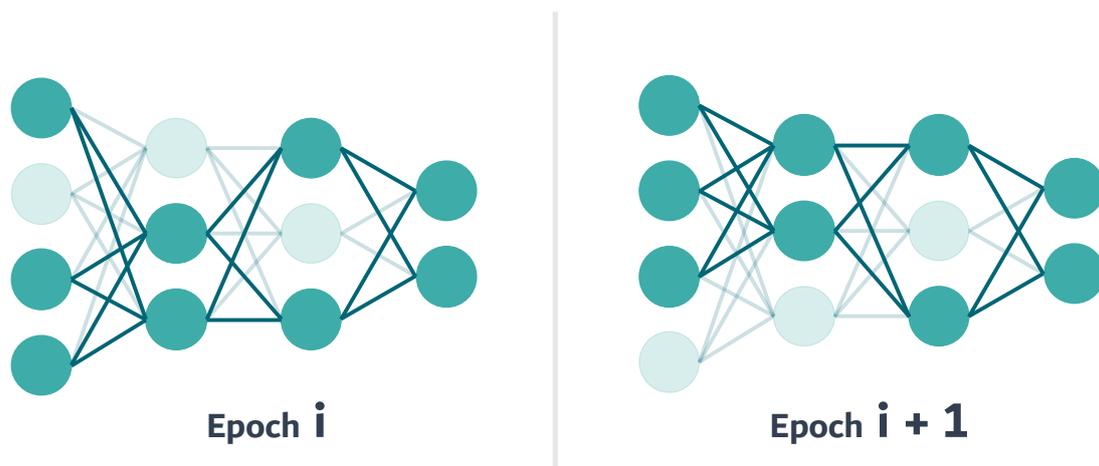


図 5.5: Dropout

### 5.1.3 過学習制御機構

ニューラルネットワークは、その表現力の高さから複雑なデータ構造にも適合していくため、学習データに対する精度は非常に高いが、未知のデータには全く対応できない、過学習を引き起こす。本研究は、脳構造と各要素との間の関係性を確認するために汎化性能が必須であり、高次元データのためネットワークが持つパラメータ数も膨大になり過学習が発生しやすい条件であるため、それに対応するための機構について論ずる。

#### Dropout

Dropout 法は、図 5.5 のようにニューラルネットワークの学習の各エポックでいくつかのノードを無効にして学習を行う方法である。これにより、ネットワークが一部のノードに依存した構成になりにくくなり、過学習を避けることができる。また、Dropout は、ノードを無効にして異なる構成のネットワークを複数用いた学習を行う点でアンサンブル学習と近似しており、画像、音声、文章の教師あり学習において汎化精度の向上が観測されている [19].

## 5.1 Convolutional Neural Network (CNN)

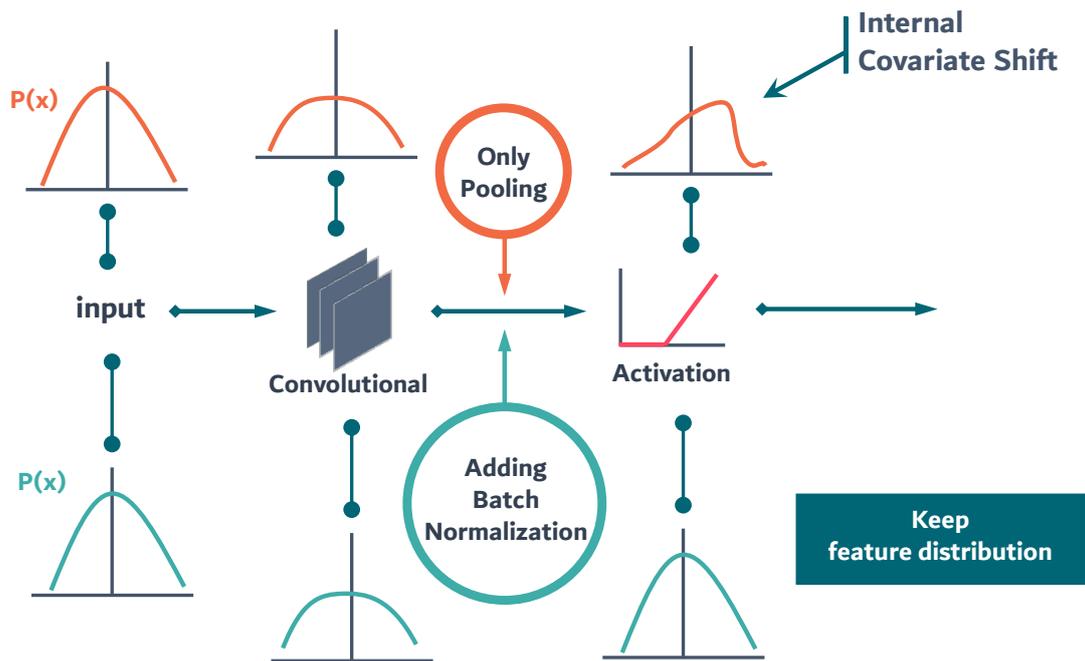


図 5.6: Batch Normalization 概要

### Batch Normalization

図 5.6 のように、深くなったニューラルネットワークにおいて、隠れ層と活性化関数での入力情報の分布が層ごとに変ってしまう問題がある。この現象を内部共変量シフト (Internal Covariate Shift) と呼び、分布の変化が特徴と捉えられ、間違った方向に学習が進むことが問題となる。特に、高次元データでは、異なる入力分布が大きな損失となる。これを抑制するのが Batch Normalization であり、各層の入力データを標準化し、内部共変量シフトなどのノイズを抑制し、データの本質的な勾配のみを学習することができる仕組みである [20]。Batch Normalization アルゴリズムでは、以下のようにミニバッチごとに正規化を行なう。式 5.5, 5.6 で、ミニバッチのデータの平均、分散を算出し、式 5.7 で正規化を行なう。その後、学習パラメータ  $\gamma$  と  $\beta$  を用いて、スケーリングおよびシフトを行なう。これによって、隠れ層の出力分布が共変量シフトすることを抑制している。

$$\mu_B = \frac{1}{m} \sum_{i=1}^m x_i \quad (5.5)$$

## 5.1 Convolutional Neural Network (CNN)

$$\sigma_B^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \quad (5.6)$$

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \quad (5.7)$$

$$y_i = \gamma \hat{x}_i + \beta \quad (5.8)$$

### 5.1.4 特徴可視化手法

CNN は特徴設計部と識別部が分離している構造であるため、特徴設計部の出力から、CNN の識別に寄与している特徴マップ (feature map) を取得する手法が提案されている。本研究では以下の手法を用いて脳構造のどの部位を用いて CNN が識別しているかを特定する。

#### 中間層の出力の可視化

学習済み CNN モデルの各畳み込み層・プーリング層の出力は、入力画像に対して識別に有意な特徴を活性化させた特徴マップとなっている。これらの特徴マップをヒートマップや勾配画像に可視化する手法が提案されている [21]。その中で、本研究では、出力された特徴マップをヒートマップにして識別に有意な領域を抽出する。

#### Grad-CAM

中間層の特徴マップは、識別クラスに関係なく入力情報のみから畳み込み処理・プーリング処理を用いて活性化した領域分布で構成されている。そのため、特徴マップによっては不明瞭な部分が現れる場合がある。この問題に対して CAM 及び Grad-CAM が提案されている [21][22][23]。図 5.7 に CAM 及び Grad-CAM の構成を示す。CNN の特徴抽出部から出力される特徴マップに Global Average Pooling を掛けることで、あるクラス  $c$  の分類において重要なニューロンの重みを表現することが可能であり、このニューロンに ReLU 関数を適用し、負の出力を削減することで、クラス  $c$  において通常の中間層の出力より有意な特徴

## 5.2 Passive Aggressive Classifier

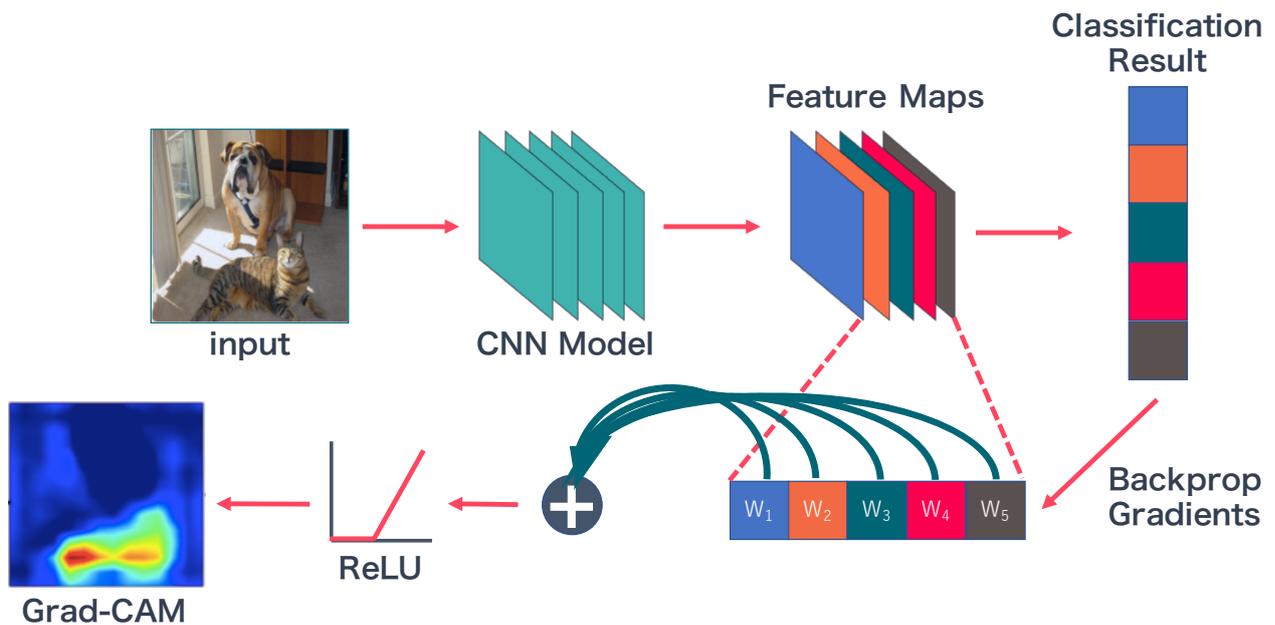


図 5.7: CAM & Grad-CAM の構成

のみを表現した特徴マップが生成できる。

## 5.2 Passive Aggressive Classifier

上記で述べた CNN モデルをベースに要素推定モデルの性能を評価する。評価対象として、Support Vector Machine(SVM) が考えられるが、バッチ学習での学習が前提となっているため、MRI データのような多次元でサンプル数の多い学習データでは、メモリの容量制限によって使用することが困難である。

Passive Aggressive Classifier(PAC) は、SVM が重み更新に用いるマージン最大化を、バッチ学習によって近似的に実現する学習アルゴリズムである [24]。図 5.8 に PAC の学習処理を示す。2 クラス分類 (binary classification) の場合、学習データを  $bfx_t$  教師ラベルを  $y_t \in \{+1, -1\}$  と定義した場合、分類関数  $\text{sign}(\mathbf{w} \cdot \mathbf{x})$  から出力された符号によって 2 クラス分類を行なう。  $\text{sign}(\mathbf{w}_t \cdot \mathbf{x}_t) = y_t$  となるようにマージン  $y_t(\mathbf{w}_t \cdot \mathbf{x}_t)$  を可能な限り 1 以上のマージンを達成することで SVM のマージン最大化の近似を行なっている。マージンが 1 未満の場合、そのバッチで発生する損失は、hinge 損失関数によって以下の式のように定義さ

## 5.2 Passive Aggressive Classifier

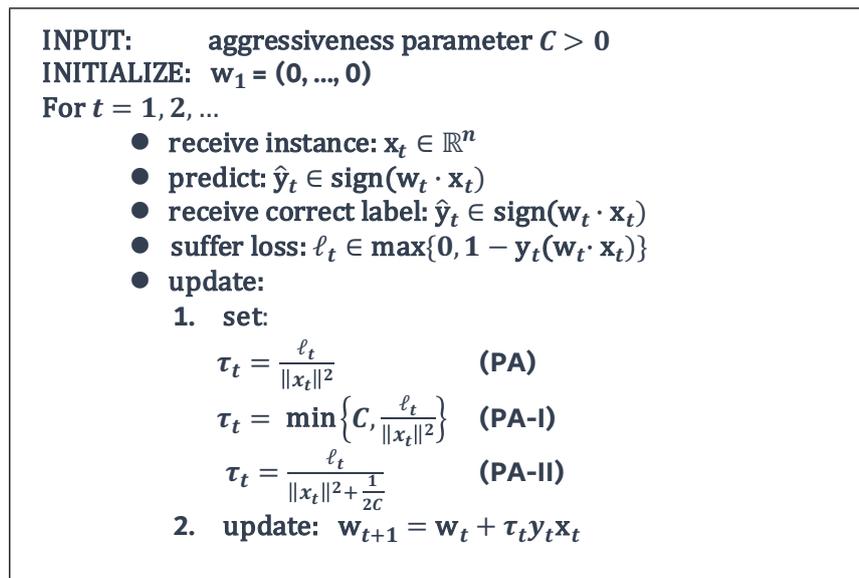


図 5.8: Passive Aggressive Algorithm の概要

文献 [24] の図 1 を参考に作成

れている。

$$\ell(\mathbf{w}; (\mathbf{x}, y)) = \begin{cases} 0 & y(\mathbf{w} \cdot \mathbf{x}) \geq 1 \\ 1 - y(\mathbf{w} \cdot \mathbf{x}) & \text{otherwise} \end{cases}$$

# 第 6 章

## 推定モデル

本章では、各推定タスクに対する推定モデルの詳細について述べる。2次元及び3次元CNNモデル、DropoutやBatch Normalizationを適用したモデルを検証する。

### 6.1 2D-CNN モデル

#### 6.1.1 3次元MRIデータへの適用

通常2D-CNNでは、2次元画像に対して適用されるが、本研究で用いるMRI構造画像は3次元データであるため、ある1次元方向をチャンネルとして扱い、2次元での畳み込みを行なう。MRI画像の2次元画像には断面ごとに以下の定義があり、

**horizontal(水平断面):** 頭立位で地面に平行な断面

**sagittal(矢状断面):** 身体を左右に分割する断面

**coronal(冠状断面):** 矢状面に垂直に交わり、身体を前後に分割する断面

図6.1のようにこれら3つの断面を平面とした3パターンの推定器を作成した。

#### 6.1.2 ネットワーク構成

表6.1は、検証したネットワーク構成を示している。“Fixed Filter”は、各層の畳み込みフィルタの枚数及び畳み込みカーネルのサイズとプーリング領域を固定したモデルであり、“Down Scaling”は入力層に近い畳み込み層、プーリング層の規模を大きくし、出力層に近いものの規模を小さくしている。表6.1中の畳み込み層欄にある左の数値はフィルタの枚数、

## 6.2 3D-CNN モデル

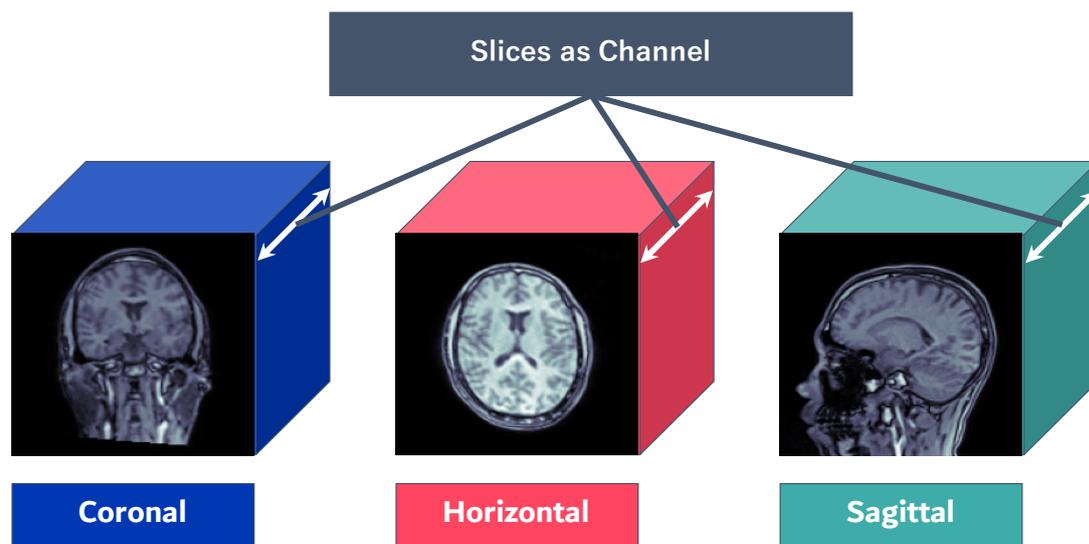


図 6.1: 各断面画像における, 2次元畳み込み

右の数値はカーネルサイズを表す. 出力層は, 性別・喫煙推定における分類問題は Softmax 関数を年齢推定における回帰問題は Logistic 関数を適用している.

### 6.1.3 評価値の算出方法

図 6.2 に各モデルの評価値の算出方法を示す. 各学習タスクにおいて, データセットを学習データ, 検証データ, 評価データに分割している. モデルの構築は学習データを用いたモデルの学習と検証データを用いた Early Stopping などのパラメータ調節によって行われる. 評価データによって算出された Accuracy や Mean Squared Error などの評価値をそのモデルの評価値として比較を行なう.

## 6.2 3D-CNN モデル

3D-CNN モデルでは, 入力値を 3次元構造のまま入力できるので, 脳構造の形状を保持したまま特徴設計が可能となるため, 2D-CNN のようにスライス間を畳み込んで特徴を落とす必要がないので, より高次元特徴設計が可能なり精度向上を期待できる. さらに, 中間層を 3次元空間で表現できるため, CNN が強い信号を出力している部位と脳構造との照合

## 6.2 3D-CNN モデル

表 6.1: ネットワーク構成 1 — 2D-CNN

	Fixed Filter1	Fixed Filter2	Fixed Filter3	Down Scaling
Conv1(Filter, kernel)	10, 5	20, 5	30, 5	30, 5
Activation			ReLU	
Pooling1	Max(6)	Max(6)	Max(6)	Max(4)
Conv2(Filter, kernel)	10, 5	20, 5	30, 5	20, 4
Activation			ReLU	
Pooling2	Max(6)	Max(6)	Max(6)	Max(3)
Conv3(Filter, kernel)	10, 5	20, 5	30, 5	10, 3
Activation			ReLU	
Pooling3	Max(6)	Max(6)	Max(6)	Max(2)
FullConnection			3000	
Output			Softmax or Logistic	

が可能なのも 3D-CNN の大きな利点である。

また、関連研究として Cole らの 3D-CNN による年齢推定モデル [25] をベースにタスクごとに出力層を変更したモデルを用いる。表 6.3 に Cole らのネットワーク構成を示す。複雑な脳構造の特徴を表現するために、各プーリング層の後に畳み込み層の特徴マップの数を 2 倍にしている。

### 6.2.1 ネットワーク構成

表 6.2 は、検証したネットワーク構成を示している。2D-CNN のときと同様に “Fixed Filter” と “Down Scaling” で構成している。

## 6.2 3D-CNN モデル

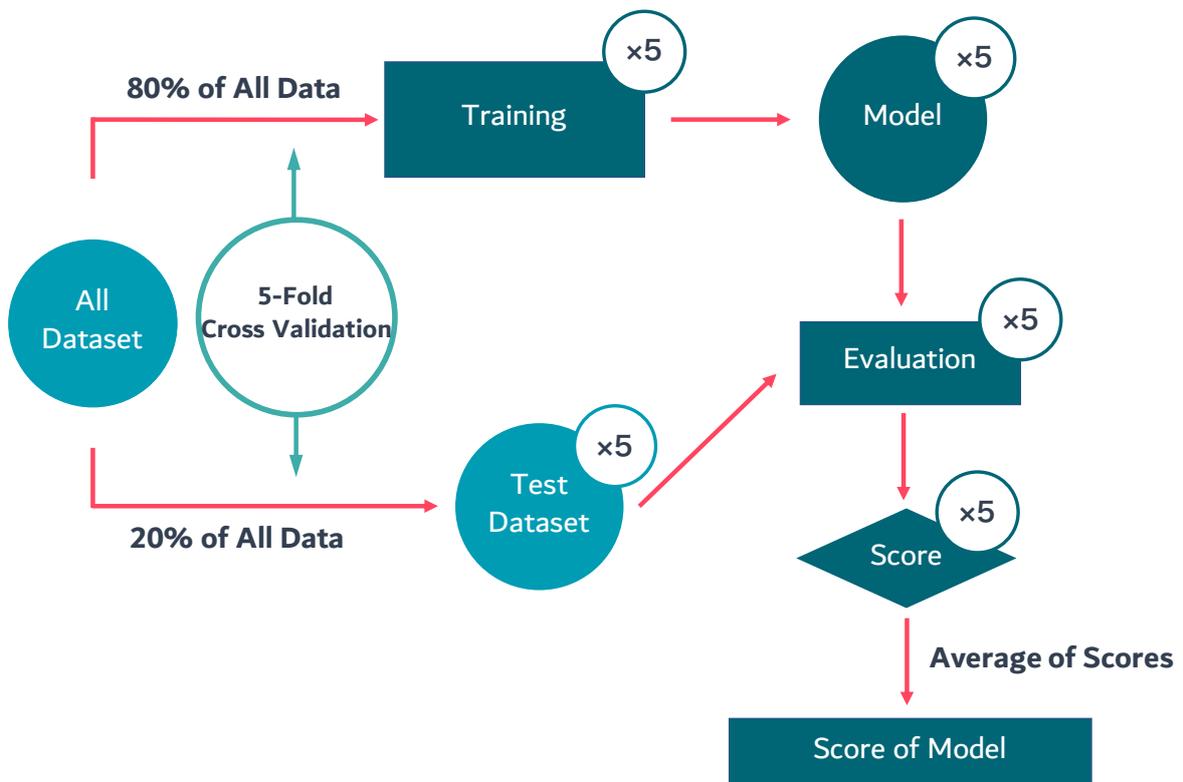


図 6.2: Neural Network モデルの評価方法

## 6.2 3D-CNN モデル

表 6.2: ネットワーク構成 — 3D-CNN

	Fixed Filter1	Fixed Filter2	Fixed Filter3	Down Scaling
Conv1(Filter, kernel)	10, 4	20, 4	30, 4	30, 4
Activation		ReLU		
Pooling1	Max(8)	Max(8)	Max(8)	Max(6)
Conv2(Filter, kernel)	10, 3	20, 3	30, 3	20, 3
Activation		ReLU		
Pooling2	Max(4)	Max(4)	Max(4)	Max(4)
Conv3(Filter, kernel)	10, 2	20, 2	30, 2	20, 3
Activation		ReLU		
Pooling3	Max(2)	Max(2)	Max(2)	Max(2)
FullConnection		3000		
Output		Softmax or Logistic		

表 6.3: ネットワーク構成 — Cole's

block No.	Archtechure
1	Conv1(8, 3) → ReLU → Conv2(8, 3) → BN → ReLU → MaxPooling(2, 2)
2	Conv3(16, 3) → ReLU → Conv4(16, 3) → BN → ReLU → MaxPooling(2, 2)
3	Conv5(32, 3) → ReLU → Conv6(32, 3) → BN → ReLU → MaxPooling(2, 2)
4	Conv7(64, 3) → ReLU → Conv8(64, 3) → BN → ReLU → MaxPooling(2, 2)
5	Conv9(128, 3) → ReLU → Conv10(128, 3) → BN → ReLU → MaxPooling(2, 2)
6	FullConnection(3000) → Output(Logistic or Softmax)

# 第7章

## 推定結果

### 7.1 性別推定

表 7.1 に、各モデルにおける全脳画像を用いた性別推定の結果を示す。全モデルにおいて、95%程度の識別率が観測された。2次元画像の断面方向に関わらず高い識別率が観測されるため、平面状でも検出可能な特徴が存在すると考える。また、ネットワークの規模による精度の変化が見られないため、性別推定に寄与する比較的単純な特徴が存在すると考える。

また、灰白質部分のみを用いた結果を表 7.2 に示す。灰白質部分のみで識別モデルを作成した場合、80%程度の識別率が確認され、全脳画像より 10%程度識別率が減少するが、高い識別率が観測された。この結果より、頭蓋骨や頭部の大きさ以外の局所の特徴が灰白質部分に存在すると考える。

3D-CNN を用いた場合の全脳画像を用いた性別推定では表 7.3 に示すように、“Fixed Filter2” では 97%と高い識別率を計測したが、他のモデルでは 2D-CNN を用いた場合と比較して、約 10%ほど識別率が減少している。識別率の減少の要因として、3D-CNN の初期パラメータが識別率に大きく関与していると考えられる。表 7.6 は、5-Fold 交差検証法での各 Fold の結果である。表 7.6 が示すとおり、同じモデルでも 90%を超える Fold とチャンスレベルである 50%程度の識別率の Fold が観測された。

また、表 7.5 に示す。PAC モデルでの全脳画像の識別率は 88.47%であったため、2D-CNN 及び 3D-CNN を用いることが、識別率向上・寄与領域の特定の面において優れている。

## 7.1 性別推定

表 7.1: 結果: 性別推定 — 2D-CNN

	Fixed Filter1	Fixed Filter2	Fixed Filter3	Down Scaling
Horizontal	90.47%	94.31%	94.29%	92.91%
Coronal	97.00%	95.93%	95.63%	93.75%
Sagittal	92.96%	89.73%	96.50%	96.00%

### 7.1.1 3D-CNN の乱数による影響

表 7.7 は, 2D-CNN 及び 3D-CNN の “Down Scaling” モデルでの各層の出力サイズと前層と結合しているパラメータ数を示す. 総パラメータ数が 2,585,012 の 2D-CNN と比較して, 3D-CNN の総パラメータ数は 152,582 と約 94%削減されているため, 1つのパラメータ値が識別に大きく寄与することが考えられる.

また, モデルの初期パラメータと K-Fold Cross Validation の組み合わせが乱数に影響されるため, モデルの精度に大きく関わると考える. 表 7.8 は K-Fold で分割する際の組み合わせを指定する乱数のシード値を固定した 5 パターンで行ったシミュレーションの結果の標準偏差である. “Fixed Filter1” は比較的, 標準偏差が小さくなったが, その他のモデルにおいては一部の Fold では 20%以上の誤差が生じる結果となるため, データのばらつきが性能評価に影響を与えると考える. 加えて, 表 7.9 では, CNN モデルの初期値生成のシード値を固定した 5つのモデルで行ったシミュレーションの結果の標準偏差である. Fold の組み合わせ同様 “Fixed Filter 1” は比較的, 標準偏差が小さくなったが, その他のモデルは初期値によって性能評価が大きく変化する傾向が見られた.

### 7.1.2 男女間における特徴マップ

脳構造画像から, 性別の識別が可能であることを前節で示した. 本節では, 性別推定における特徴マップを視覚化することで, 特徴強度の大きな部位を観測する.

## 7.1 性別推定

表 7.2: 結果: 性別推定 — 2D-CNN — 灰白質

	Fixed Filter1	Fixed Filter2	Fixed Filter3	Down Scaling
Horizontal	83.42%	82.62%	84.51%	85.32%
Coronal	83.95%	84.76%	84.78%	83.98%
Sagittal	79.33%	80.43%	82.33%	83.69%

表 7.3: 結果: 性別推定 — 3D-CNN

	Fixed Filter1	Fixed Filter2	Fixed Filter3	Down Scaling
Accuracy	80.14%	97.01%	80.51%	70.51%

### 中間層の出力

図 7.1-7.6 は第 1 プーリング層における同年代の男女の性別識別に関する特徴マップを表示したものである。男女間で異なる特徴マップが反応している為、頭部構造において、男女を識別する特徴が存在する。また、顔の表面(頭蓋骨部分)より内部の領域における反応が高いことから、顔の形状特徴だけではなく、脳の構造に特徴が存在すると思われる。図 B.1 - B.12 に第 2 層以降のプーリング層における男女の特徴マップを示すように、男性と女性で反応強度の強い特徴マップが異なるため、明確な局所特徴によって、男女の識別が行われていると考える。

## 7.1 性別推定

表 7.4: 結果: 性別推定 — 3D-CNN — 灰白質

	Fixed Filter1	Fixed Filter2	Fixed Filter3	Down Scaling
Accuracy	83.71%	77.47%	68.17%	78.55%

表 7.5: 5-Fold 交差検証法による性別推定の結果 — Passive Aggressive Classifier — Whole Brain

	1st	2nd	3rd	4th	5th	Average	S.D.	S.E.
Accuracy	89.19	87.84	88.89	83.56	92.86	88.47	3.333	1.490

表 7.6: 5-Fold 交差検証法による性別推定の結果 — 3DCNN — Whole Brain

Model	1st	2nd	3rd	4th	5th	Average	S.D.	S.E.
Fixed 1	97.30%	94.59%	56.76%	94.52%	57.53%	80.14%	21.023	9.40
Fixed 2	95.95%	95.95%	100.00%	95.89%	97.26%	97.01%	1.769	0.79
Fixed 3	98.65%	62.16%	51.35%	93.15%	97.26%	80.51%	22.115	9.89
Down Scale	58.11%	54.05%	51.35%	98.63%	90.41%	70.51%	22.240	9.95

## 7.1 性別推定

表 7.7: Down Scaling での 2D, 3D-CNN モデルの出力サイズ & パラメータ数

	2D-CNN		3D-CNN	
	OutputSize	Parameter	OutputSize	Parameter
Conv1	(252,252,30)	138,780	(253,253,182,30)	1,950
Pool1	(63,63,30)	0	(31,31,22,30)	0
Conv2	(61,61,20)	5,420	(29,29,20,20)	16,220
Pool2	(20,20,20)	0	(7,7,5,20)	0
Conv3	(18,18,10)	1,810	(5,5,3,10)	5,410
Pool3	(9,9,10)	0	(2,2,1,10)	0
FC	3,000	2,433,000	3,000	123,000
Output	2	6002	2	6002
Total		2,585,012		152,582

表 7.8: 3D-CNN における, 各 Fold での識別率の標準偏差

	1st	2nd	3rd	4th	5th
Fixed Filter1	5.2%	2.0%	4.3%	2.9%	3.5%
Fixed Filter2	15.6%	19.6%	14.1%	26.3%	2.5%
Fixed Filter3	16.3%	19.5%	3.7%	18.5%	25.1%
Down Scaling	21.2%	18.0%	6.4%	21.2%	18.7%

表 7.9: 3D-CNN における, モデルの初期値シード値ごとの識別率の標準偏差

	1st	2nd	3rd	4th	5th
Fixed Filter1	3.1%	2.1%	4.4%	4.3%	3.1%
Fixed Filter2	21.9%	15.9%	5.4%	27.8%	17.6%
Fixed Filter3	24.7%	16.5%	2.0%	2.1%	18.0%
Down Scaling	18.8%	22.2%	17.4%	7.5%	20.1%

## 7.1 性別推定

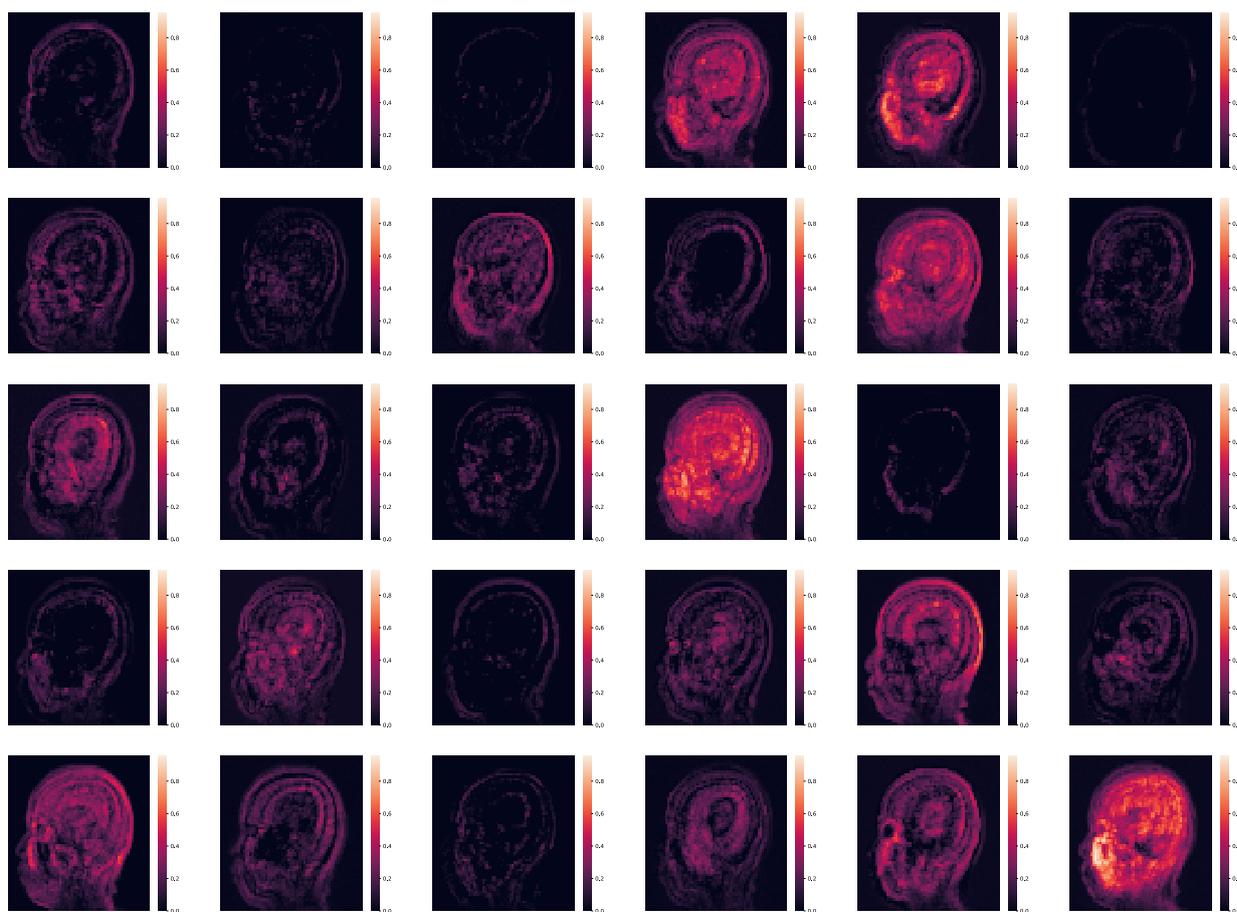


図 7.1: 第 1 プーリング層の特徴マップ — 男性 — Sagittal

## 7.1 性別推定

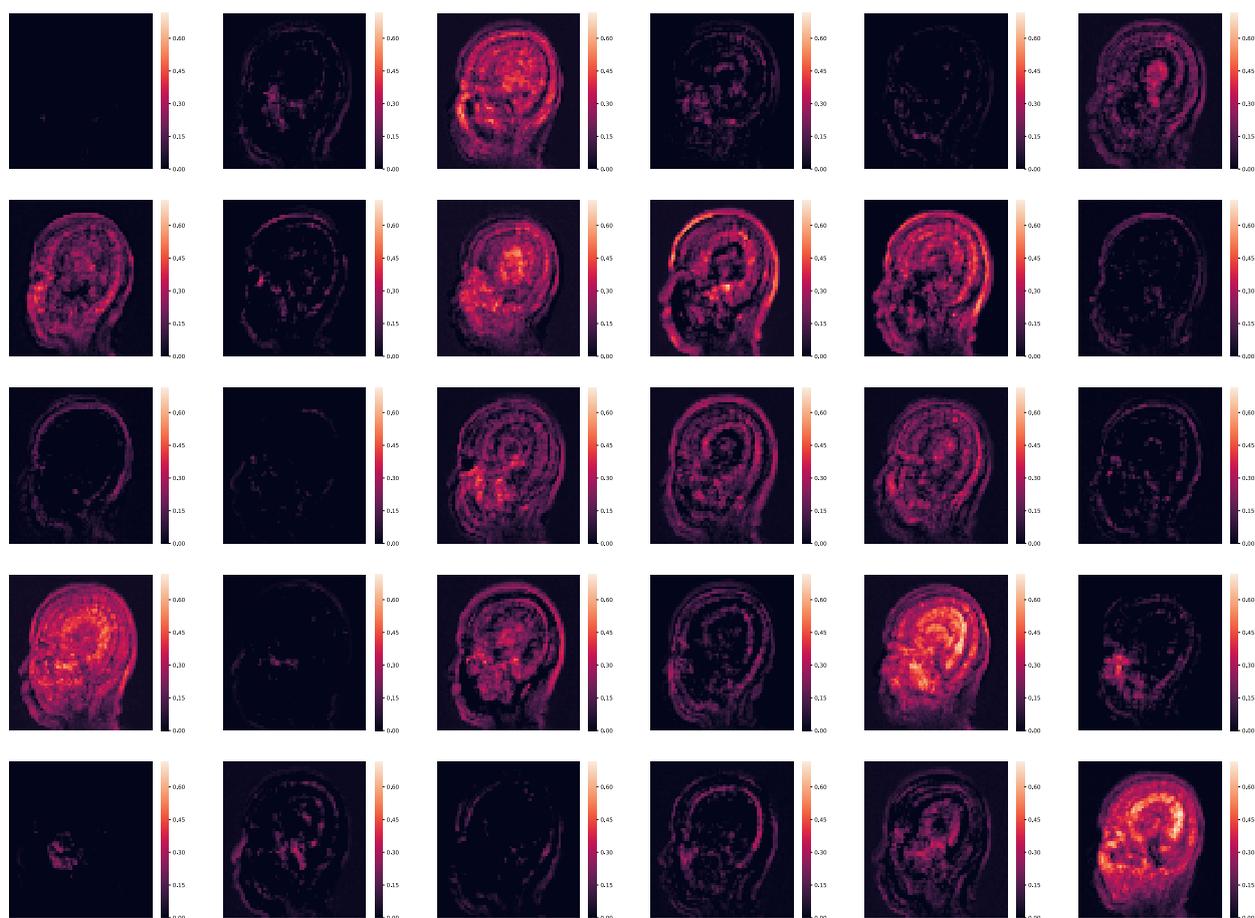


図 7.2: 第 1 プーリング層の特徴マップ — 女性 — Sagittal

## 7.1 性別推定

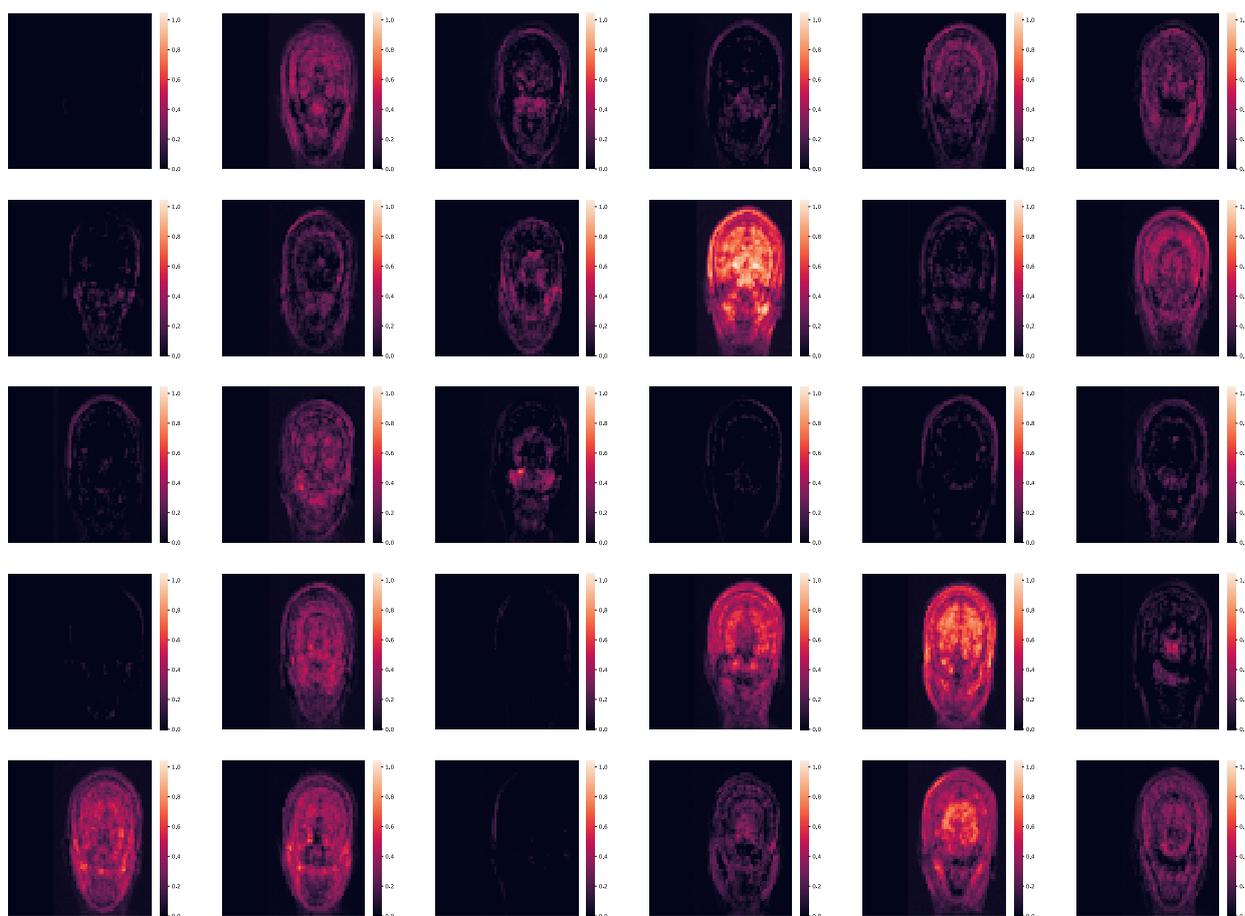


図 7.3: 第 1 プーリング層の特徴マップ — 男性 — Coronal

## 7.1 性別推定

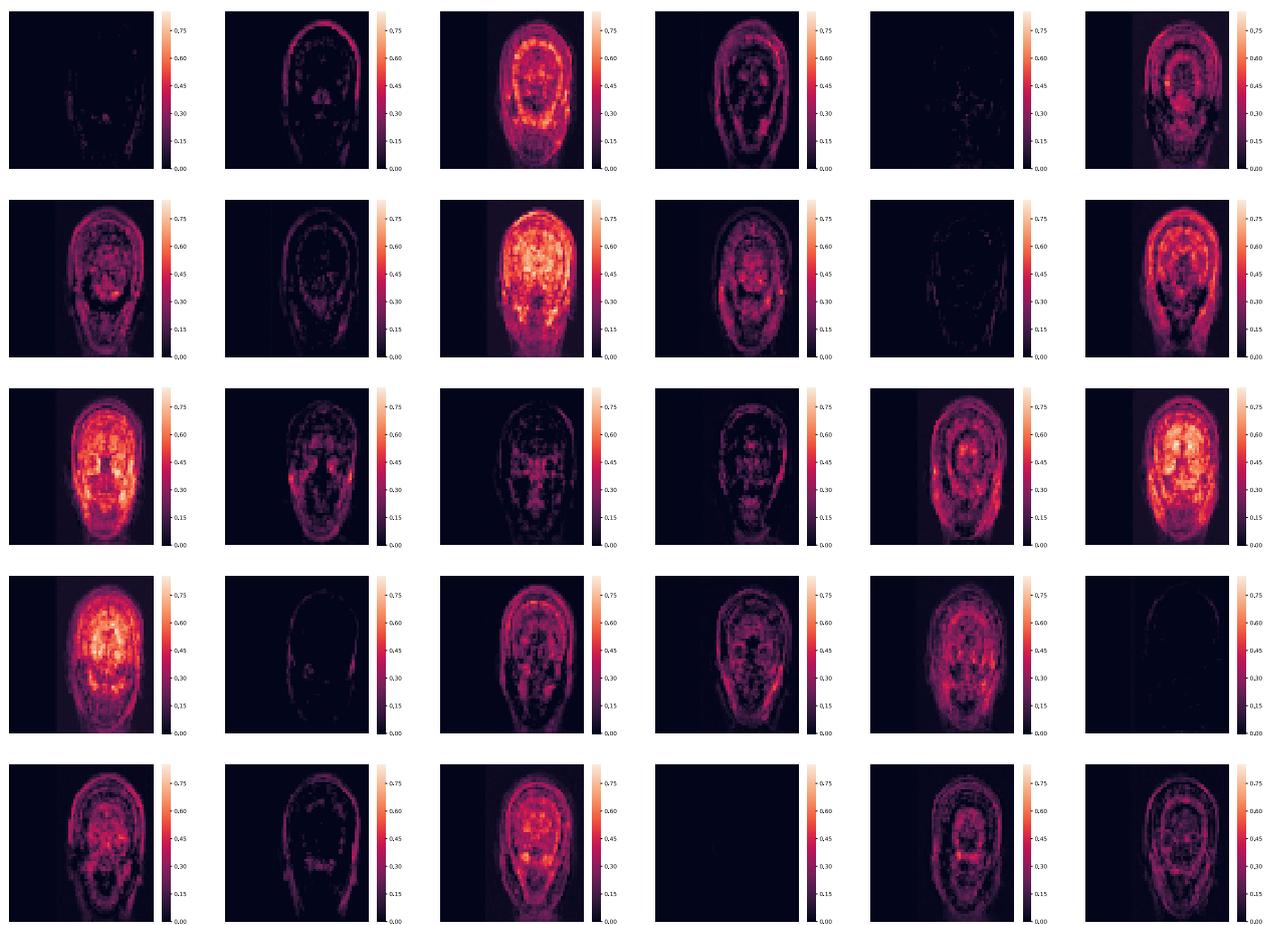


図 7.4: 第 1 プーリング層の特徴マップ — 女性 — Coronal

## 7.1 性別推定

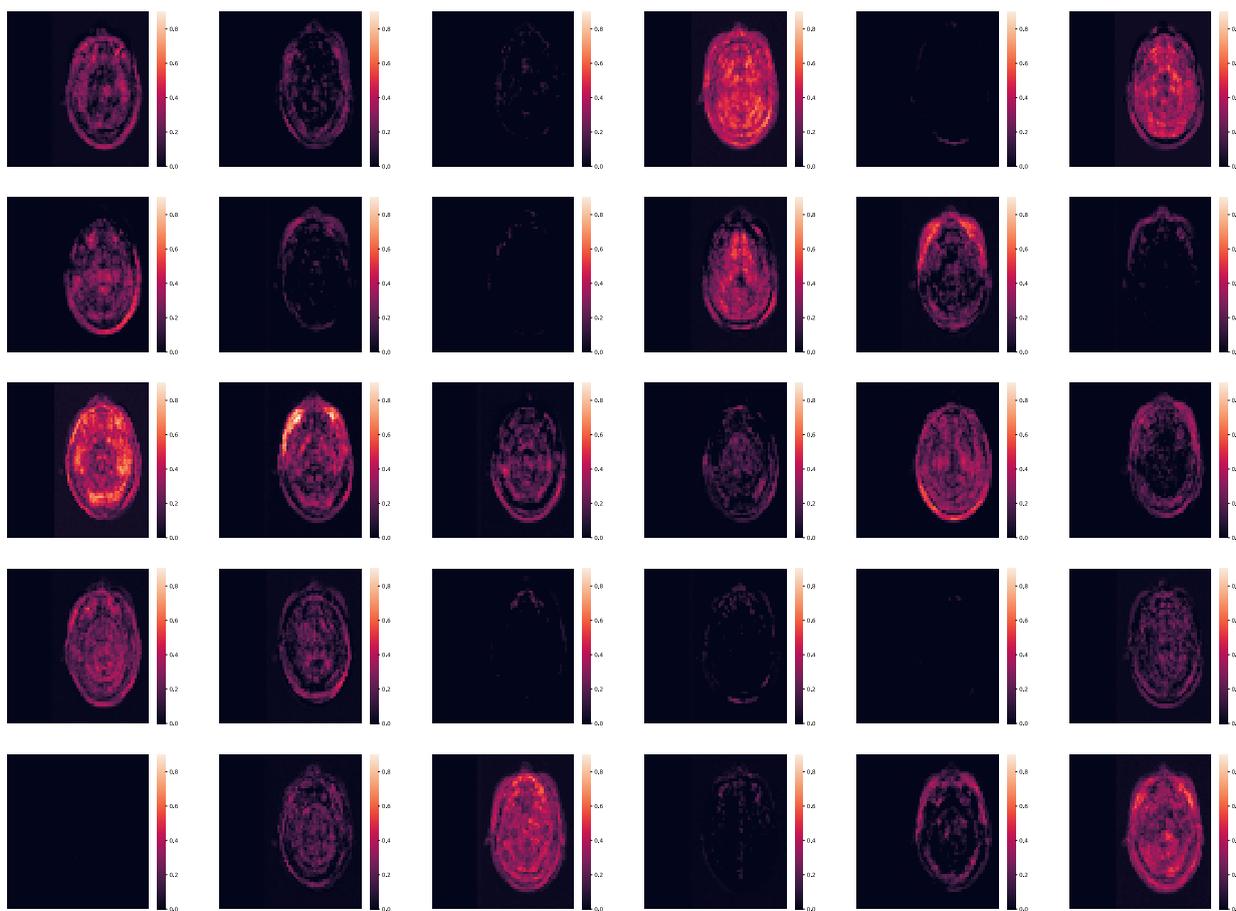


図 7.5: 第 1 プーリング層の特徴マップ — 男性 — Horizontal

## 7.1 性別推定

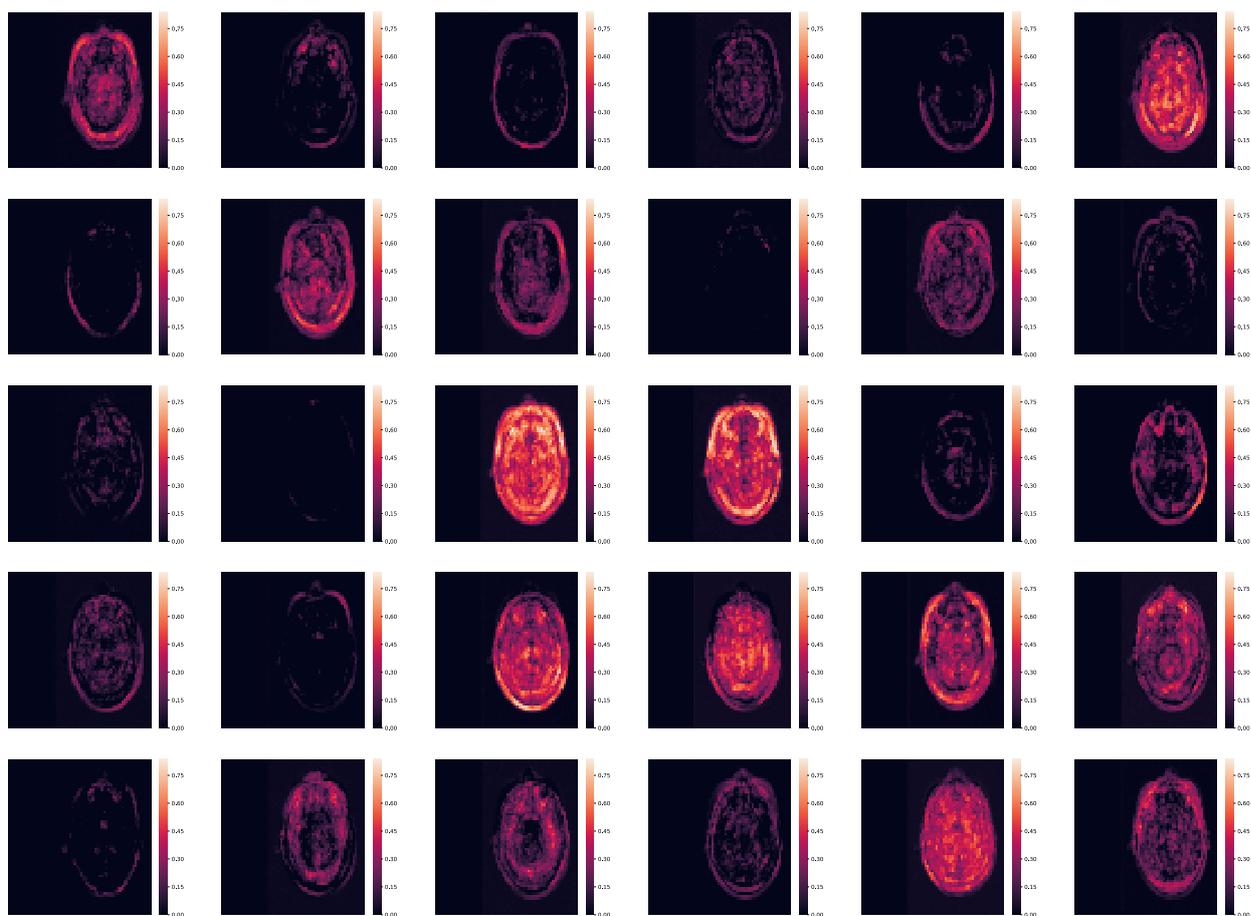


図 7.6: 第 1 プーリング層の特徴マップ — 女性 — Horizontal

## 7.2 年齢推定

表 7.10: 結果: 年齢推定 — 2D-CNN

MSE/MAE	Fixed Filter1	Fixed Filter2	Fixed Filter3	Down Scaling
Horizontal	10.88/8.57	10.70/8.70	10.90/8.70	11.20/9.08
Coronal	11.74/9.52	12.10/9.54	11.13/8.87	10.78/8.67
Sagittal	10.80/8.76	9.87/7.86	10.06/7.89	9.09/7.08

### Grad-CAM

図 7.7 は, Grad-CAM を用いて特徴マップを視覚化した結果である. 中間層の出力同様に, 顔の形状などに影響する頭蓋骨部分より, 脳部分強い反応が見られた. また, Sagittal と Coronal からは, 海馬等の存在する脳の中心部分に高強度な特徴が現れ, Horizontal からは後頭部に高強度な特徴が現れたため, 脳構造においてこれらの部位に男女で異なる形状特徴が存在することで, 高識別率な推定が可能であると考えられる.

## 7.2 年齢推定

表 7.11 に 3D-CNN で全脳画像を学習したモデルでの年齢推定の結果を示す. 特徴マップの数に関係なく, MSE では 10 歳, MAE では 8 歳程度の誤差での推定となった. この原因として, 図 7.8 で示しているように, 予測値の分布が 50 - 60 歳の範囲でのみ推定が行われており, 近似直線が水平に近いため, 相関がなく, 平均値を出力しているモデルとなっている.

Cole らのような結果にならない原因として, 本研究で用いたデータの年齢分布が 40 - 60 代が 90%以上を占めているため, その他の年齢層のデータが外れ値扱いされていると考えられる. そのため, 精度向上として, 年齢層の分布を均等にすることが要求される.

### 7.3 喫煙量推定

表 7.11: 結果: 年齢推定 — 3D-CNN

	Fixed Filter1	Fixed Filter2	Fixed Filter3	Down Scaling	Cole's
MSE/MAE	10.84/8.68	10.20/8.20	10.76/8.68	10.76/8.68	15.53/12.33

### 7.3 喫煙量推定

表 7.12 に, 2DCNN での喫煙推定の結果を示す. “未経験”の割合が, 全データセットの 54%を占めているため, 識別が行えておらず, 図 7.9 に示すように学習データと検証データでの推移が異なるため, 喫煙推定に寄与する局所的特徴が弱いと考える.

### 7.3 喫煙量推定

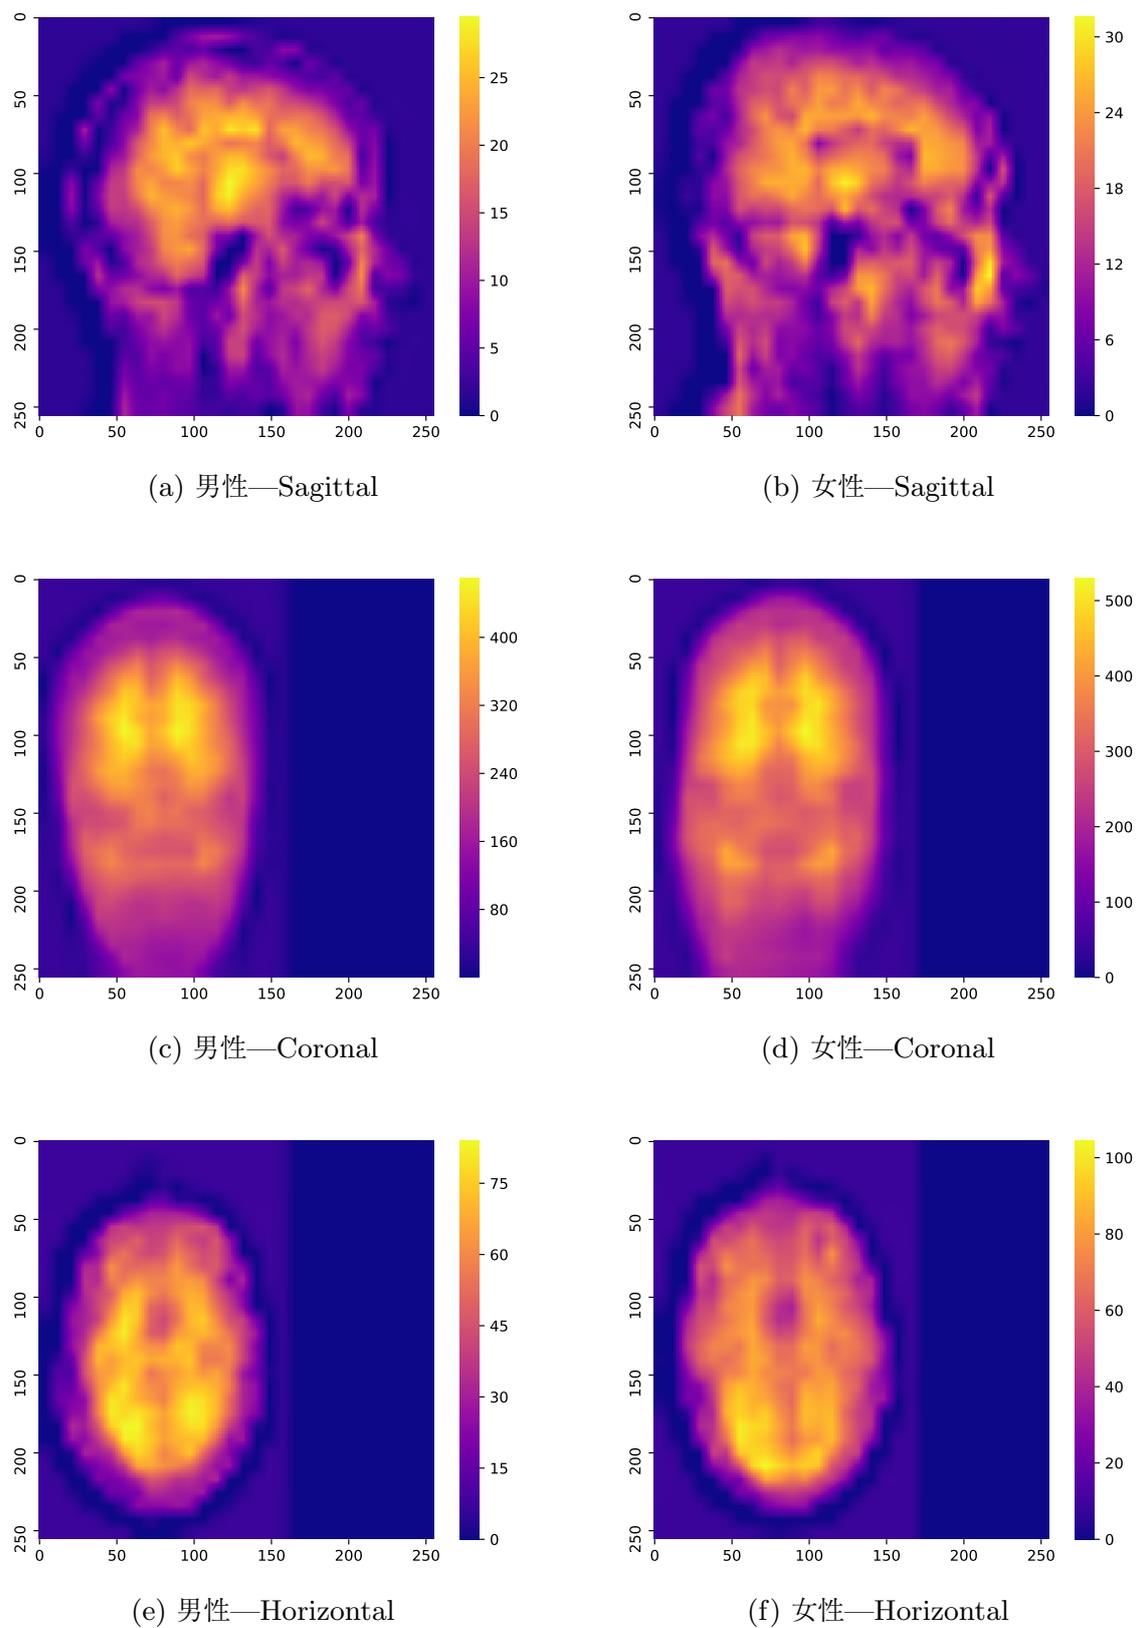


図 7.7: Grad-Cam による特徴マップ

### 7.3 喫煙量推定

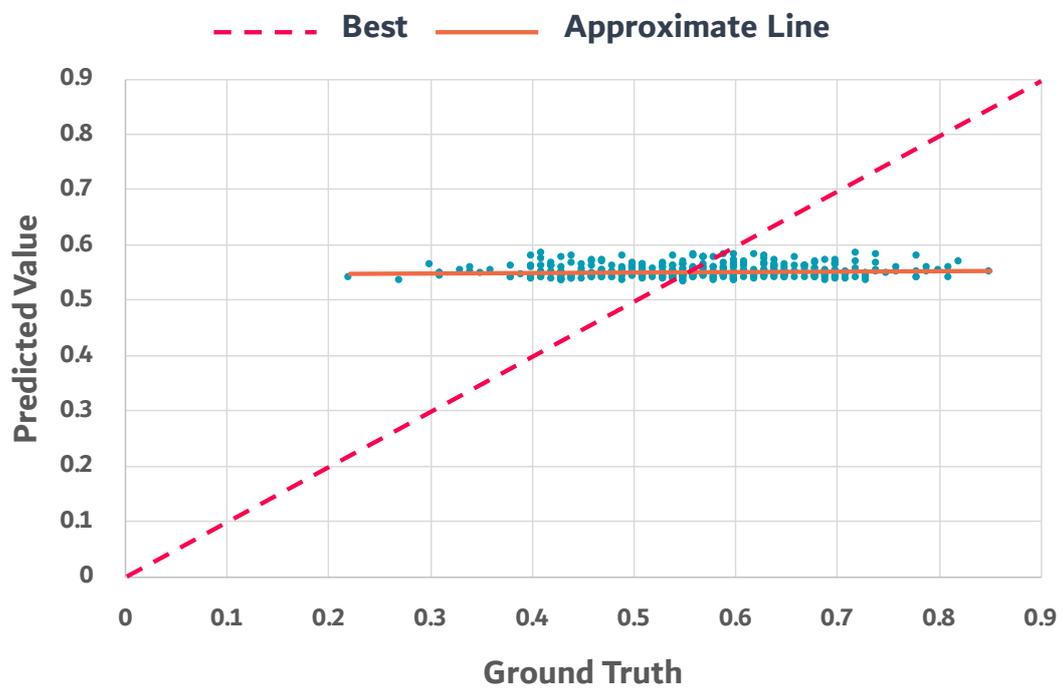


図 7.8: 結果: 年齢推定の真値と予測値の散布図

### 7.3 喫煙量推定

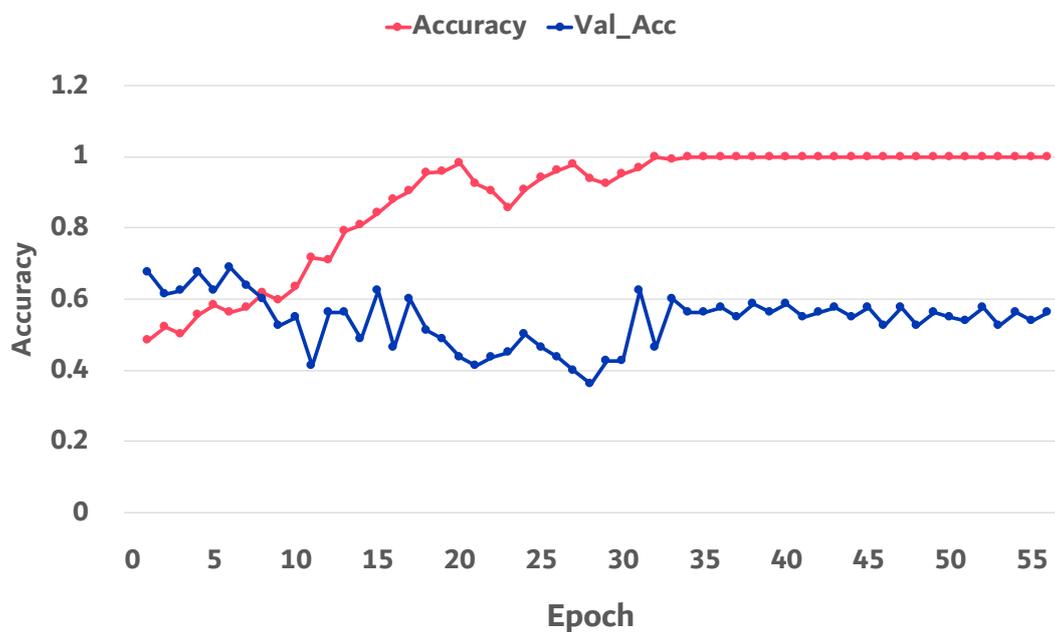


図 7.9: 結果: 学習過程 — 喫煙推定 — 2D-CNN

表 7.12: 結果: 喫煙推定 — 2D-CNN

	Fixed Filter1	Fixed Filter2	Fixed Filter3	Down Scaling
Accuracy	54.34%	52.43%	51.96%	50.00%

## 第 8 章

# Brodmann Area 別の推定結果

本章では, Brodmann Area ごとに各推定タスクを行った結果について論ずる.

### 8.1 性別推定

図 8.1 に Brodmann Area ごとの性別推定の結果を示す. チャンスレベル 57.26 % に対して, 75%を超える精度で識別可能な領野が観測された. 表 8.1 に, それらの部位の Brodmann の皮質領野番号と機能領野, 主な機能についてまとめる. 主に, 思考・認知に関わる前頭回 (BA: 9 - 12, 43 - 47) や視覚・聴覚などに関わる側頭回 (BA: 20 - 22) で高精度な識別が可能であった. そのため, これらの認知機能で男女間に違いがあると考え.

14 - 16 領野のようなチャンスレベル程度の識別率になるモデルでは, 予測値が全て同じになり, 学習が収束していないため, 部位による固有の形状特徴が存在しないと考える. 図 8.2 には Brodmann Area 27 領野での学習推移を示す.

図 8.3 は Brodmann Area 27 の部位である. このように識別率が低い領野は容積として非常に小さく, 画像中に数ボクセルしか存在せず CNN による局所特徴の抽出が困難であることが考えられるため, より空間分解能の高い撮像機器を用いるか, 文献 [26] のような Super-Resolution を用いた画素補間技術により, 画像の解像度を向上させることで, これらの部位に本来存在する局所特徴が抽出できる可能性がある.

## 8.2 高精度な領野を全て用いた学習

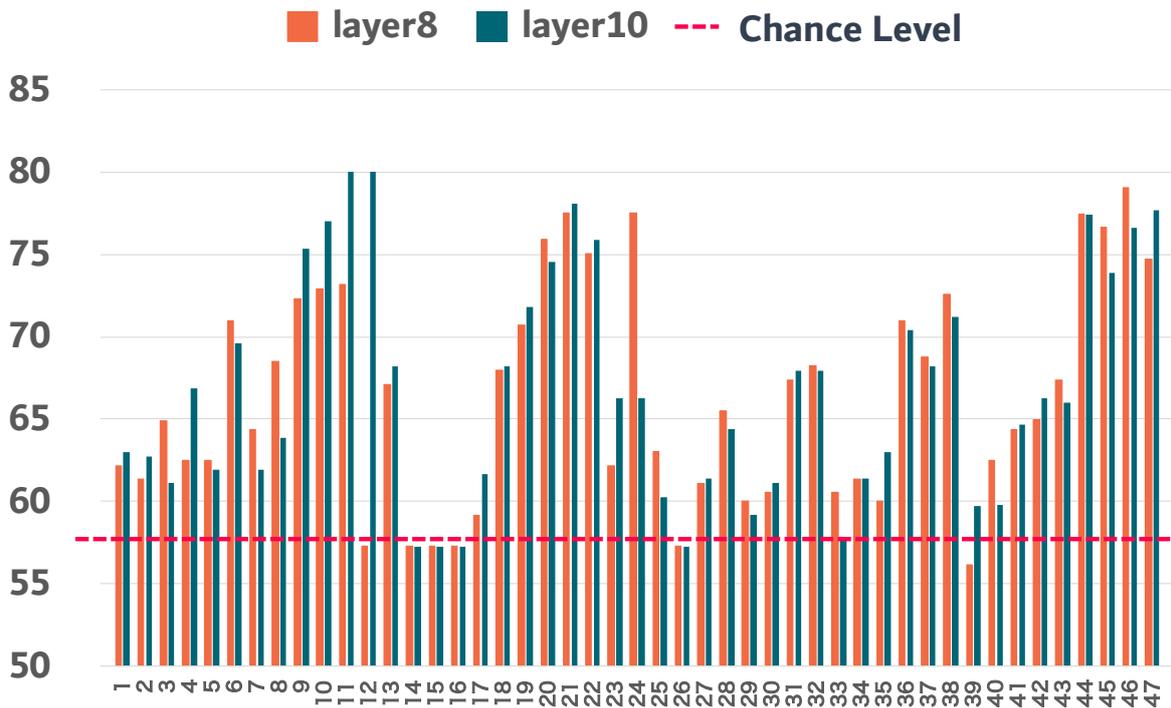


図 8.1: Brodmann Area ごとの性別推定結果

## 8.2 高精度な領野を全て用いた学習

一部の Brodmann 領野において 2D-CNN モデルで 70%を超えるものを観測した。それらの領野をすべて含んだ画像で性別推定を行った結果を図 8.2 に示す。識別率は 83%と灰白質と大きく変わらない値を観測した。

## 8.2 高精度な領野を全て用いた学習

表 8.1: 75%以上の精度で性別識別可能な Brodmann Area 領野

Brodmann Area	名称	機能
9	Dorsolateral Prefrontal Cortex	思考 認知 運動企図
10	Anterior Prefrontal Cortex	思考 認知 運動企図
11	Orbitofrontal Area	思考 認知 運動企図
12	Orbitofrontal Area	思考 認知 運動企図
20	Inferior Temporal Gyrus	形態視
21	Middle Temporal Gyrus	形態視
22	Part of the Superior Temporal Gyrus	聴覚 言語
24	Ventral Anterior Cingulate Cortex	情動 学習 記憶
44	Opercular Part of Inferior Frontal Gyrus	言語 運動の計画
45	Triangular Part of Inferior Frontal Gyrus	思考 認知 計画的行動
46	Dorsolateral Prefrontal Cortex	思考 認知 計画的行動
47	Orbital Part of Inferior Frontal Gyrus	思考 認知 計画的行動

表 8.2: 高精度な Brodmann Area を用いた性別推定

	1st	2nd	3rd	4th	5th	Average	S.D.	S.E.
Accuracy	77.03	95.89	81.08	73.97	87.67	83.13	7.86	3.51

## 8.2 高精度な領野を全て用いた学習

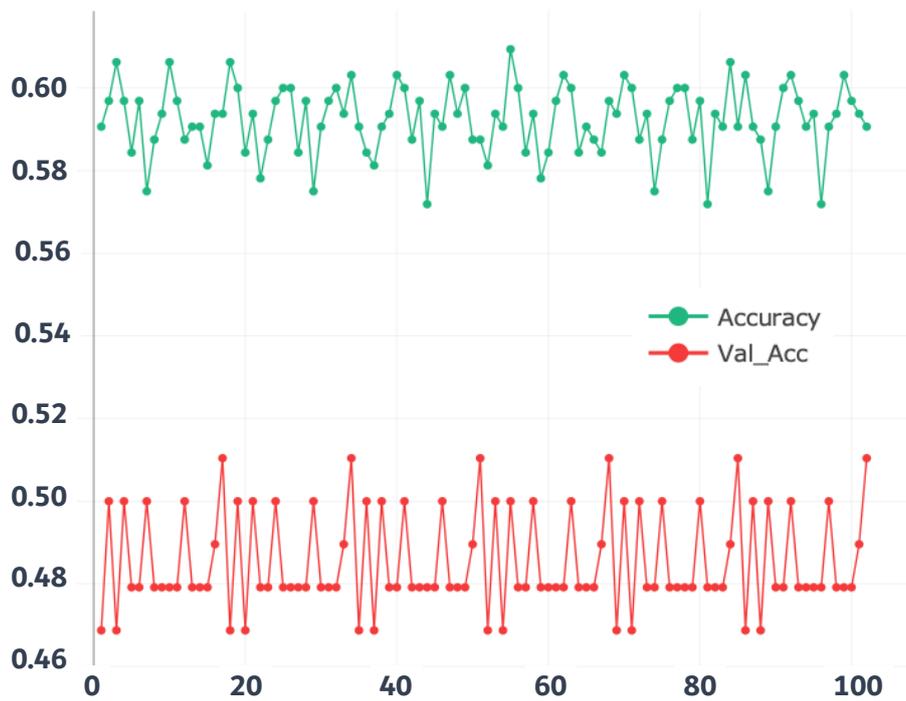


図 8.2: 学習が収束しない場合の学習推移

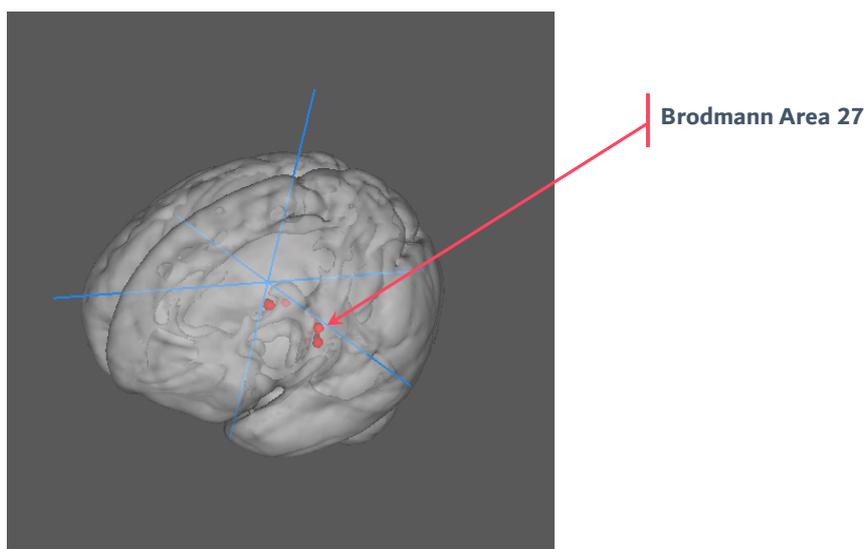


図 8.3: Brodmann Area 27

## 第9章

### まとめ

本論では、脳構造と人間の特性や生活習慣に相関が存在するかを特定するため、MRI 構造画像から最も根源的な人間の特性である、性別・年齢推定及び脳構造に変化が生じる生活習慣である喫煙推定を行なう CNN モデルについて、全脳画像・灰白質画像・白質画像にて識別精度の評価を行った。

その結果、性別推定では 2D-CNN モデルの場合、全脳画像で 97.00%と高い識別率を持つモデルが構築されたため、脳構造にて性別に寄与する局所的な特徴が存在すると考える。また、3 方向のスライス断面において、90%を超える識別モデルが構築されたことから、スライス断面及びそれに直交する面に沿った有用な画像特徴量が存在すると考える。また、灰白質画像で 85.32%と男女間において灰白質に構造的特徴が存在すると考える。3D-CNN を用いた場合 97.01%と 2D-CNN と同程度の識別率で識別可能であるため、より高次元特徴マップで特徴抽出部を表現することが可能であるため、寄与部位の特定に有用であると考えられる。しかしながら、3D-CNN の識別精度は重みベクトル生成時の乱数や学習データによって、大きく変化する傾向が見られた。また、3D-CNN は 2D-CNN と比較して重み係数が少なく、1つのニューロンが識別に大きく関与してしまうため、精度に偏りが生じると考える。また、解剖学・脳機能的区分である Brodmann Area の 47 領域を各領域に識別実験を行なった結果、思考・認知に関わる前頭回、視覚・聴覚に関わる側頭回で高精度な識別が可能であったため、これらの部位及び脳機能にて男女差があることが脳構造的な特徴から証明できると考える。

年齢推定では、2D-CNN、3D-CNN 共に、MSE で 9.09 歳、MAE で 7.08 歳の誤差で識別可能であったが、予測値として平均値を出力している傾向が見られるため学習が進んでい

ないと考える。原因として、本研究で用いたデータの40-60代の年齢分布が極端に多いため、今後、より若い年代の脳構造画像を学習データに取り入れることで、精度向上が見込める。喫煙推定では、“喫煙中”、“禁煙中”、“未経験”の3クラス分類にて、54.34%とほとんど学習ができていないため、局所的な特徴表現は困難であると考え、脳の萎縮による容積の減少が医学的に存在するため、VBMのような大域的特徴で推定を行なう手法で有効であると考え。

## 参考文献

- [1] 内閣府, 平成 30 年版高齢社会白書 (全体版). 2018.
- [2] 川内敦文 医療と社会, vol. 26, no. 3, pp. 290–302, 2016.
- [3] S. Hoo-Chang, H. R. Roth, M. Gao, L. Lu, Z. Xu, I. Nogues, J. Yao, D. Mollura, and R. M. Summers, “Deep convolutional neural networks for computer-aided detection: Cnn architectures, dataset characteristics and transfer learning,” *IEEE transactions on medical imaging*, vol. 35, no. 5, p. 1285, 2016.
- [4] H. G. Schnack, M. Nieuwenhuis, N. E. van Haren, L. Abramovic, T. W. Scheewe, R. M. Brouwer, H. E. H. Pol, and R. S. Kahn, “Can structural mri aid in clinical classification? a machine learning study in two independent samples of patients with schizophrenia, bipolar disorder and healthy subjects,” *Neuroimage*, vol. 84, pp. 299–306, 2014.
- [5] S. Karama, S. Ducharme, J. Corley, F. Chouinard-Decorte, J. M. Starr, J. M. Wardlaw, M. E. Bastin, and I. J. Deary, “Cigarette smoking and thinning of the brain’s cortex,” *Molecular psychiatry*, vol. 20, no. 6, p. 778, 2015.
- [6] C. Blaiotta, P. Freund, M. Cardoso, and J. Ashburner, “Generative diffeomorphic atlas construction from brain and spinal cord mri data,” *arXiv preprint arXiv:1707.01342*, 2017.
- [7] M. M. Joseph A, “Riipl laboratory::pickatlas.” <http://fmri.wfubmc.edu/software/pickatlas>.
- [8] J. L. Lancaster, M. G. Woldorff, L. M. Parsons, M. Liotti, C. S. Freitas, L. Rainey, P. V. Kochunov, D. Nickerson, S. A. Mikiten, and P. T. Fox, “Automated talairach atlas labels for functional brain mapping,” *Human brain mapping*, vol. 10, no. 3, pp. 120–131, 2000.

## 参考文献

- [9] V. Garcia-Vazquez, S. Reig, J. Janssen, J. Pascau, A. Rodriguez-Ruano, A. Udias, J. Chamorro, J. J. Vaquero, and M. Desco, “Use of ibaspm atlas-based automatic segmentation toolbox in pathological brains: effect of template selection,” in *Nuclear Science Symposium Conference Record, 2008. NSS’08. IEEE*, pp. 4270–4272, IEEE, 2008.
- [10] S. A. Huettel, A. W. Song, and G. M. 福山秀直監訳, *fMRI 原理と実践 3rd edition*. メディカル・サイエンス・インターナショナル, 2016.
- [11] K. Fukushima, S. Miyake, and T. Ito, “Neocognitron: A neural network model for a mechanism of visual pattern recognition,” *IEEE transactions on systems, man, and cybernetics*, no. 5, pp. 826–834, 1983.
- [12] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, “Gradient-based learning applied to document recognition,” *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [13] N. Pinto, D. D. Cox, and J. J. DiCarlo, “Why is real-world visual object recognition hard?,” *PLoS computational biology*, vol. 4, no. 1, 2008.
- [14] 神蔦敏弘, 麻生英樹, 安田宗樹, 前田新一, and 岡野原大輔, *深層学習*. 近代科学社, 2015.
- [15] K. Simonyan and Zisserman.A, “Very deep convolutional networks for large-scale image recognition,” *arXiv: 1409.1556*, 2014.
- [16] T. Serre, L. Wolf, and T. Poggio, “Object recognition with features inspired by visual cortex,” tech. rep., 2006.
- [17] S. Ji, W. Xu, M. Yang, and K. Yu, “3d convolutional neural networks for human action recognition,” *IEEE transactions on pattern analysis and machine intelligence*, vol. 35, no. 1, pp. 221–231, 2013.
- [18] A. Karpathy, G. Toderici, S. Shetty, T. Leung, R. Sukthankar, and L. Fei-Fei, “Large-scale video classification with convolutional neural networks,” in *Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*, pp. 1725–

## 参考文献

- 1732, 2014.
- [19] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, “Dropout: a simple way to prevent neural networks from overfitting,” *The Journal of Machine Learning Research*, vol. 15, no. 1, pp. 1929–1958, 2014.
- [20] S. Ioffe and C. Szegedy, “Batch normalization: Accelerating deep network training by reducing internal covariate shift,” *arXiv preprint arXiv:1502.03167*, 2015.
- [21] M. D. Zeiler and R. Fergus, “Visualizing and understanding convolutional networks,” in *European conference on computer vision*, pp. 818–833, Springer, 2014.
- [22] B. Zhou, A. Khosla, A. Lapedriza, A. Oliva, and A. Torralba, “Learning deep features for discriminative localization,” in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 2921–2929, 2016.
- [23] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, “Grad-cam: Visual explanations from deep networks via gradient-based localization,” in *Proceedings of the IEEE International Conference on Computer Vision*, pp. 618–626, 2017.
- [24] K. Crammer, O. Dekel, J. Keshet, S. Shalev-Shwartz, and Y. Singer, “Online passive-aggressive algorithms,” *Journal of Machine Learning Research*, vol. 7, no. Mar, pp. 551–585, 2006.
- [25] J. H. Cole, R. P. Poudel, D. Tsagkrasoulis, M. W. Caan, C. Steves, T. D. Spector, and G. Montana, “Predicting brain age with deep learning from raw imaging data results in a reliable and heritable biomarker,” *NeuroImage*, vol. 163, pp. 115–124, 2017.
- [26] S. Y. C. Zhuo, “Super-resolution using convolutional neural network for magnetic resonance imaging,” in *The 8th International Symposium on Computational Intelligence and Industrial Applications*, Nov 2018.

# 謝辞

4年間の研究室での活動にあたり、テーマ決めや方針、学会参加にあたって懇切丁寧に指導して頂いた高知工科大学情報学群の吉田真一准教授に心から感謝いたします。研究活動の補助だけでなく、サーバ・ネットワークなど研究外における貴重な体験をさせて頂き、私の貴重な財産となりました。また、今まで人の話を真に受けすぎていたのですが、先生の辛辣な毒舌を回避するために身についた、聞き流すスキルが非常に私の中での武器になりましたことを感謝致します。ただ、この毒舌を回避できない人もいたので、先生は言葉選びに注意してください。また、本研究の副査を引き受けてくださった福本昌弘教授・妻鳥貴彦准教授にも心より御礼申し上げます。お二人とも脳に関するご専門でないにも関わらずセミナーから発表会まで、お付き合い頂いたこと心から感謝致します。福本先生には学部時代とは異なり、とても話し易い雰囲気があり、飲み会の席でもお互い遠慮なしで意見が言い合えたような気がしており、とても社会勉強になりました。妻鳥先生には主に飲み会の席でご一緒させていただき、そのまま朝まで話すこともあり、高知ならではの呑んだくれ生活を経験させて頂きました。ただ、最近酔っ払ったときの発言が過激になっているので、ご注意ください。

また、様々な外部機関の方にも感謝を申し上げます。高知検診クリニックの朴啓彰氏には医師の観点からデータに関する情報や本研究を進めるためのアドバイスを頂き、同氏なしでは本研究は発足することさえ困難だったため、本当に感謝致します。電気通信大学の岡本一志助教授は吉田研OBでもあるため、度々研究相談させて頂き、プログラムバグを見つけて頂いたり、異なる視点からのアプローチを提案して頂いたりと研究がより深いものになりました。

研究室の皆さまのおかげで研究室生活が有意義なものになったことを心から感謝いたします。同期の6名は2年間、切磋琢磨しあい自分の成長の糧になりました。佐々木泰一氏は研究室にはあまり頻繁には来なかったですが、要所で集中的に作業をして、それなりに仕上げてくる要領の良さに感銘を学部のお時から受けています。また趣味に対するリサーチ力が凄

## 謝辞

まじいので「これを研究・仕事に使えたら…」といつも思っていました。中山梨奈氏は後輩にタメ口を聞かれるなど一見ちゃらんぽらんに見えて、研究室でも遅くまで残って努力で問題を解決している頑張り屋の印象がありました。そのスタミナやプレゼンなどの自分の見せ方が上手な部分は私の中で非常に参考になりました。領内あゆみ氏とは、色々ありすぎたため何を書けばよいか分かりませんが、一番この大学生活で経験値となった体験をさせていただきました。また、吉田先生とは異なる辛辣さがあり、一度 TOEIC を教えてもらう時、1日 で心を折られたこと今でも覚えています。留学生の Jiang Yunpeng 氏、Zhuo Churong 氏、Li Xiang 氏のおかげで英語のコミュニケーション能力がかなり向上しました。中国での国際会議の時は現地の案内や迷子になったときに助けてもらい非常にありがたかったです。中国版 Uber に乗った経験が非常に印象深いものになりました。また、仕事で中国に行ったときに会えればと思います。

後輩の皆様にも様々な面で成長させていただきました。三浦康寛氏は研究室配属の時からすごく苦手な印象で研究室に入ってこないでと願っていましたが、いざ入ってくると見た目と裏腹に真面目で気弱な性格だったため、扱いやすい後輩でした。これからは完全に引っ張っていく側になるので大学院生として頑張ってください。澤村優希氏とは3年の付き合いですが、非常に寡黙で仕事はしっかりしている印象でした。その聡明さがあれば優秀な大学院生になれると思います。三浦氏とともに研究室をよろしく願います。畠山友華氏は自由奔放に行動している印象で自分には真似できないなと感心していました。でも、吉田先生とコミュニケーション取れてなさすぎで、誰かが仲介しないと意思疎通ができていなかったのには苦勞しました。同じ社会人として頑張っていきましょう。3年生の皆様とは1年間の付き合いでしたが、それ以上に感じる非常に濃い時間を過ごしたように感じています。主にゲームや遊びメインでしたが、3つ下とは思えないほど慣れ慣れしく絡んでくれたので、修士の研究の良い息抜きになりました。再来年度に入院される方は無事に卒院できるように残りの3年間をリア充してください。就職の方はまた東京や大阪で吉田研同窓会でもしましょう。

6年間資金の面で援助して頂いた家族にも感謝致します。社会人になるので、可能な限り

## 謝辞

迅速に返済していきます。最後に大学・大学院生活において関わった全ての方にこの6年間は自分の糧となりましたことを心から感謝致します。

## 付録 A

### 交差検証法での各検証結果

表 A.1: 5-Fold 交差検証法による性別推定の評価 — 2DCNN — Whole Brain

Model	Slice Direction	1st	2nd	3rd	4th	5th	Average	STD Dev	STD Err
Fixed 1	Sagittal	89.19%	89.19%	91.89%	97.30%	97.22%	92.96%	4.079	1.82
Fixed 2	Sagittal	83.78%	91.89%	89.19%	94.59%	89.19%	89.73%	4.009	1.79
Fixed 3	Sagittal	91.89%	91.89%	89.19%	94.59%	89.19%	92.43%	2.961	1.32
Down Scale	Sagittal	89.19%	89.19%	91.89%	97.30%	94.59%	92.43%	3.524	1.58
Fixed 1	Coronal	100.00%	98.65%	95.95%	94.52%	95.89%	97.00%	2.248	1.01
Fixed 2	Coronal	93.24%	94.59%	98.65%	97.26%	95.89%	95.93%	2.131	0.95
Fixed 3	Coronal	100.00%	94.59%	98.65%	91.78%	93.15%	95.63%	3.544	1.58
Down Scale	Coronal	90.54%	94.59%	95.95%	93.15%	94.52%	93.75%	2.049	0.92
Fixed 1	Horizontal	95.95%	90.54%	90.54%	89.04%	86.30%	90.47%	3.515	1.57
Fixed 2	Horizontal	90.54%	89.19%	97.30%	95.89%	98.63%	94.31%	4.199	1.88
Fixed 3	Horizontal	93.24%	97.30%	91.89%	97.26%	91.78%	94.29%	2.784	1.25
Down Scale	Horizontal	93.24%	97.30%	98.65%	86.30%	89.04%	92.91%	5.266	2.36

表 A.2: 5-Fold 交差検証法による性別推定の評価 — 2DCNN — Gray Matter

Model	Slice Direction	1st	2nd	3rd	4th	5th	Average	STD Dev	STD Err
Fixed 1	Sagittal	72.97%	85.14%	85.14%	75.34%	78.08%	79.33%	5.596	2.50
Fixed 2	Sagittal	79.73%	77.03%	87.84%	75.34%	82.19%	80.43%	4.897	2.19
Fixed 3	Sagittal	82.43%	77.03%	87.84%	75.34%	82.19%	80.33%	3.281	2.19
Down Scale	Sagittal	83.78%	85.14%	82.43%	90.41%	76.71%	83.69%	4.938	2.21
Fixed 1	Coronal	83.78%	89.19%	85.14%	78.08%	83.56%	83.95%	3.983	1.78
Fixed 2	Coronal	85.14%	89.19%	86.49%	78.08%	84.93%	84.76%	4.104	1.835
Fixed 3	Coronal	86.49%	83.78%	83.78%	84.93%	84.93%	84.78%	1.112	0.50
Down Scale	Coronal	79.73%	87.84%	79.73%	86.30%	86.30%	83.98%	3.930	1.76
Fixed 1	Horizontal	85.14%	86.49%	79.73%	82.19%	83.56%	83.42%	2.622	1.172
Fixed 2	Horizontal	75.68%	86.49%	81.08%	82.19%	87.67%	82.62%	4.776	2.136
Fixed 3	Horizontal	83.78%	85.14%	86.49%	76.71%	90.41%	84.51%	5.011	2.241
Down Scale	Horizontal	90.54%	85.14%	83.78%	83.56%	83.56%	85.32%	2.993	1.339

## 付録 B

# 性別推定における特徴マップ

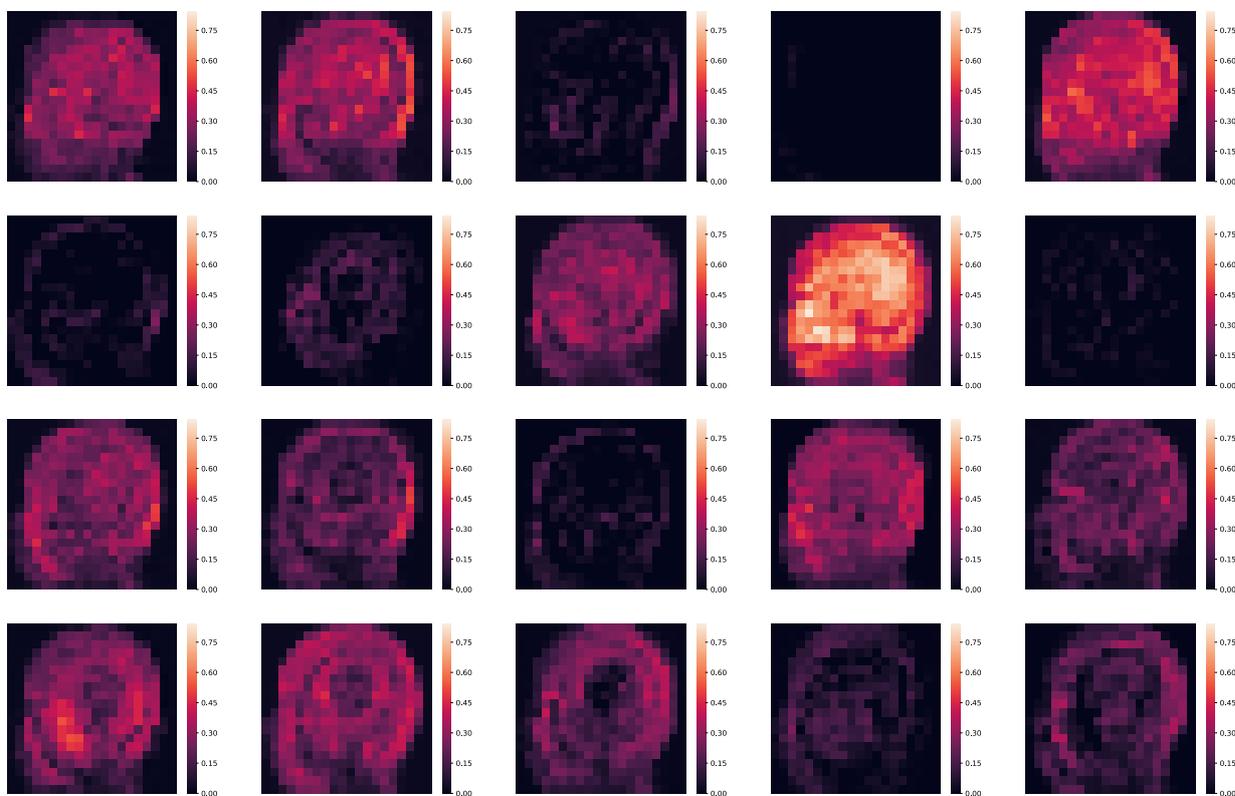


図 B.1: 第 2 プーリング層の特徴マップ — 男性 — Sagittal

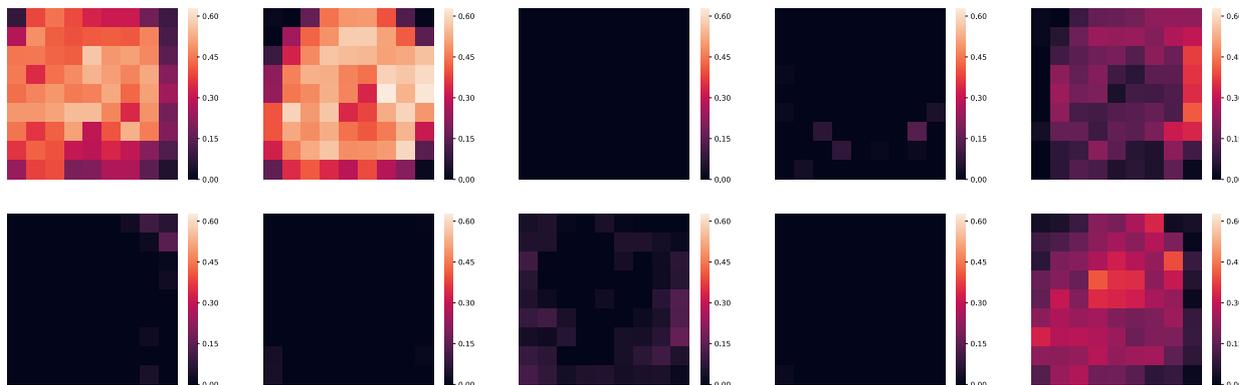


図 B.2: 第 3 プーリング層の特徴マップ — 男性 — Sagittal

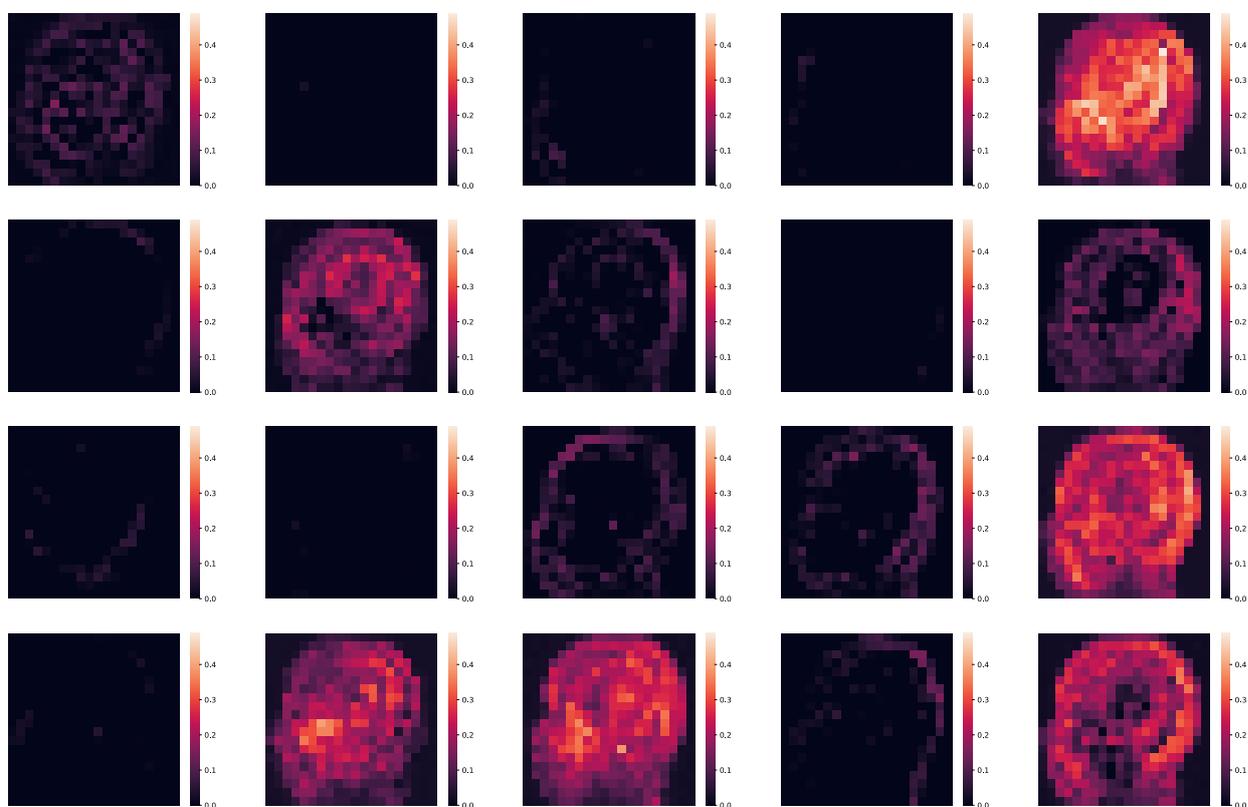


図 B.3: 第 2 プーリング層の特徴マップ — 女性 — Sagittal

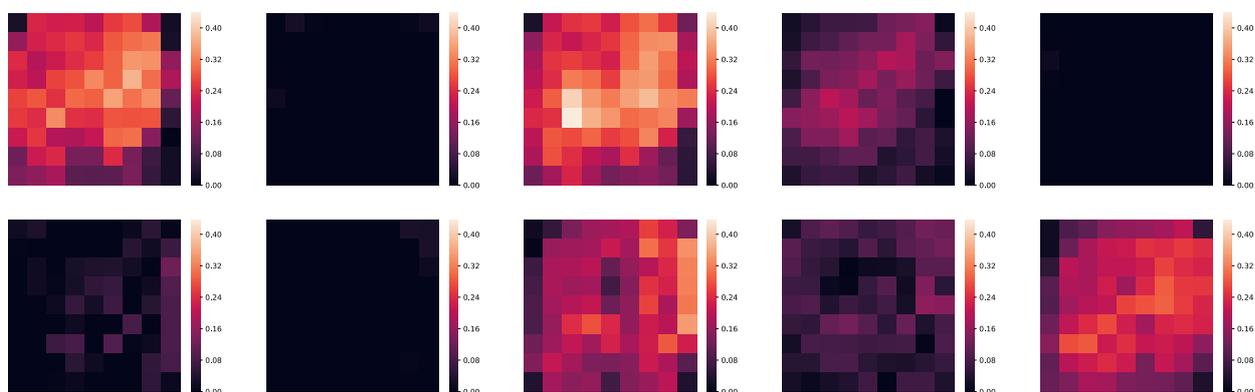


図 B.4: 第 3 プーリング層の特徴マップ — 女性 — Sagittal

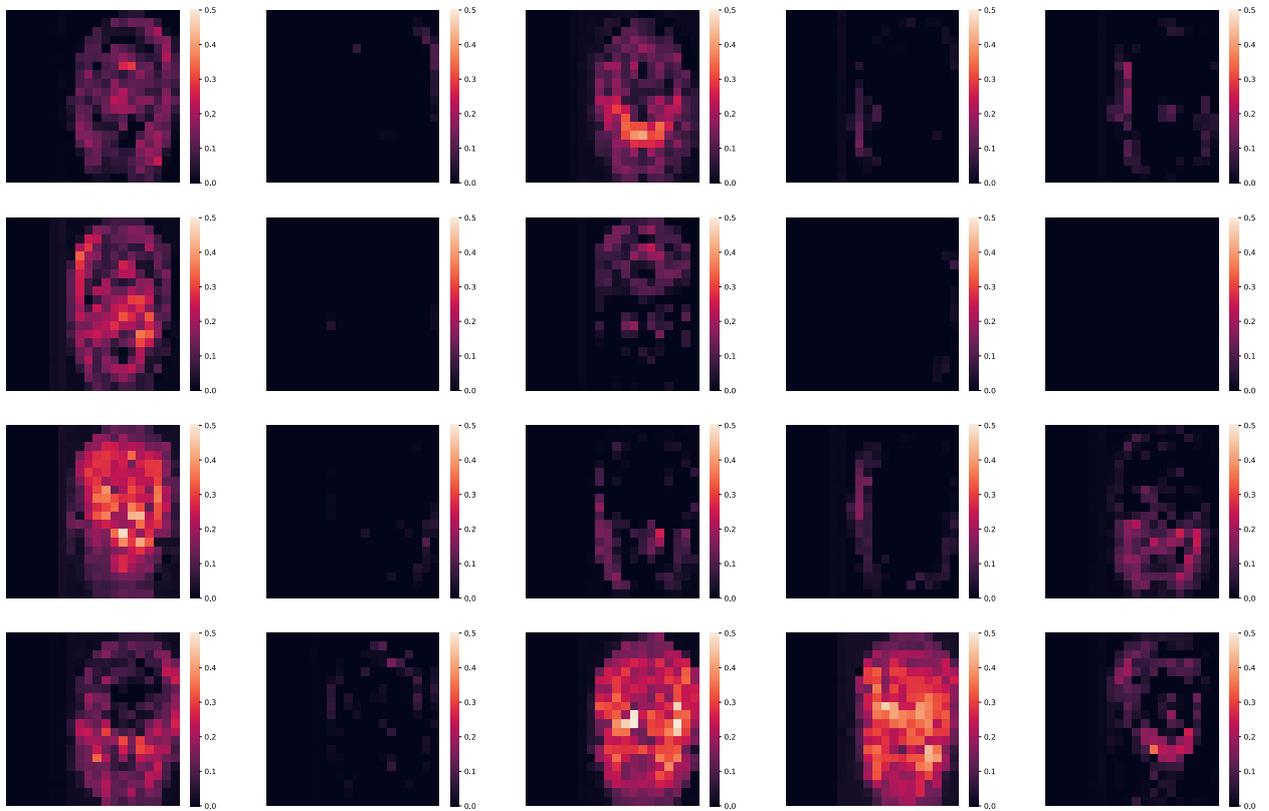


図 B.5: 第 2 プーリング層の特徴マップ — 男性 — Coronal

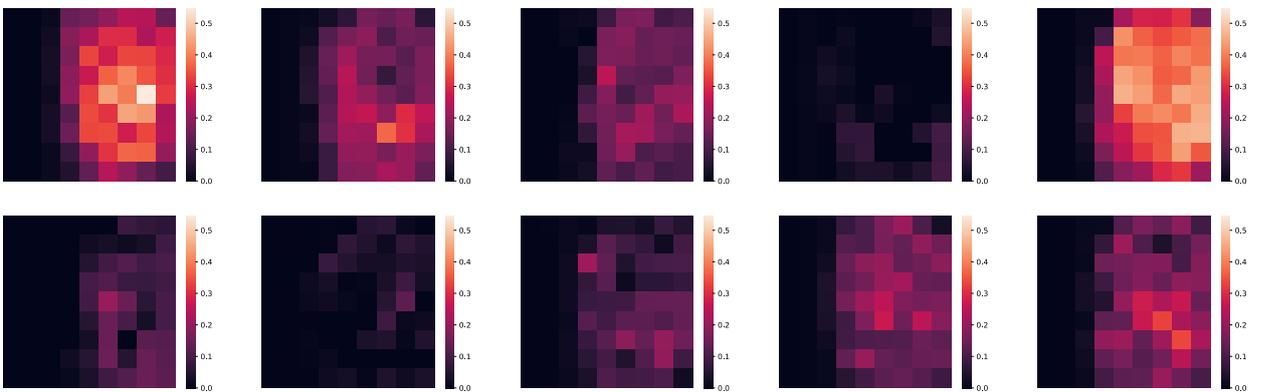


図 B.6: 第 3 プーリング層の特徴マップ — 男性 — Coronal

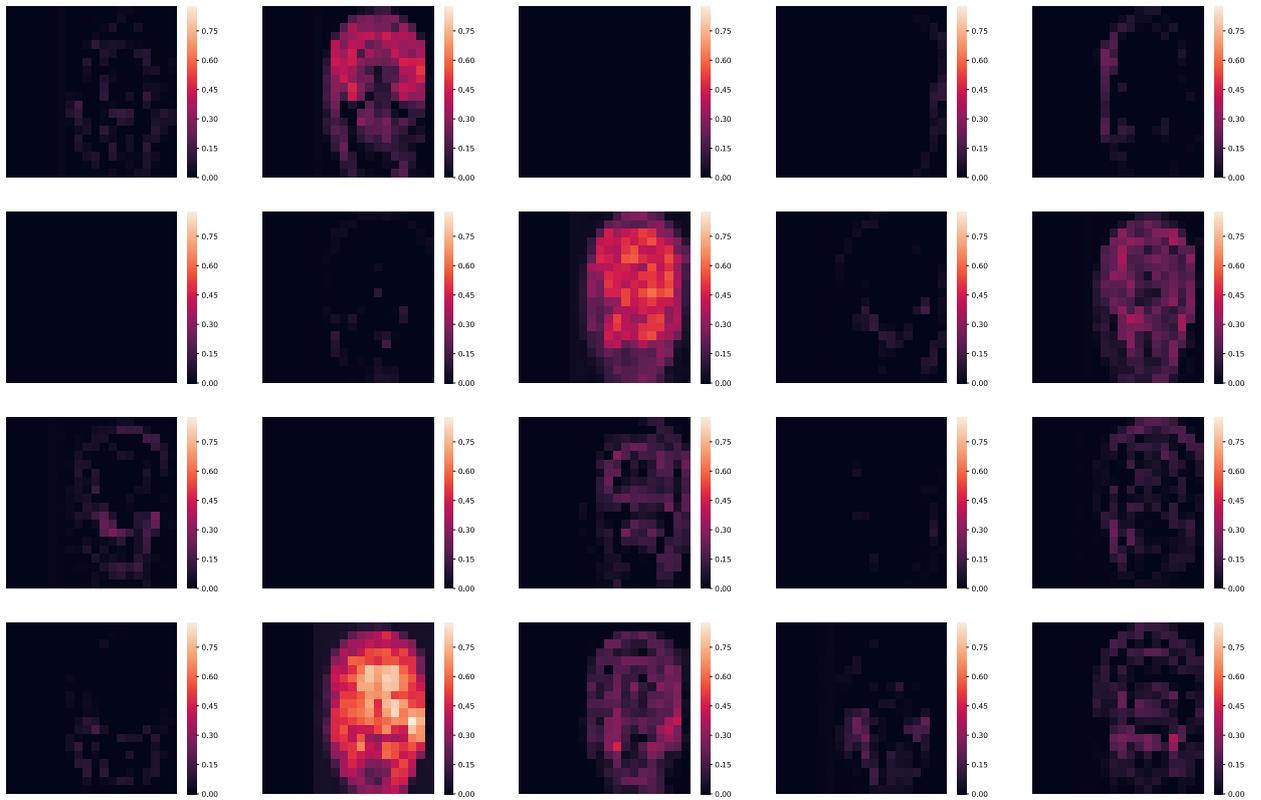


図 B.7: 第 2 プーリング層の特徴マップ — 女性 — Coronal

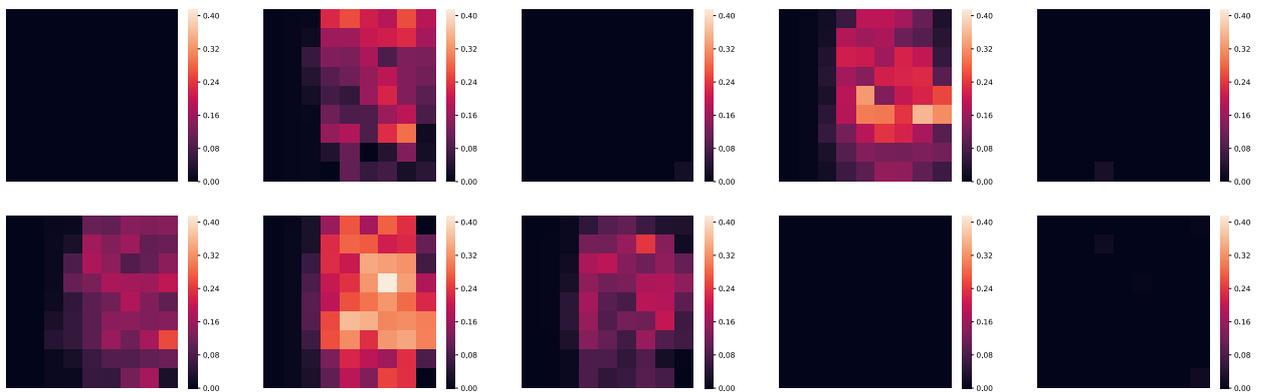


図 B.8: 第 3 プーリング層の特徴マップ — 女性 — Coronal

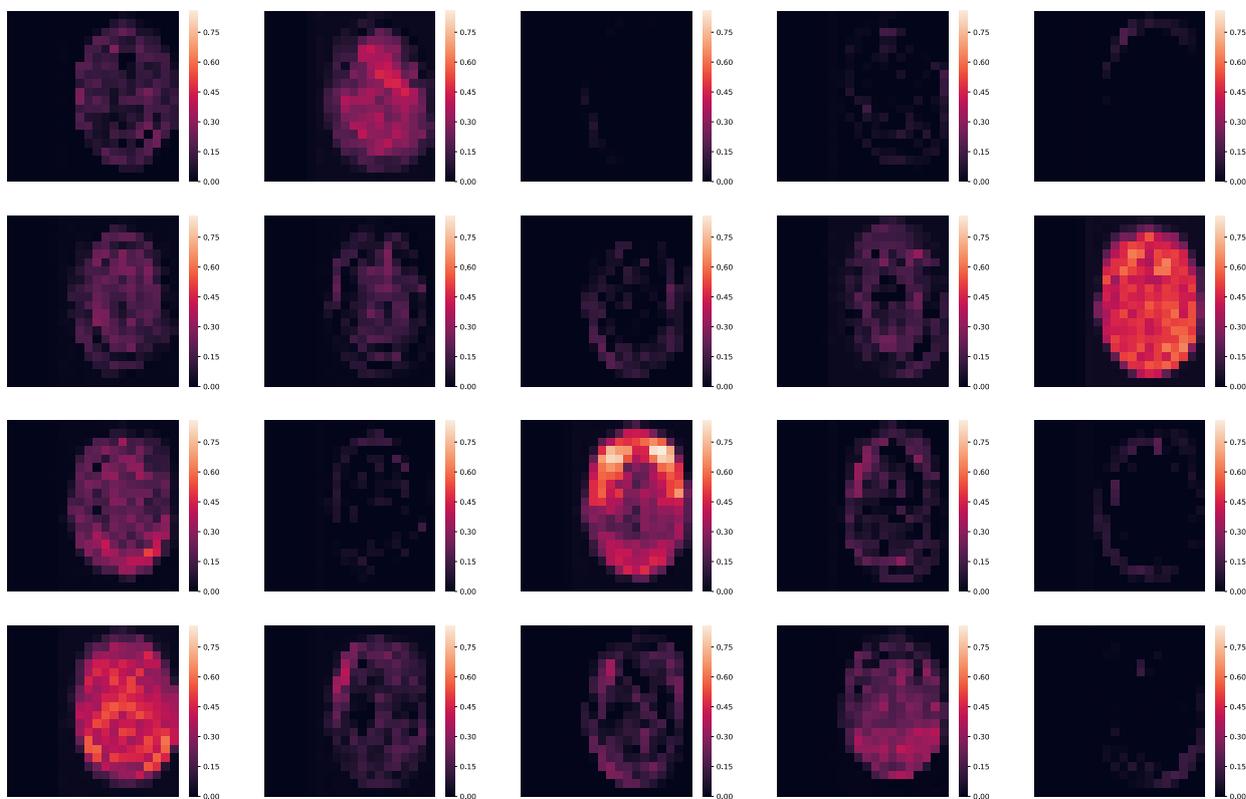


図 B.9: 第 2 プーリング層の特徴マップ — 男性 — Horizontal

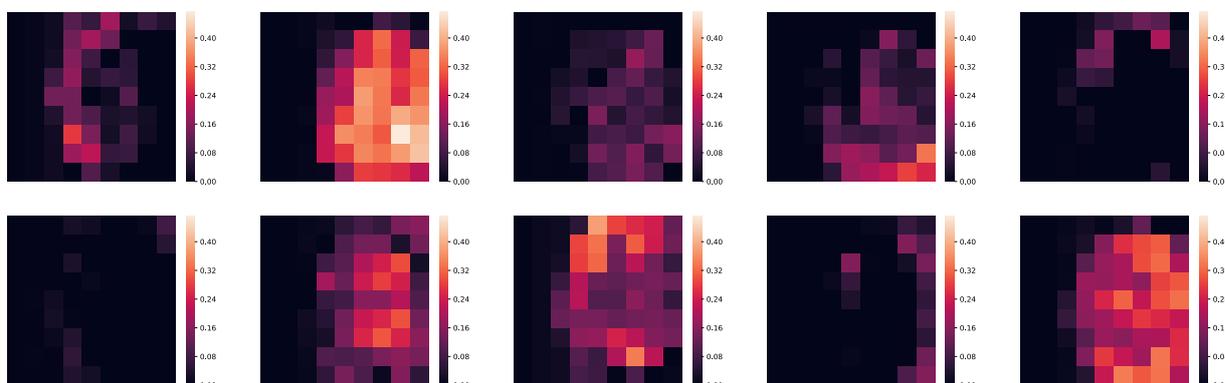


図 B.10: 第 3 プーリング層の特徴マップ — 男性 — Horizontal

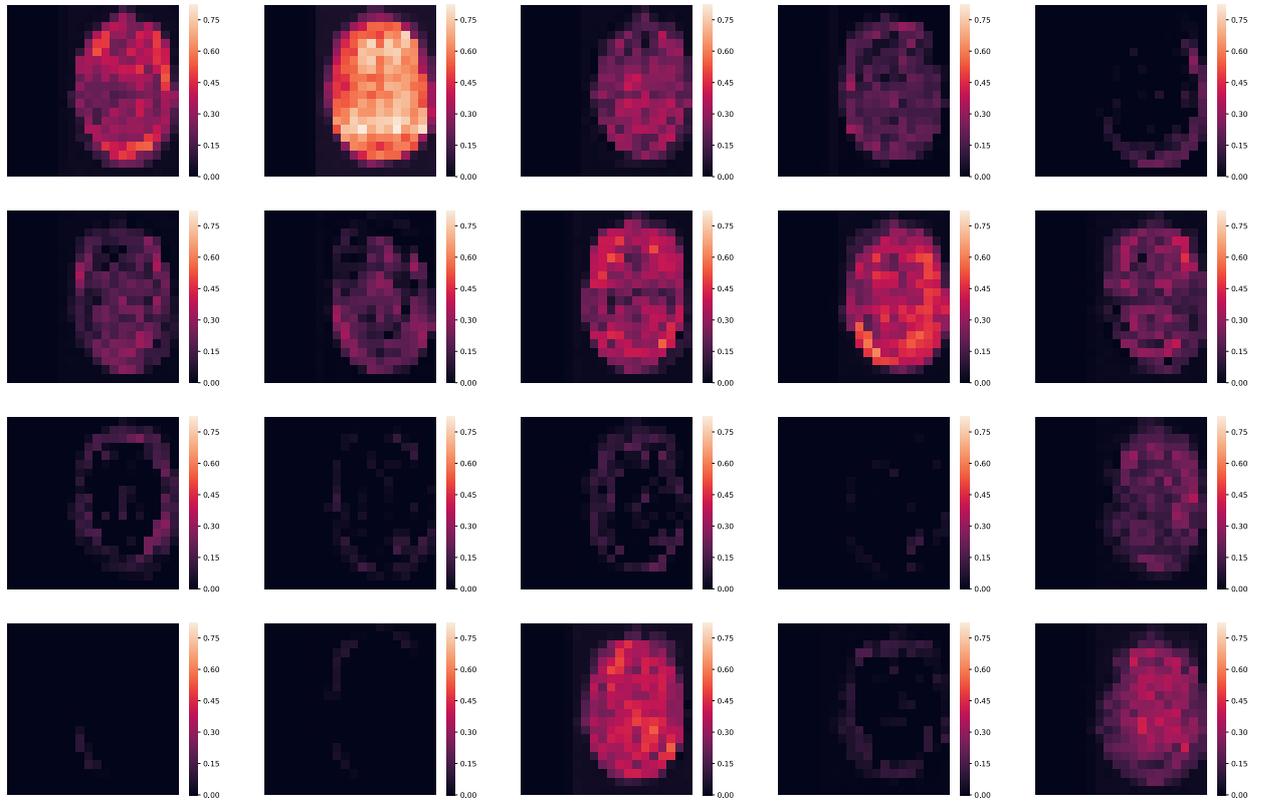


図 B.11: 第 2 プーリング層の特徴マップ — 女性 — Horizontal

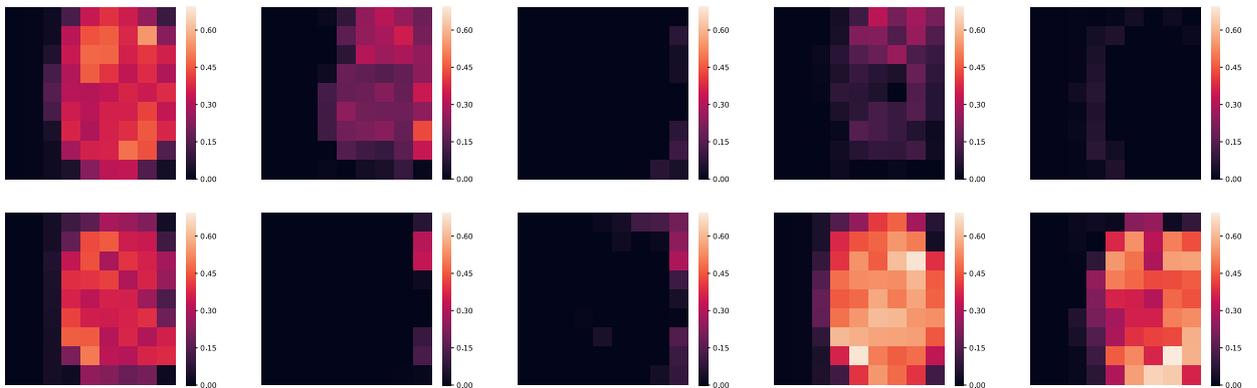


図 B.12: 第 3 プーリング層の特徴マップ — 女性 — Horizontal