

平成 30 年度  
修士学位論文

fMRI を用いた脳情報デコーディング  
における時系列特徴の研究

Study on Time Series Feature Engineering  
for Brain Decoding using  
functional Magnetic Resonance Imaging

1215093 中山梨奈

指導教員 吉田真一

2019 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

## fMRI を用いた脳情報デコーディング における時系列特徴の研究

中山梨奈

近年、脳活動から人の見ているものや聞いているもの、運動の内容、心の内部状態を推定する脳情報デコーディングの研究が行われている。従来の脳情報デコーディングでは、脳の単一ボクセルにおけるある時刻の脳活動値を特徴とする単変量解析や、脳の複数ボクセルにおけるある時刻の脳活動値のパターンを特徴とする多変量解析によって人の状態推定が行われてきた。これらの解析手法では、ある瞬間のみの脳活動値を解析に用いてきた。しかし近年、脳活動の時間変化に着目した Default Mode Network(DMN) の研究が行われている。DMN とは、安静時 fMRI における神経活動の振幅 (0.1Hz 以下) が同期している領域を見出すというものであり、脳活動には時間変化が存在することが明らかになっている。本研究では、安静時以外にも時系列パターンに特徴があると考え、2つの時系列解析手法の提案、有用性の検証を行う。1つ目は、個々ボクセルの脳活動値の時系列パターンを特徴とする時系列解析であり、被験者の運動内容の推定を行う。また、一般的に時系列データは変動が激しくノイズなどを含むため、脳波データ解析にも用いられているトポロジカルデータ分析 (TDA) と 1次元畳み込みニューラルネットワーク (1dCNN) も適用する。結果は、トポロジカルデータ分析を適用しない時系列解析の推定精度は 64%~100%であった。2つ目は、単一ボクセルにおける脳活動値の時系列パターンを特徴とする時系列解析であり、被験者の運動内容と見ている内容の推定を行う。結果は、従来手法の推定精度と比較した時、線形サポートベクトルマシン (SVM) を用いた場合で、45 秒分の脳活動値の時系列パターンを特徴とした提案手法の推定精度が最も高く、運動内容の推定においては 74%~95%、見て

いる内容の推定においては 88%~96%であった。このことより、安静時以外の脳活動値にも人の状態推定に有効な時系列特徴があることが示唆された。また、高い推定精度が得られた解析には従来手法では着目されないボクセルも選択されていたことから、従来手法では着目されないボクセルから人の状態推定に有効な特徴を得られることが示唆された。

キーワード 脳情報デコーディング, 安静時 fMRI, Default Mode Network, 時系列データ解析, トポロジカルデータ分析, 線形サポートベクトルマシン (SVM), 1次元畳み込みニューラルネットワーク (1dCNN, 1D-CNN)

# Abstract

## Study on Time Series Feature Engineering for Brain Decoding using functional Magnetic Resonance Imaging

In recent years, research on brain decoding that estimates what people are seeing or hearing, contents of exercise, internal state of mind from brain activity is being conducted. In conventional brain decoding, univariate analysis, which extract brain activity values at a certain time in a single voxel of the brain as a feature and multivariate analysis which extract a pattern of brain activity values at a certain time in multiple voxels of the brain as feature have been used for estimation human condition. In these analysis methods, brain activity values of only a certain moment have been used for analysis. However, in recent years, research on default mode network (DMN) focusing on time series features of resting-state fMRI(rs-fMRI) is being conducted. In this study, we consider that there are time series features other than rfMRI, proposes two time series analysis methods and verifies the usefulness. The first is time series analysis characterized by time series patterns of brain activity values of individual voxels and estimates the exercise contents of subjects. We also apply topological data analysis(TDA) and 1-dimensional convolutional neural network (1dCNN). As a result, the estimation accuracy of time series analysis without TDA is 64% to 100%. The second is a time series analysis characterized by time series patterns of brain activity values in a single voxel and estimates exercise contents of subjects, what the subject is seeing.

As a result, compared with the estimation accuracy of the conventional method using linear support vector machine (SVM), the estimation accuracy of the proposed method featuring the time series pattern of brain activity value for 45 seconds is the highest, and 74% to 95% in the estimation of the exercise contents, and 88% to 96% in the estimation of what the subject is seeing. This suggests that brain activity values other than rfMRI also have time-series features that are effective for human state estimation. In addition, since voxels not focused on in the conventional method were also selected in the analysis for which high estimation accuracy was obtained, it was suggested that effective features for human state estimation could be obtained from voxels not focused on in the conventional method.

**key words** brain decoding, resting-state fMRI (rs-fMRI), default mode network (DMN), time series analysis, TDA(topological data analysis), 1dCNN (1-dimensional convolutional neural network, 1D-CNN)

# 目次

第 1 章	序論	1
第 2 章	脳情報デコーディング	4
2.1	脳活動計測	4
2.2	脳活動解析	7
	単変量解析	7
	多変量解析	8
2.3	機械学習	8
第 3 章	提案手法	9
3.1	提案手法 1：個々ボクセルの脳活動値の時系列パターン	10
3.1.1	脳活動計測	12
3.1.2	脳活動解析	13
3.1.3	機械学習	15
3.2	提案手法 2：単一ボクセルにおける脳活動値の時系列パターン	16
3.2.1	脳活動計測	16
3.2.2	脳活動解析	17
3.2.3	機械学習	17
第 4 章	実験および解析	18
4.1	提案手法 1	18
4.1.1	実験装置	18
4.1.2	実験デザイン	19
	タッピングタスク	19
	ジャンケンタスク	19

## 目次

4.1.3	SPM における解析のための画像変換 . . . . .	20
4.1.4	前処理 . . . . .	20
4.1.5	ボクセル選択による脳活動値取得 . . . . .	21
	Active Voxel : タスク時に賦活しているボクセル . . . . .	21
	Motor Voxel : タスクとの関連が予測されるボクセル . . . . .	22
4.1.6	特徴抽出 . . . . .	24
	Time Series Data . . . . .	24
	TDA Data . . . . .	25
4.1.7	機械学習・精度評価 . . . . .	27
4.1.8	機械学習アルゴリズム : SVM . . . . .	27
4.1.9	機械学習アルゴリズム : 1dCNN . . . . .	28
4.1.10	精度評価 . . . . .	28
4.2	提案手法 2 . . . . .	29
4.2.1	実験装置 . . . . .	29
4.2.2	実験デザイン . . . . .	29
	タッピングタスク . . . . .	29
	ジャンケンタスク . . . . .	29
	斜線動画順序呈示タスク . . . . .	29
	斜線動画ランダム呈示タスク . . . . .	30
4.2.3	SPM における解析のための画像変換 . . . . .	31
4.2.4	前処理 . . . . .	31
4.2.5	ボクセル選択による脳活動値取得 . . . . .	31
4.2.6	特徴抽出 . . . . .	32
4.2.7	機械学習・精度評価 . . . . .	34
4.2.8	機械学習アルゴリズム : SVM . . . . .	34
4.2.9	精度評価 . . . . .	34

## 目次

<b>第 5 章</b>	<b>結果および考察</b>	<b>36</b>
5.1	提案手法 1 . . . . .	36
5.1.1	タッピングタスク . . . . .	36
5.1.2	ジャンケンタスク . . . . .	39
5.2	提案手法 2 . . . . .	41
5.2.1	タッピングタスク . . . . .	41
5.2.2	ジャンケンタスク . . . . .	44
5.2.3	斜線動画順序提示タスク . . . . .	46
5.2.4	斜線動画ランダム提示タスク . . . . .	49
<b>第 6 章</b>	<b>結論</b>	<b>53</b>
	謝辞	56
	参考文献	58
付録 A	脳部位の詳細	61



# 目次

2.1	BOLD 効果のメカニズム	6
2.2	ボクセル	7
3.1	従来手法と提案手法の違い	10
3.2	穴の種類	11
3.3	データ点の直径の変化に伴う穴の発生と消滅	11
3.4	バーコード	12
3.5	3次元空間への埋め込み：Time Series Data	14
3.6	3次元空間への埋め込み：Quasi-attractor	14
4.1	実験デザイン：タッピングタスク	19
4.2	実験デザイン：ジャンケンタスク	20
4.3	抽出された脳活動値	24
4.4	各ボクセルごとに1タスクから得られる特徴ベクトル：Time Series Data	25
4.5	Quasi-attractor	26
4.6	バーコードから得られる特徴ベクトル：TDA Data	26
4.7	leave-one-out 交差検証法	28
4.8	実験デザイン：斜線動画提示タスク 1	30
4.9	レスト画像	30
4.10	45度の斜線	30
4.11	135度の斜線	30
4.12	実験デザイン：斜線動画提示タスク 2	31
4.13	1時系列脳活動値から得られる特徴ベクトル：単一ボクセルにおける時系列パターン	33

## 図目次

4.14	テストデータと教師データの Z 値の重複を考慮した交差検証法 . . . . .	35
5.1	提案手法 1 : 全被験者のタッピングタスクの推定精度の平均 (%) . . . . .	38
5.2	提案手法 1 : 全被験者のジャンケンタスクの推定精度の平均 (%) . . . . .	39
5.3	従来手法と提案手法 2 の全被験者のタッピングタスクの推定精度の平均 (%)	42
5.4	従来手法と提案手法 2 の全被験者のジャンケンタスクの推定精度の平均 (%)	44
5.5	被験者 C, グー時の脳活動値 : $\tau=1$ で 3 次元空間への埋め込み . . . . .	46
5.6	被験者 C, チョキ時の脳活動値 : $\tau=1$ で 3 次元空間への埋め込み . . . . .	46
5.7	従来手法と提案手法 2 の全被験者の斜線動画順序提示タスクの推定精度の平均 (%) . . . . .	47
5.8	被験者 E, 45 度の斜線動画提示 4 試行目の脳活動値 : $\tau=1$ で 3 次元空間への埋め込み . . . . .	49
5.9	被験者 E, 135 度の斜線動画提示 4 試行目の脳活動値 : $\tau=1$ で 3 次元空間への埋め込み . . . . .	49
5.10	従来手法と提案手法 2 の全被験者の斜線動画ランダム提示タスクの推定精度の平均 (%) . . . . .	50
5.11	被験者 D, 45 度の斜線動画提示 1 試行目の脳活動値 : $\tau=1$ で 3 次元空間への埋め込み . . . . .	52
5.12	被験者 D, 135 度の斜線動画提示 1 試行目の脳活動値 : $\tau=5$ で 3 次元空間への埋め込み . . . . .	52

# 表目次

2.1	脳活動計測法の特徴	6
4.1	実験内容と被験者の対応	18
4.2	有意水準 (uncorrected)	22
4.3	Motor Voxel の座標一覧	23
4.4	生成する TDA Data 一覧	27
4.5	生成した特徴ベクトル情報	27
5.1	提案手法 1 : SVM を用いた場合のタッピングタスクの推定精度 (%)	38
5.2	提案手法 1 : 1dCNN を用いた場合のタッピングタスクの推定精度の平均 (%)	38
5.3	提案手法 1 : SVM を用いた場合のジャンケンタスクの推定精度 (%)	40
5.4	提案手法 1 : 1dCNN を用いた場合のジャンケンタスクの推定精度 (%)	40
5.5	従来手法と提案手法 2 のタッピングタスクの推定精度比較 (%)	43
5.6	タッピングタスクの推定時に選択されたボクセルが含まれる脳部位	43
5.7	従来手法と提案手法 2 のジャンケンタスクの推定精度比較 (%)	45
5.8	ジャンケンタスクの推定時に選択されたボクセルが含まれる脳部位	45
5.9	従来手法と提案手法 2 の斜線動画順序提示タスクの推定精度比較 (%)	48
5.10	斜線動画順序提示タスクの推定時に選択されたボクセルが含まれる脳部位	48
5.11	従来手法と提案手法 2 の斜線動画ランダム提示タスクの推定精度比較 (%)	51
5.12	斜線動画ランダム提示タスクの推定時に選択されたボクセルが含まれる脳部位	51
A.1	運動タスクとの関連が予測される脳部位	61
A.2	視覚刺激動画提示タスクとの関連が予測される脳部位	62
A.3	その他の脳部位	62

# 第 1 章

## 序論

脳情報デコーディングは、Haxby による研究 [2] において、fMRI 脳活動計測値をパターン認識としてとらえることが提案されたことがその始まりである。この研究は、顔や人の顔、5つの人工物、建物、意味のない画像の複数クラスの画像を、被験者がそれらを見たときの fMRI による脳計測ボクセル値のパターンにより推定するものであり、あらかじめクラスが既知である脳活動パターンと、未知の脳活動パターンの相関から、未知のクラスを推定している。その後、パターンに対して教師付き機械学習を使った研究が Kamitani と Tong[3]、および Haynes と Ree[4] により独立に提案され、脳情報デコーディング（ブレインデコーディング）の研究が盛んに行われるようになった。文献 [3] の研究では線形カーネルの SVM (Support Vector Machine) が、文献 [4] の研究では線形判別分析 (LDA: Linear Discriminant Analysis) が用いられている。どちらの研究も、脳情報デコーディングの研究として、人の見ている線分の傾き推定を行っており、被験者に 45 度の線分画像と 135 度の線分画像を呈示し、このときの脳活動を学習し、デコーダを構築する。そして、同じ被験者に 45 度の線分と 135 度の線分が重なっている画像を呈示し、45 度が 135 度のどちらかの線分に注目するよう指示を出す。このときの脳活動をデコーダで評価することで、被験者の見ている線分の傾きの推定を行った結果、90%を超える推定精度が得られたと報告されている。こうした斜線の角度を推定することを行った理由の一つとして、Hubel と Wiesel のネコの脳に線分の傾きに反応する神経細胞を発見した研究 [5] があり \*<sup>1</sup>、脳の中で異なる場所での神経活動が行われていることが明らかであることによると考えられる。脳情報デコー

---

\*<sup>1</sup> 1981 年ノーベル医学・生理学賞受賞

ディングの研究は、多くの研究が行われており、視覚の分野を中心に白黒画面に呈示されたアルファベットの文字や単純図形を脳活動信号のみから再構成するもの [7]、被験者が見ているカラーの動画像を推定するもの [8]、寝ている人の夢の映像の推定 [9]、過去に見た映像の想起の推定 [10] などが行われている。また、多くのサーベイも行われている [1]。

また、複数の脳活動計測結果のボクセル値をパターンとしてとらえる研究は、ブレインデコーディングだけでなく、多変量パターン解析 (MVPA: Multivariate Pattern Analysis) \*2 として、通常の神経科学的な脳活動の研究にも応用されている [6]。

これまでの脳活動の賦活を調べる神経科学の研究では、脳の単一ボクセルにおけるある時刻の脳活動値を特徴とする単変量解析を行うことで、相関の高い脳の位置を特定してきた。これを拡張し、先に述べた脳情報デコーディングの研究や、近年の神経科学研究では、脳の複数ボクセルにおけるある時刻の脳活動値のパターンを特徴とする多変量解析が用いられてきている。どちらの研究でもある自国の脳活動のボクセル値またはパターンのみに着目している。一方で、安静時における神経活動の時系列パターン (0.1Hz 以下の振幅、すなわち 10 秒周期) が同期している脳領域を見出す Default Mode Network(DMN) の研究が行われており、脳活動には時間変化が存在することが明らかになっている [11]。

そこで、本研究では、安静時以外にも時系列パターンに特徴は存在すると考え、脳情報デコーディングにおける 2 つの時系列解析を提案する。1 つ目は、個々ボクセルの脳活動値の時系列パターンを特徴とする時系列解析 [12] で、脳波の解析において用いられたこともあるトポロジカルデータ解析 (TDA: Topological Data Analysis, 位相的データ解析) を用いるもので、2 つ目は単一ボクセルにおける脳活動値の時系列パターンを特徴とする時系列解析で、それぞれの有用性の検証を行う。

本論文の構成は、第 2 章では、脳情報デコーディングの概要を述べる。第 3 章では、本研究で提案する脳活動の時系列パターンを特徴として用いる手法の詳細を述べる。第 4 章で

---

\*2 以前は、MVPA を Multi-Voxel Pattern Analysis の略とすることもあったが近年は、fMRI だけでなく広く一般の複数チャネルからの信号値を多変量としてとらえることにも応用できることから、より一般に Multivariate Pattern Analysis の略とすることが多い

は、実験および解析として、fMRI データを得る被験者実験とそのタスク内容、ボクセル選択や特徴抽出など提案手法による解析、機械学習について述べる。第 5 章では、実験および解析の結果を示し、提案手法の有用性を示し、考察を述べる。第 6 章では、本研究の結論を述べる。

## 第 2 章

# 脳情報デコーディング

近年、脳情報デコーディングの研究が活発に行われている。脳情報デコーディングとは、脳活動から人の見ているものや聞いているもの、運動の内容、心の内部状態を推定する技術である。

本章では、従来の脳情報デコーディングにおける解析の流れについて記す。

### 2.1 脳活動計測

脳活動計測法には、表 2.1 に示すように、fMRI(functional Magnetic Resonance Imaging: 機能的磁気共鳴画像法) や EEG(Electroencephalography: 脳波), NIRS(Near InfraRed Spectroscopy: 近赤外分光法), PET(Positron Emission Tomography: 陽電子放出断層撮影) など、様々な種類・特徴があり、脳情報デコーディングでは fMRI が用いられることが多い。その理由として、1 画素あたり約 2mm 程度という空間分解能の高さで、深部を含めた脳全体の活動を計測できることが挙げられる。しかし、全脳を計測する場合には時間分解能が約 3 秒程度と他の計測法と比較すると長いことが欠点である。

fMRI で得られる情報は、脳の賦活を直接的に示しているわけではなく、MR 信号 (磁気共鳴) と呼ばれる信号強度から脳が賦活した可能性の高さを示している。MR 信号とは、人の体内に多く存在する水素原子由来の信号である。水素原子は、1 個の陽子と 1 個の電子で構成されており、陽子の周囲を電子が回転 (スピン) している。通常時、このスピンの方向に指向性はないため、全体としての磁場は打ち消し合っている状態となる。MRI 装置では、まず強い静磁場によりこの水素原子のスピンの向きを強制的に同一方向に修正し、126MHz

## 2.1 脳活動計測

の電磁場 (RF 波) を照射することでスピンのエネルギーを与える。RF 波によりエネルギーが与えられている間を励起, RF 波の照射をやめることでスピンの状態へ回復する過程を緩和と言う。MRI 装置は, 水素原子が緩和の際に放出する電磁波を MR 信号として収集・画像化する。

この MR 信号の強度は脳活動に由来する血中酸素飽和の度合いによって変動し, BOLD(Blood Oxygenation Level Dependency) 効果と呼ばれる。BOLD 効果のメカニズムを図 2.1 に示す。

まず, 人の血液中には反磁性体である酸化ヘモグロビン (oxy-Hb) と磁性体である還元ヘモグロビン (deoxy-Hb) の 2 つが存在している。生体内の神経細胞は酸素を必要とし, 酸素は動脈血中の酸化ヘモグロビンによって供給される。酸素を神経細胞へ放出した酸化ヘモグロビンは還元ヘモグロビンとなり静脈血中へ運ばれる。定常状態時は血中に酸化ヘモグロビンと還元ヘモグロビンは一定の割合で含まれており, 磁性体である還元ヘモグロビンが MR 信号を減少させている。ただし, 神経細胞が賦活すると (賦活状態時), 賦活部位の神経細胞の酸素消費量が増加し, 一時的な酸素濃度の低下を引き起こす。これに伴い, 酸素濃度の低下を防ぐために血流量が増大し, 大量の酸化ヘモグロビンが送られる。すると, 賦活部位の神経細胞は酸素を消費しきれなくなり, MR 信号を減少させていた還元ヘモグロビンが相対的に減少するため, 賦活部位の MR 信号は増加する。

近年では, 複数の異なる周波数の RF 波を同時に照射することで複数脳部位の同時励起・同時 MR 信号収集するマルチバンド 2 次元 EPI 撮像法という技術が開発されており, 時間分解能の向上, 脳計測時間の短縮などが可能である。

MRI 装置では脳の前後・左右・上下から上記の原理で計測しているため, fMRI データでは 3 次元データとなり図 2.2 に示すようなボクセルという単位を用いる。また, 計測の際にはパラメータを設定する必要がある。例えば, 水素原子の励起する角度をフリップアングル, 水素原子が励起してから信号を収集するまでの時間を TE(echo time), 水素原子が励起してから次の励起までの時間を TR(repetition time) などである。TR は, 1 スキャン (= 1 回に計測される 3 次元脳データ) にかかる時間でもあり, マルチバンド 2 次元 EPI 撮像法の



## 2.1 脳活動計測

場合は通常の撮像法の数倍の速さで1 スキャンが可能となる。

表 2.1 脳活動計測法の特徴

脳活動計測法	長所	短所
fMRI	空間分解能が高い (2mm 程度)	時間分解能が低い (3sec 程度)
EEG	時間分解能が高い (1msec 程度)	空間分解能が低い (3cm 程度)
NIRS	時間分解能が高い (数 10msec 程度)	空間分解能が低い (3cm 程度)
PET	雑音が少ない	時間分解能が低い (約 10sec 程度)

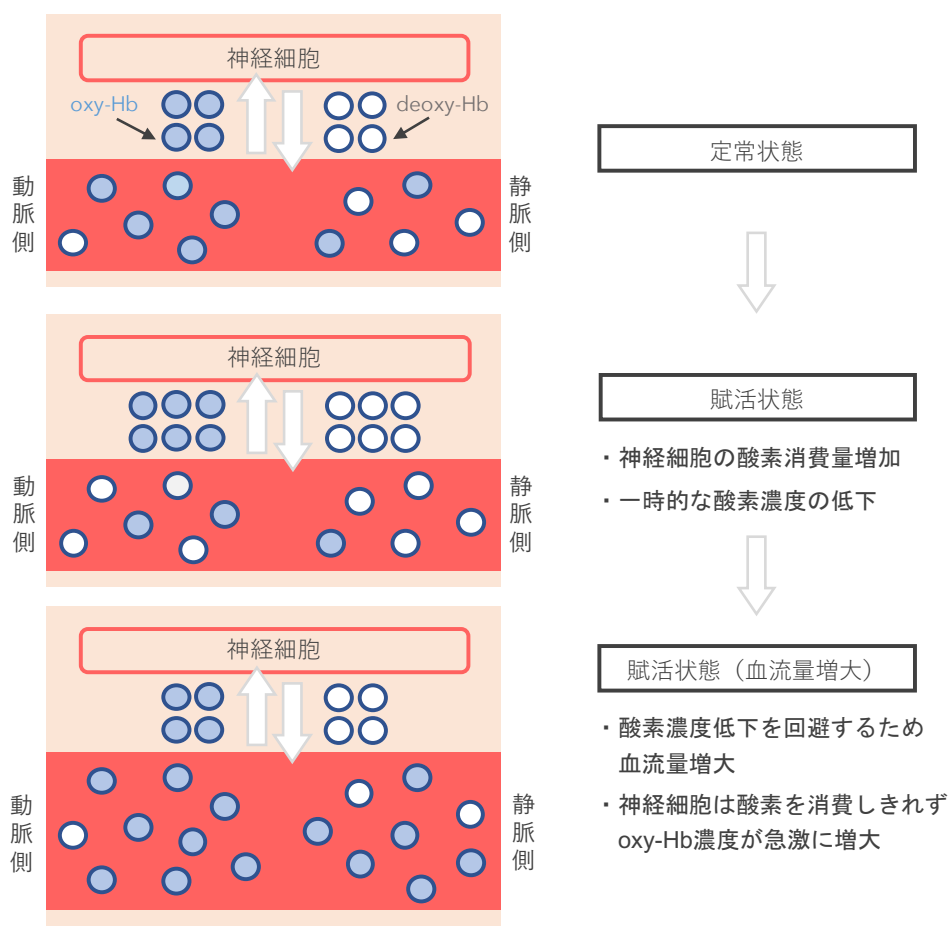


図 2.1 BOLD 効果のメカニズム

## 2.2 脳活動解析

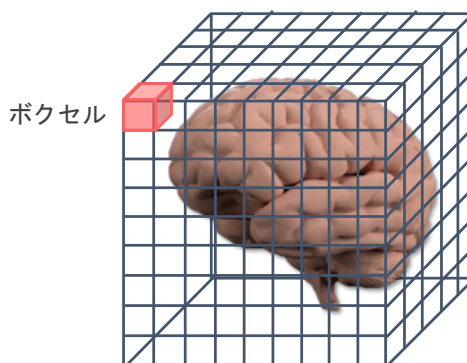


図 2.2 ボクセル

## 2.2 脳活動解析

fMRI データを解析する手法として、単変量解析や多変量解析などが挙げられる。

### 単変量解析

単変量解析では、脳の単一ボクセルにおけるある時刻の脳活動値を特徴として取得する解析法であり、SPM(Statistical Parametric Mapping) などが挙げられる。

SPM は、脳機能画像解析用に作成された国際標準の代表的なソフトウェアである [13]. SPM では、個々のボクセルで分散を計算し、その結果から個々のボクセルに対して t 検定を行うことで t 統計量や Z 値を求める。そして、有意な t 統計量や Z 値を有するボクセルを特定・表示している [14].

Z 値とは、下式 (2.1) のように各ボクセルの  $i$  スキャン目におけるボクセル値  $x_i$  と分布の平均値 ( $\mu$ ) の差を標準偏差 ( $\sigma$ ) で割ることで求められる。この Z 値の値が 0 のとき、 $x_i$  は平均値と等しく、Z 値の値が 0 から離れる程、分布の平均値からのズレが大きいことを示す。本研究では、この Z 値を脳活動値とする。

$$Z \text{ 値} = \frac{x_i - \mu}{\sigma} \quad (2.1)$$

## 2.3 機械学習

### 多変量解析

多変量解析では、脳の複数ボクセルにおけるある時刻の脳活動値のパターンを特徴として取得する解析法である。

人の脳では、2つの同じ現象に反応する脳領域は同じでも、その領域に含まれるボクセル群の脳活動値のパターンが異なることがある。単変量解析ではこうした違いを捉えることは不可能であるが、多変量解析ではこのような空間的パターンの違いを捉えることが可能であるため、より高精度な推定が可能となる [15]。ただし、fMRI データは数十万ものボクセル情報を有しており、解析に使用するボクセルが多くなるほど空間的パターン数が膨大になる。そのため、多変量解析において推定に有効なボクセル選択は高い推定精度を目指す上で重要となる。

これまでは、推定に有効なボクセルを選択するにあたり、推定したい状態と関連が予測される脳領域において SPM を用いて統計的に有意なボクセルを特定・選択する BDTB (Brain Decoder ToolBox) が主に用いられてきた。脳領域の選択には、ブロードマンの脳地図が用いられることが多い。ブロードマンの脳地図とは、ドイツの医師であり神経生物学者の Korbinian Brodmann による人の大脳皮質の解剖学的区分の通称である。

また、中路ら [16] は fMRI 画像における画素値と推定したい状態の種類の違いの間の相関を求め、相関係数の絶対値の高いボクセルを選択する方法を提案している。

## 2.3 機械学習

脳情報デコーディングに用いられる機械学習アルゴリズムとして、サポートベクターマシン (Support Vector Machine : SVM) が挙げられる。

SVM は、脳情報デコーディングに用いられる 4 つの機械学習アルゴリズム (SVM, ニューラルネットワーク, ランダムフォレスト, Sparse Logistic Regression) の精度や速度を比較した小池ら [17] の研究において、高い性能を発揮すると報告されている。

## 第3章

# 提案手法

これまでの脳情報デコーディングでは、高橋や山中ら [18][19] は人間の感情推定の研究として画像から誘発される快・不快画像の推定を行い、前原ら [20] は人の表情から誘起される喜び・怒りの推定を行い、それぞれ約 80%の精度で推定できることが報告されている。しかし、被験者によっては推定精度が 40%と、チャンスレベルよりも低いものもあることから、より安定して高い精度で推定できる解析手法の提案が必要であると考えます。

これらの先行研究では、単変量解析や多変量解析など、ある瞬間のみの脳活動値に着目しているが、安静時における神経活動の時系列パターン (0.1Hz 以下の振幅) が同期している脳領域を見出す Default Mode Network(DMN) の研究が行われており、脳活動には時間変化が存在することが明らかになっている [11]。

本研究では、安静時以外にも脳活動には時間変化が存在すると考え、脳活動値の時系列パターンを新しい特徴として取得する時系列解析手法の提案により、従来手法よりも安定的に高い精度での人の状態推定を目指す。

本章では、本研究で提案する脳情報デコーディングにおける 2つの時系列解析について記す。1つ目の個々ボクセルの脳活動値の時系列パターンを特徴とする時系列解析を提案手法 1、2つ目の単一ボクセルにおける脳活動値の時系列パターンを特徴とする時系列解析を提案手法 2 とする。図 3.1 には、提案手法である時系列解析と従来手法である単変量解析、多変量解析との違いを示す。

### 3.1 提案手法 1：個々ボクセルの脳活動値の時系列パターン

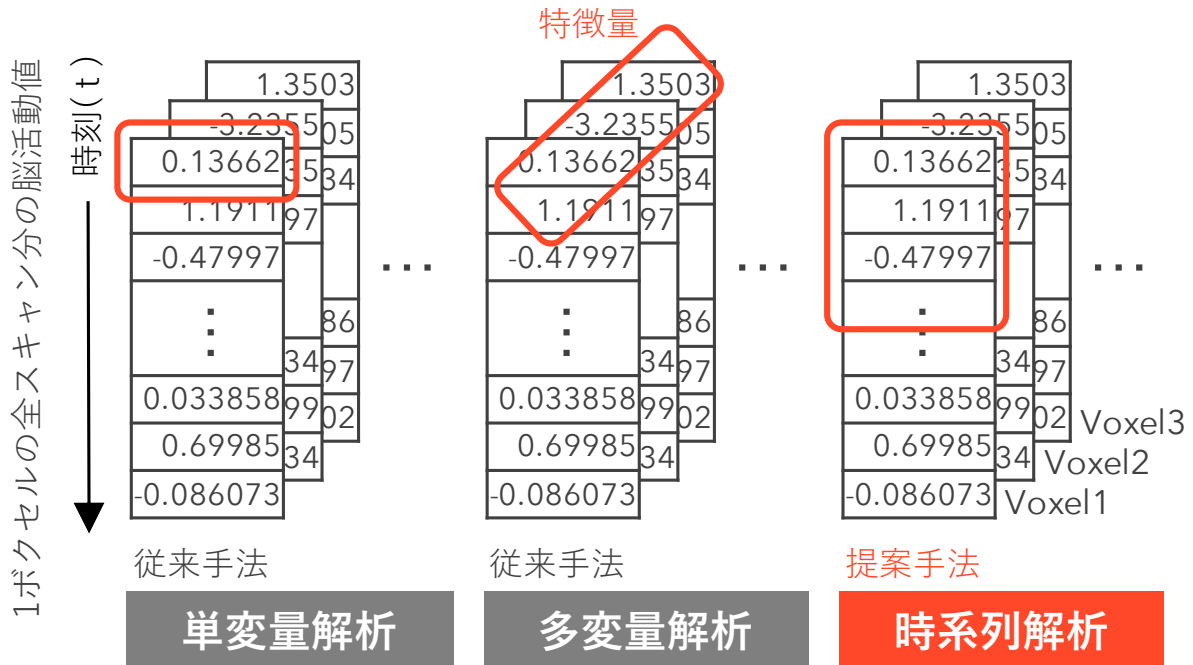


図 3.1 従来手法と提案手法の違い

1zh

### 3.1 提案手法 1：個々ボクセルの脳活動値の時系列パターン

本提案手法では、各ボクセルごとの脳活動値の時系列変化は同期していると考え、個々ボクセルの脳活動値の時系列パターンを特徴とした時系列解析を行う。また、一般的に時系列データは変動が激しくノイズを多く含むため、そのまま解析に用いられることは少ない。そこで、Umeda ら [21] のトポロジカルデータ分析 (Topological Data Analysis : TDA) とディープラーニングを組み合わせた手法による時系列解析の研究を参考にする。

トポロジカルデータ分析 (Topological Data Analysis:TDA)) とは、距離や角度などの様々な性質が失われても残る性質である位相不変量の特徴として捉える分析手法である。TDA で扱う位相不変量はいくつかあり、Umeda らの手法では「穴」に着目する Persistent

### 3.1 提案手法 1：個々ボクセルの脳活動値の時系列パターン

Homology が用いられる。Persistent Homology では、データ点の直径の変化に伴う穴の発生と消滅情報を取得できる。ここで扱う穴には図 3.2 に示すように、一般的な穴である 1 次の穴とデータ点そのものを指す 0 次の穴、空洞を指す 2 次の穴が存在する。これらの穴の情報を可視化するものとしてバーコードがある。図 3.3 の各次の穴の発生時と消滅時の時刻に応じて、図 3.4 のバーコードでは穴発生時の時刻と消滅時の時刻を結んだ直線が並べられている。直線の本数は発生中の穴の数を示しており、穴のような位相不変量の数をベッチ数と呼ぶ。

Umeda らの研究ではあらゆる時系列データからベッチ数を特徴として取得し、分類を行っている。その中でも、目の開閉の時脳波データ解析において、従来手法に比べて約 20% 精度が向上したと報告されている。本提案手法では、fMRI から得られた脳活動データにも適用可能であると考え、個々ボクセルの脳活動値の時系列パターンに TDA を適用する解析も行う。



図 3.2 穴の種類

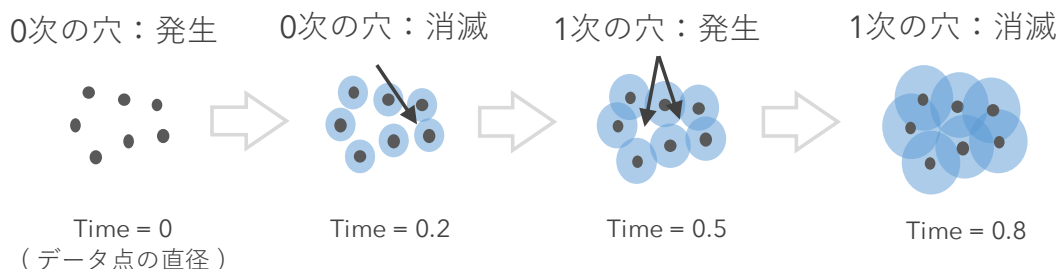


図 3.3 データ点の直径の変化に伴う穴の発生と消滅

### 3.1 提案手法 1：個々ボクセルの脳活動値の時系列パターン




図 3.4 バーコード

#### 3.1.1 脳活動計測

被験者には運動タスクを行ってもらい、そのときの脳活動を MRI 装置を用いて計測する。運動時の脳活動を計測する理由としては、感情誘発タスクのような高次脳機能課題に比べて推定に有効なボクセル選択が可能であると考えたためである。

被験者に行ってもらう運動タスクは 2 種類である。1 つ目はタッピングタスクであり、指を動かしているタッピング時と何もしていない安静時であるレスト時の 2 状態の脳活動を取得する。2 つ目はジャンケンタスクであり、手の形がグーのときとチョキのとき、パーのときの 3 状態の脳活動を取得する。これは、タッピングタスクは時系列変化が存在すると明らかになっている安静時を推定対象の状態として含むため、安静時を含まない似ている状態間でも正しく推定できるかを検証するためである。

### 3.1 提案手法 1：個々ボクセルの脳活動値の時系列パターン

#### 3.1.2 脳活動解析

脳活動解析では、脳活動計測で得られた fMRI データからボクセル選択を行い、各ボクセルが有する脳活動値から特徴抽出を行う。

ボクセル選択では、SPM の個人解析により各タスク時に有意な活動を示す上位 7 ボクセルを Active Voxel、タスクとの関連が予測される部位の 7 ボクセルを Motor Voxel として選択する。これらは、従来の多変量解析においても用いられるボクセル選択方法である。

選択した各ボクセルは、スキャン順つまり時系列順に記録された脳の賦活度合い (MR 信号の大きさ) を標準化した Z 値を脳活動値として有している。特徴抽出では、選択した個々ボクセルが有する全スキャン分の Z 値を特徴ベクトル “Time Series Data”, Time Series Data に TDA を適用したものを特徴ベクトル “TDA Data” として生成する。TDA Data は以下の手順で生成する。

##### 1. 3次元空間への埋め込み

Time Series Data は 1 ボクセルあたりスキャン数分の Z 値が時系列順に並んだ 1 次元時系列データであり、これを 3 次元空間へ埋め込む。埋め込みとは、図 3.5、図 3.6 のように時系列データにおいてある時刻  $t$  の値を 3 次元空間の  $x$  軸、 $t + \tau$  の値を 3 次元空間の  $y$  軸、 $t + 2\tau$  の値を 3 次元空間の  $z$  の座標としてとり、これを時刻  $t$  をずらしながら繰り返すことである。 $\tau$  は時間遅れといい、最適な決定法についてはいくつかの基準が提案されている。本研究では、解析する時系列データの時間相関に関する情報に基づく「自己相関関数が最初に極小値をとる値」を  $\tau$  に設定する [22]。時系列データに時系列パターンが存在していれば、3 次元空間へ埋め込んだデータ点は Quasi-attractor と呼ばれる特徴的な軌道を描く。

##### 2. TDA 適用によるベクトル化

Quasi-attractor に TDA を適用することでバーコードを取得し、0 次～2 次の穴で  $n$  回ベッチ数を取得し、結合する。Umeda らは脳波データ解析の際、 $n$  は 300、ベッチ数を取得する穴の種類は 0 次の穴と 1 次の穴に設定されていた。本提案手法では、 $n$  には



### 3.1 提案手法 1：個々ボクセルの脳活動値の時系列パターン

100 と 200, 穴の種類は 2 次の穴のベッチ数を取得する場合と取得しない場合で特徴ベクトルを生成する. これは, 脳波データ解析時の同様のパラメータはもちろん, 他のパラメータも設定することで, fMRI で得た脳活動データに適したパラメータを検証するためである.




図 3.5 3次元空間への埋め込み：Time Series Data




図 3.6 3次元空間への埋め込み：Quasi-attractor

### 3.1 提案手法 1：個々ボクセルの脳活動値の時系列パターン

#### 3.1.3 機械学習

機械学習では、脳活動解析で得られた特徴を学習することで、与えられた脳活動値のみから状態推定を行う。タッピングタスクの場合はタッピング時とレスト時の 2 状態、ジャンケンタスクの場合は手がグーのとき、チョキのとき、パーのときの 3 状態の推定となる。

機械学習には、従来の脳情報デコーディングで用いられてきた SVM に加え、一次元畳み込みニューラルネットワーク (1-dimensional Convolutional Neural Network : 1dCNN) を用いる。1dCNN は、TDA を用いて得た特徴ベクトルと相性が良いとされる機械学習アルゴリズムである。

## 3.2 提案手法 2：単一ボクセルにおける脳活動値の時系列パターン

提案手法 1 では、タスク時にも脳活動値の時系列パターンが存在することを前提とした解析手法となるが、タスク時における脳活動値に時系列パターンが存在するのか、存在するのであればどのような周期で存在するのか、どのボクセルに存在するのか、特徴として有用性があるのかをより詳細に検証する必要があると考える。そこで本提案手法では、単一ボクセルにおける脳活動値の時系列パターンを特徴とした時系列解析を行う。

### 3.2.1 脳活動計測

提案手法 2 では、提案手法 1 で得られたタッピングタスク時とジャンケンタスク時の脳活動データに加え、新しいタスクを用いて追加実験を行う。追加実験では、被験者に視覚刺激動画呈示タスクを実施し、そのときの脳活動を MRI 装置を用いて計測する。視覚刺激動画呈示時の脳活動を計測する理由としては、運動タスクでは被験者によって運動の速度や強さが異なり、脳活動の時系列変化に統一性がないと考えたためである。

被験者に実施する視覚刺激動画呈示タスクは 2 種類である。

1 つ目は斜線動画順序呈示タスクである。視覚刺激には、Kamitani ら [3] の研究において高い精度で推定可能であると報告されている 45 度の斜線と 135 度の斜線を用いる。ただし、静止画では脳活動変化が微細で瞬間的であることが考えられるため、より脳が活動し続けるよう動画として呈示する。そのため、45 度の斜線が右方向にスライドしている動画を見ている時と 135 度の斜線が右方向にスライドしている動画を見ている時の 2 条件の脳活動を取得する。このタスクは 4 試行行うが、いずれも 45 度の斜線動画、135 度の斜線動画という順序で呈示する。2 つ目は斜線動画ランダム呈示タスクであり、被験者に呈示する視覚刺激動画は視覚刺激動画順序呈示タスクと同様である。ただし、このタスクも 4 試行行うが、45 度の斜線動画と 135 度の斜線動画の呈示順はランダムとする。これは、被験者の刺激に対する予測や慣れを防ぐためである。

## 3.2 提案手法 2：単一ボクセルにおける脳活動値の時系列パターン

### 3.2.2 脳活動解析

脳活動解析では、脳活動計測で得られた fMRI データからボクセル選択を行い、各ボクセルが有する脳活動値から特徴抽出を行う。

ボクセル選択では、大脳にあたる全ボクセルを選択する。これは、タスクとの関連が予測される部位やそれ以外の部位など、様々なボクセルにおいて本提案手法で解析を行うことで、時系列特徴を持つボクセルの特定も目的としている。選択された各ボクセルは提案手法 1 と同様に、スキャン順つまり時系列順に記録された脳の賦活度合い (MR 信号の大きさ) を標準化した Z 値を脳活動値として有している。

特徴抽出では、選択された時系列脳活動値を有するボクセルごとに  $N$  スキャン (秒) 分の Z 値を取得する。 $N$  は時系列幅 (秒) とし、安静時の周期と同様の 10 に加え、15, 30, 45 を設定する。本提案手法では、この時系列幅  $N$  秒分の Z 値を特徴ベクトル“単一ボクセルにおける脳活動値の時系列パターン”とする。特徴ベクトルは、選択された各ボクセルにおける各タスク時の時系列脳活動値ごとに生成する。

### 3.2.3 機械学習

機械学習では、脳活動解析で得られた特徴を学習することで、与えられた脳活動値のみから状態推定を行う。視覚刺激動画提示タスクの場合は 45 度の斜線動画を見ている時と 135 度の斜線動画を見ている時の 2 状態の推定となる。

機械学習には、従来の脳情報デコーディングで用いられてきた SVM を用いる。

## 第 4 章

# 実験および解析

本章では，提案手法 1 と提案手法 2 を用いた実験および解析の流れを記す。

本研究では 5 人の被験者を対象に 4 種類の MRI 実験を行い，被験者と実験内容の対応を表 4.1 に示す。被験者 A, B, D, E は成人男性，被験者 C は成人女性であり，全員右利きである。各被験者には，高知工科大学倫理審査承認 93-C1 に基づき fMRI 装置の原理や実験内容，所要時間，安全性，個人情報保護についての説明を十分に行い，同意を得る。

表 4.1 実験内容と被験者の対応

	被験者 A	被験者 B	被験者 C	被験者 D	被験者 E
タッピングタスク	○	○	○	×	×
ジャンケンタスク	○	○	○	×	×
斜線動画順序提示タスク	×	○	×	○	○
斜線動画ランダム提示タスク	×	×	○	○	○

### 4.1 提案手法 1

#### 4.1.1 実験装置

脳活動計測には MRI 装置を用いる。MRI 装置として，高知工科大学が保有する SIEMENS 社の MAGNETOM Prisma(3T) を使用する。撮像パラメータは，1 ボクセルあたりのサイズが  $2.0 \times 2.0 \times 2.2\text{mm}$ ，スライス数が 48 枚，TE が 30 ミリ秒，フリップアングルが  $90^\circ$  である。また，撮像法は 64ch ヘッドネックコイルを使用したマルチバンド 2 次元 EPI 撮像法，TR は 1000 ミリ秒とする。

## 4.1 提案手法 1

### 4.1.2 実験デザイン

#### タッピングタスク

被験者には、目を閉じた状態で左手 (利き手ではない手) の親指と人差し指、親指と中指といったように、親指とそれ以外の指を順番にくっつけて離すを早く正確に行うタッピング運動 (タッピング) と何もしない状態 (レスト) を行ってもらおう。

本研究では脳活動値の時系列性に着目するため、1タスクの時間を長めにとる。そのため、1試行あたりタッピングを 300 秒、レストを 300 秒間という独自の実験デザインを用いる (図 4.1)。各タスクの開始時には、被験者に口頭で指示を出す。この実験デザインを、被験者 1 人に対し 1 試行行う。




図 4.1 実験デザイン：タッピングタスク

#### ジャンケンタスク

被験者には、目を閉じた状態で左手 (利き手ではない手) でジャンケンのグー、チョキ、パーの形を作る、力を抜くを早く繰り返すジャンケン模倣 (グー、チョキ、パー) と何もしない状態 (レスト) を行ってもらおう。

本タスクもタッピングタスクと同様に 1タスクの時間を長めにとるため、レストを 30 秒、グーを 300 秒、チョキを 300 秒、パーを 300 秒、レストを 30 秒という独自の実験デザインを用いる (図 4.2)。各タスクの開始時には、被験者に口頭で指示を出す。この実験デザイン

## 4.1 提案手法 1

を、被験者 1 人に対し 1 試行行う。




図 4.2 実験デザイン：ジャンケンタスク

### 4.1.3 SPM における解析のための画像変換

fMRI 装置で得られる fMRI データは DICOM 形式で保存されるため、SPM での解析処理を可能にするために NIFTI 形式に変換する。形式変換には、フリーソフトウェアである MRIConvert を使用する [23].

### 4.1.4 前処理

前処理では、まず各タスクの最初と最後の 2 スキャン分のデータはノイズを含むため除去しておく。次に、SPM を用いて以下の順番で各処理を行う [13].

#### 1. Realignment : fMRI データの動きの補正

1 スキャン目の fMRI データにそれ以降の fMRI データの位置を合わせることで、計測中の胎動や心拍による頭部の動きに伴う fMRI データの変動を補正する。

#### 2. Normalization : fMRI データの標準脳への変換

被験者によって脳の形状、大きさが異なるため、それぞれの脳を標準化する。標準化するには、Realignment 処理で作成された平均画像を SPM で用意されている MNI(Montreal Neurological Institute) 標準脳へ変換する際の変換パラメータを算出する。そして、このパラメータを元に全ての Realignment 処理済みの fMRI データを MNI 標準脳に合わせることで標準化する。

#### 3. Smoothing : Normalization 処理済みの fMRI データの空間的平滑化

## 4.1 提案手法 1

Realignment 処理や Normalization 処理によって生じた fMRI データの様々なノイズの除去や、個人間の脳構造の違いを緩和する。

### 4.1.5 ボクセル選択による脳活動値取得

以下の 2 つの方法を用いて fMRI データから特定ボクセルの脳活動値を取得する。

#### Active Voxel : タスク時に賦活しているボクセル

SPM を用いて、各被験者ごとに個人解析を行うことで、各タスク時に有意な活動を示すボクセル (賦活ボクセル) を特定する。個人解析の流れは、まず、デザインマトリクス (Design Matrix) を作成し、前処理が完了した fMRI データを GLM (General Linear Model : 一般線形モデル) に組み込む。この GLM は、実験における複数条件の説明変数 ( $x_i(t)$ ) に重み (偏回帰変数  $\beta_i$ ) を掛け算した項の総和と、この総和だけでは説明できないノイズ項 ( $e(t)$ ) や定数項との和でモデル化されたものである。下式 (4.1) は、特に変数が正規化されている場合の表現である。本実験における説明変数は、タッピングタスクはレスト条件、タッピング条件の 2 つ、ジャンケンタスクはレスト条件、グー条件、チョキ条件、パー条件の 4 つとなる [13]。

$$y(t) = \beta_1 \cdot x_1(t) + \beta_2 \cdot x_2(t) + \cdots \beta_n \cdot x_n(t) + e(t) \quad (4.1)$$

次に、統計的仮説検定を行い、タッピングタスクはタッピング時、ジャンケンタスクはグー、チョキ、パーのときの賦活ボクセルを特定する。このときの有意水準は特定されたボクセル数が 7 ボクセル程度になるように設定したため、各被験者によって異なる (表 4.2)。各条件時の賦活ボクセルを特定後、 $t$  値の高い上位 7 ボクセルの脳活動値を抽出する。



## 4.1 提案手法 1

表 4.2 有意水準 (uncorrected)

	タッピングタスク	ジャンケンタスク
被験者 A	$p < 0.0001$	$p < 0.000001$
被験者 B	$p < 0.001$	$p < 0.000001$
被験者 C	$p < 0.000001$	$p < 0.00001$

### Motor Voxel：タスクとの関連が予測されるボクセル

SPM を用いて、タスクとの関連が予測されるボクセルの脳活動値を抽出する。

まず、Active Voxel と同様に個人解析を行うが、有意水準  $p < 1$  と設定して統計的仮説検定を行う。SPM では賦活ボクセルでなければ脳活動値を抽出できないため、 $p < 1$  とすることで全ボクセルを賦活ボクセルとして表示されるようにする。

そして、タッピングタスクやジャンケンタスクとの関連が予測されるブロードマンエリア 1~4 の 7 ボクセルの脳活動値を抽出する。これらのボクセルを指定するには座標が必要となり、脳における座標には Talairach 座標系と MNI 座標系が存在する。

Talairach 座標は、脳の深部にある前交連と後交連に向かう線を  $y$  軸、前交連から  $y$  軸と垂直に正中線方向へ伸ばした線を  $z$  軸、 $yz$  軸平面の原点を通る線  $x$  軸と定義している。これを用いることで、様々な形状や大きさを持った被験者の個人脳を同じ Talairach 空間へ整理することによる標準化や、全ての脳の位置を 3 つの座標値として表すことを可能としている。また、Talairach 標準脳は 20 世紀初頭に作成されたブロードマン脳地図との対応が充実しているため、Talairach 標準脳に fMRI データを標準化することでブロードマンエリアと座標の相互変換が可能となる。ただし、60 歳代に亡くなった女性の萎縮しつつある脳に基づいて作られていることから、正確性に欠けるとの欠点も持っていた。

そこで、新しく開発されたのが MNI 座標系である。MNI 座標系は、Talairach 座標系を用いて 100 人以上の脳を平均して作成された。そのため、Talairach 座標の軸と大まかな

## 4.1 提案手法 1

比率は大体一致しているが、側頭葉で大きさの違いがあるなど構造上での違いがある。

SPM では、Normalization 処理時に fMRI データを MNI 標準脳に合わせているため、MNI 座標系が用いられている。そのため、ブロードマンエリアから抽出したいボクセルの MNI 座標を得る必要があるが、ブロードマンエリアからは Talairach 座標にしか変換できないため、ブロードマンエリア、Talairach 座標、MNI 座標の順で変換する必要がある。ブロードマンエリアから Talairach 座標への変換には、各ブロードマンエリアとそのエリア内のボクセルの Talairach 座標情報を有する Brede データベースを使用する [25]。本解析で着目したブロードマンエリア 1~4 にはいくつものボクセルが含まれているため、各エリアごとの平均座標に位置するボクセルを選択する。Talairach 座標から MNI 座標への変換には、MATLAB 関数 tal2mni.m を用いる。以上の手順で得られるそれぞれの座標を表 4.3 に示す (MNI 座標値が奇数のものは SPM 入力時に偶数に変換されてしまう)。

表 4.3 Motor Voxel の座標一覧

ブロードマンエリア	部位名	Talairach 座標	MNI 座標	SPM 入力座標
1	一次体性感覚	(37, -27, 48)	(37, -30, 51)	(36, -30, 52)
2	一次体性感覚 (左脳)	(-33, -35, 63)	(-33, -39, 66)	(-34, -38, 66)
3	一次体性感覚 (右脳)	(34, -26, 46)	(34, -29, 49)	(34, -28, 50)
4	一次体性感覚 (左脳)	(-49, -19, 26)	(-49, -21, 27)	(-50, -20, 28)
5	一次体性感覚 (右脳)	(28, -24, 44)	(28, -27, 46)	(28, -26, 46)
6	一次運動 (左脳)	(-34, -14, 50)	(-34, -18, 53)	(-34, -18, 54)
7	一次運動 (右脳)	(37, -13, 45)	(37, -17, 51)	(36, -16, 52)

## 4.1 提案手法 1

### 4.1.6 特徴抽出

各ボクセルは実験デザインに従って時系列順に記録された Z 値を脳活動値として有している (図 4.3). 本解析では, この時系列活動値から以下の 2 種類の特徴ベクトルを生成する.

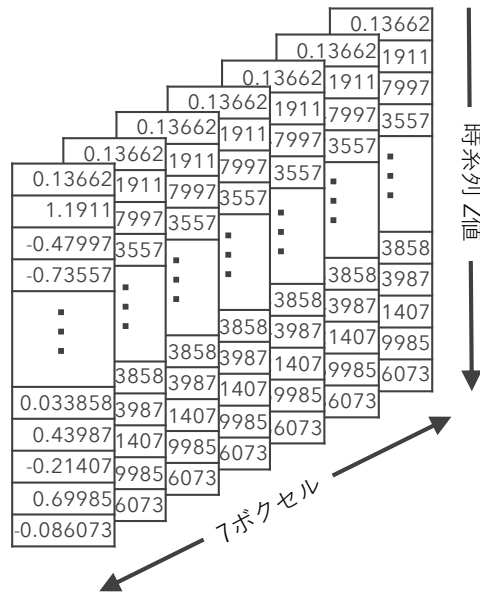
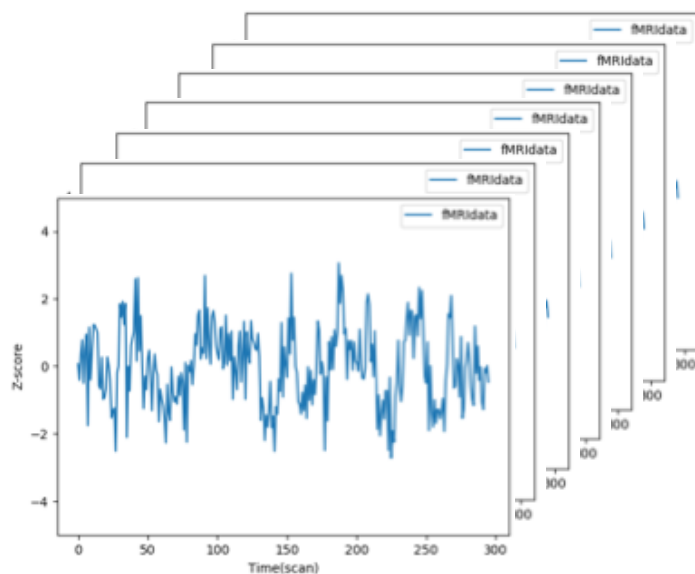


図 4.3 抽出された脳活動値

### Time Series Data

各ボクセルが有する時系列脳活動値をタスクごとに分別し, それぞれの Z 値の組を取得する. これを, 個々ボクセルの脳活動値の時系列パターンを特徴とするベクトル “Time Series Data” とする. Time Series Data の次元数は (1 タスクあたりのスキャン数 300) - (除去したスキャン数 4) = 296, データセット数は (使用ボクセル数) × (タスクの種類数) となる (表 4.5).

## 4.1 提案手法 1



特徴ベクトル Time Series Data

図 4.4 各ボクセルごとに 1 タスクから得られる特徴ベクトル：Time Series Data

### TDA Data

Time Series Data に TDA を適用する.

#### 1. 3 次元空間への埋め込み

Time Series Data を 3 次元空間へ埋め込む. 実際に埋め込みで得られる Quasi-attractor を図 4.5 に示す.

#### 2. TDA によるベクトル化

Quasi-attractor に TDA を適用することでバーコードを取得し, ベッチ数を取得する. これを, 個々ボクセルの脳活動値の時系列パターンに TDA を適用して得たベッチ数を特徴とするベクトル “TDA Data” とする. この際,  $n$  とベッチ数を取得する穴を表 4.4 のように設定することで, 4 種類の TDA Data を生成する. 実際に TDA 適用することで得られるバーコードと TDA Data を図 4.6 に示す. TDA Data の次元数は  $n \times$  ベッチ数を取得する穴の種類数, データセット数はボクセル数  $\times$  タスクの種類数となる (表

4.1 提案手法 1

4.5).




図 4.5 Quasi-attractor

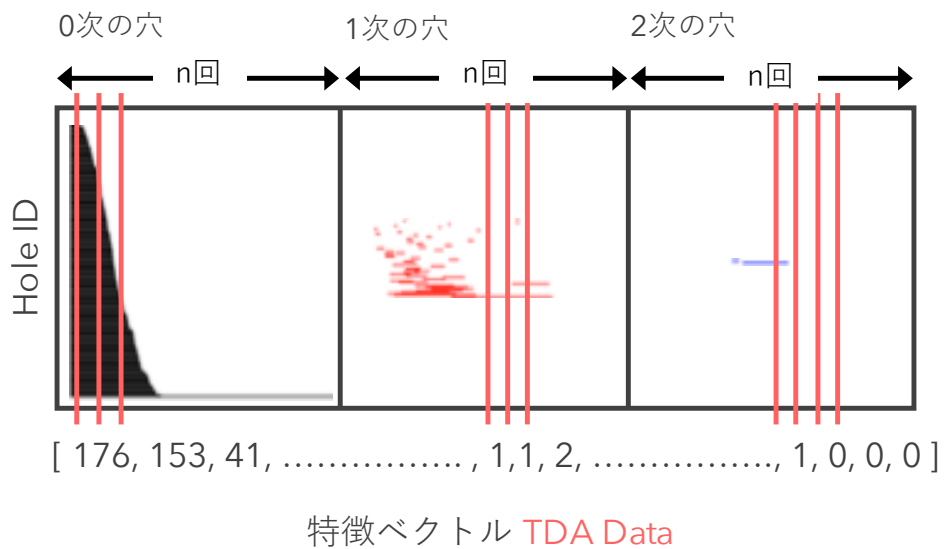


図 4.6 バーコードから得られる特徴ベクトル：TDA Data

## 4.1 提案手法 1

表 4.4 生成する TDA Data 一覧

n	0 次の穴	1 次の穴	2 次の穴	特徴ベクトル名
100	○	○	×	TDA Data(01dim100)
100	○	○	○	TDA Data(012dim100)
300	○	○	×	TDA Data(01dim300)
300	○	○	○	TDA Data(012dim300)

表 4.5 生成した特徴ベクトル情報

特徴ベクトル名	次元数	データセット数
Time Series Data	296	14
TDA Data(01dim100)	200	14
TDA Data(012dim100)	300	14
TDA Data(01dim300)	600	14
TDA Data(012dim300)	900	14

### 4.1.7 機械学習・精度評価

機械学習には、サポートベクターマシンと 1dCNN を用いる。精度評価には、交差検証法を用いる。

### 4.1.8 機械学習アルゴリズム：SVM

SVM の実装には Python3.6.1 のライブラリ scikit-learn を使用する。scikit-learn にはいくつかの SVM の実装法があるが、本解析では svm.SVC(Support Vector Classifier) を用いる。この時、カーネル関数は線形カーネル、誤分類をどの程度許容するかを決めるコストパラメータ  $C$  には 1 を設定する。

## 4.1 提案手法 1

### 4.1.9 機械学習アルゴリズム：1dCNN

1dCNN の実装には Python3.6.1 のライブラリ keras を使用する。この時、各種パラメータは Umeda ら [21] らの研究において、脳波解析時に用いられた値を設定する。

### 4.1.10 精度評価

交差検証法は、データセット数が少ない時に用いられる精度評価手法である。手順としては、まずデータセットを  $k$  グループに分割し、1 グループをテストデータ、残り  $k - 1$  グループを教師データとして推定精度を求める。これを  $k$  回繰り返し、得られた  $k$  回分の推定精度の平均を検証対象の推定精度とする。

分割数  $k$  がデータセット数より少ない場合は  $k$ -fold 交差検証法、 $k$  がデータセット数と等しい場合は leave-one-out 交差検証法となる。本提案手法の精度評価では、データセット数が多くないため、leave-one-out 交差検証法を用いる (図 4.7)。

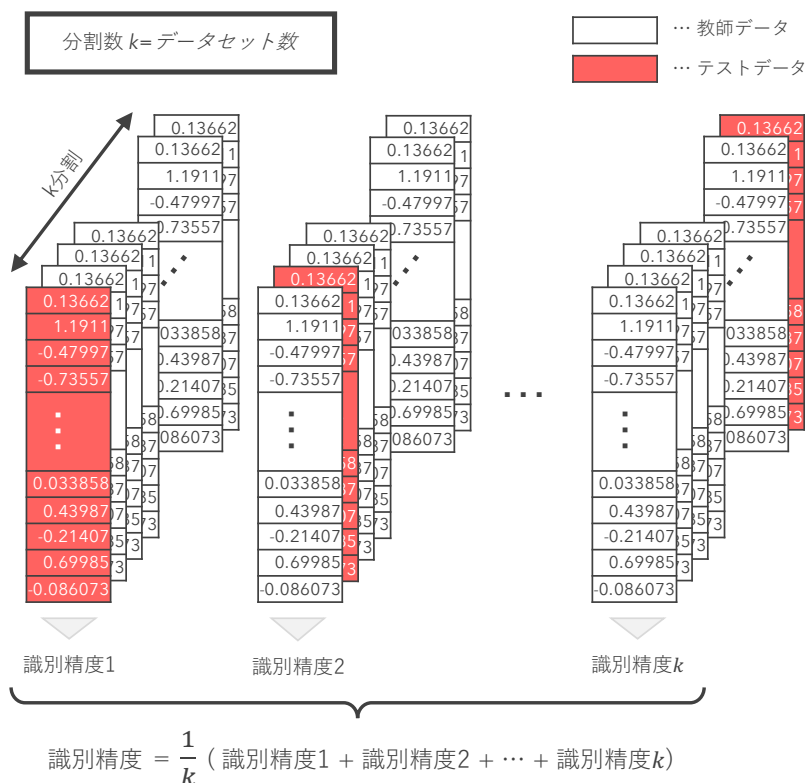


図 4.7 leave-one-out 交差検証法

## 4.2 提案手法 2

### 4.2 提案手法 2

#### 4.2.1 実験装置

脳活動計測には MRI 装置を用いる。MRI 装置として、高知工科大学が保有する SIEMENS 社の MAGNETOM Prisma(3T) を使用する。撮像パラメータは、1 ボクセルあたりのサイズが  $2.0 \times 2.0 \times 2.2\text{mm}$ 、スライス数が 48 枚、TE が 30 ミリ秒、フリップ角度が  $90^\circ$  である。また、撮像法は 64ch ヘッドネックコイルを使用したマルチバンド 2 次元 EPI 撮像法、TR は 1000 ミリ秒とする。

視覚刺激動画呈示には、プロジェクターと fMRI 装置内のスクリーンを使用する。このスクリーンに、マイクロソフト社のプレゼンテーションソフトウェア Microsoft Power Point で視覚刺激動画を映し出す。このとき、実験室は照明を点灯せず暗室とする。

また、眠気防止用に判定などに使用されるボタンを用いる。

#### 4.2.2 実験デザイン

##### タッピングタスク

提案手法 1 の実験で計測したデータを使用する。

##### ジャンケンタスク

提案手法 1 の実験で計測したデータを使用する。

##### 斜線動画順序呈示タスク

被験者には、図 4.9 のような注視点ありの黒の背景画像 (レスト)、斜め 45 度線の動画 (45 度線)、斜め 135 度線の動画 (135 度線) を呈示する。45 度線と 135 度線はそれぞれ図 4.10、図 4.11 を右方向へ 1 秒間で 0.5 画面の速さでスライドさせることで動画を作成する。



## 4.2 提案手法 2

本研究では脳活動値の時系列性に着目するため、1タスクの時間を長めに取る。ただし、運動タスク実施時に、1タスクあたりの時間が長すぎたため疲れや眠気などの問題が生じた。本タスクでは、1タスクごとの時間を短くし、1試行あたりレストを10秒、45度線を90秒、レストを10秒、135度線を90秒、レストを10秒の順で提示する(図4.8)。レストは、脳が安静な状態で実験に集中することができるように入れている。また、眠気を防止するため、被験者にタスクの切り替わり時にはボタンを押すよう指示する。この実験デザインを、被験者1人に対し4試行行う。




図 4.8 実験デザイン：斜線動画提示タスク 1




図 4.9 レスト画像




図 4.10 45度の斜線

図 4.11 135度の斜線

### 斜線動画ランダム提示タスク

本タスクは、45度線の動画と135度線の動画の提示順を試行ごとに変更する。そのため、図4.8のようにレストを10秒、45度線を90秒、レストを10秒、135度線を90秒、レストを10秒の順で提示する実験デザインと、図4.12のようにレストを10秒、135度線を90秒、レストを10秒、45度線を90秒、レストを10秒の順で提示する実験デザインの2種類を用意する。これらを被験者1人に対し、4試行行うが、1試行目、3試行目、4試行目は

## 4.2 提案手法 2

斜線動画呈示タスク 2 の実験デザイン, 2 試行めは斜線動画呈示タスク 1 の実験デザインとする.




図 4.12 実験デザイン：斜線動画呈示タスク 2

### 4.2.3 SPM における解析のための画像変換

fMRI 装置で得られる fMRI データは DICOM 形式で保存されるため, SPM での解析処理を可能にするために NIFTI 形式に変換する. 形式変換には, フリーソフトウェアである MRIConvert を使用する [23].

### 4.2.4 前処理

前処理では, まず各タスクの最初と最後の数スキャンのデータはノイズを含むため除去しておく. タッピングタスク, ジャンケンタスクでは 2 スキャン分, 斜線動画順序呈示タスク, 斜線動画ランダム呈示タスクでは 1 スキャン分を除去する. 次に, SPM を用いて以下の順番で各処理を行う [13].

### 4.2.5 ボクセル選択による脳活動値取得

以下の方法を用いて, 大脳 (ブロードマンエリア, 大脳基底核, 大脳辺縁系) にあたるボクセルの脳活動値を取得する.

まず, SPM を用いて, 1 スキャンあたり  $x$  軸,  $y$  軸,  $z$  軸の座標情報を持つ 3 次元 fMRI データを, 時系列順に全スキャン分並べることで時間情報を追加した 4 次元 fMRI データへ変換する.

## 4.2 提案手法 2

次に, WFU pickAtlas[26] を用いて, 人の脳においてブロードマンエリアに含まれる範囲のみを限定するマスク画像を作成する. この際, 作成したマスク画像を SPM の Normalization 処理で標準脳のサイズに変換し, Reslice 処理で各被験者ごとの fMRI データにリスライスしておく.

最後に, Python3.6.1 のライブラリ PyMVPA を用いて, 4次元 fMRI データにマスク画像を適用することで, 大脳にあたるボクセルごとの脳活動値を抽出する.

### 4.2.6 特徴抽出

提案手法 1 と同様に, 各ボクセルは実験デザインに従って時系列順に記録された Z 値を脳活動値として有している. 各ボクセルが有する時系列脳活動値をタスクと試行ごとに分別し, それぞれの Z 値の組を  $X = \{x_t\}_{t=1}^T$  とし,  $T$  は 1 組のデータ数を表している. タッピングタスクとジャンケンタスクの  $T$  は, (1 タスクあたりのスキャン数 300) - (除去したスキャン数 4) = 296, 斜線動画順序呈示タスクと斜線動画ランダム呈示タスクの  $T$  は, (1 タスクあたりのスキャン数 90) - (除去したスキャン数 2) = 88 となる.

そして, 分別された時系列脳活動値から, 時系列幅  $N$ (=10, 15, 30, 45) 秒分の Z 値を切り取る. これを, 単一ボクセルにおける脳活動値の時系列パターンを特徴としたベクトルとする. この際, 時系列パターンの始点・終点(位相(phase))の変化によるパターンの変化も学習対象とするよう, 図 4.13 に示すようにある時刻  $t$  における時系列特徴ベクトル  $\mathbf{f}_t$  を

$$\mathbf{f}_t = [x_t, x_{t+1}, \dots, x_{t+N}]^T \quad (4.2)$$

として生成する.

4.2 提案手法 2

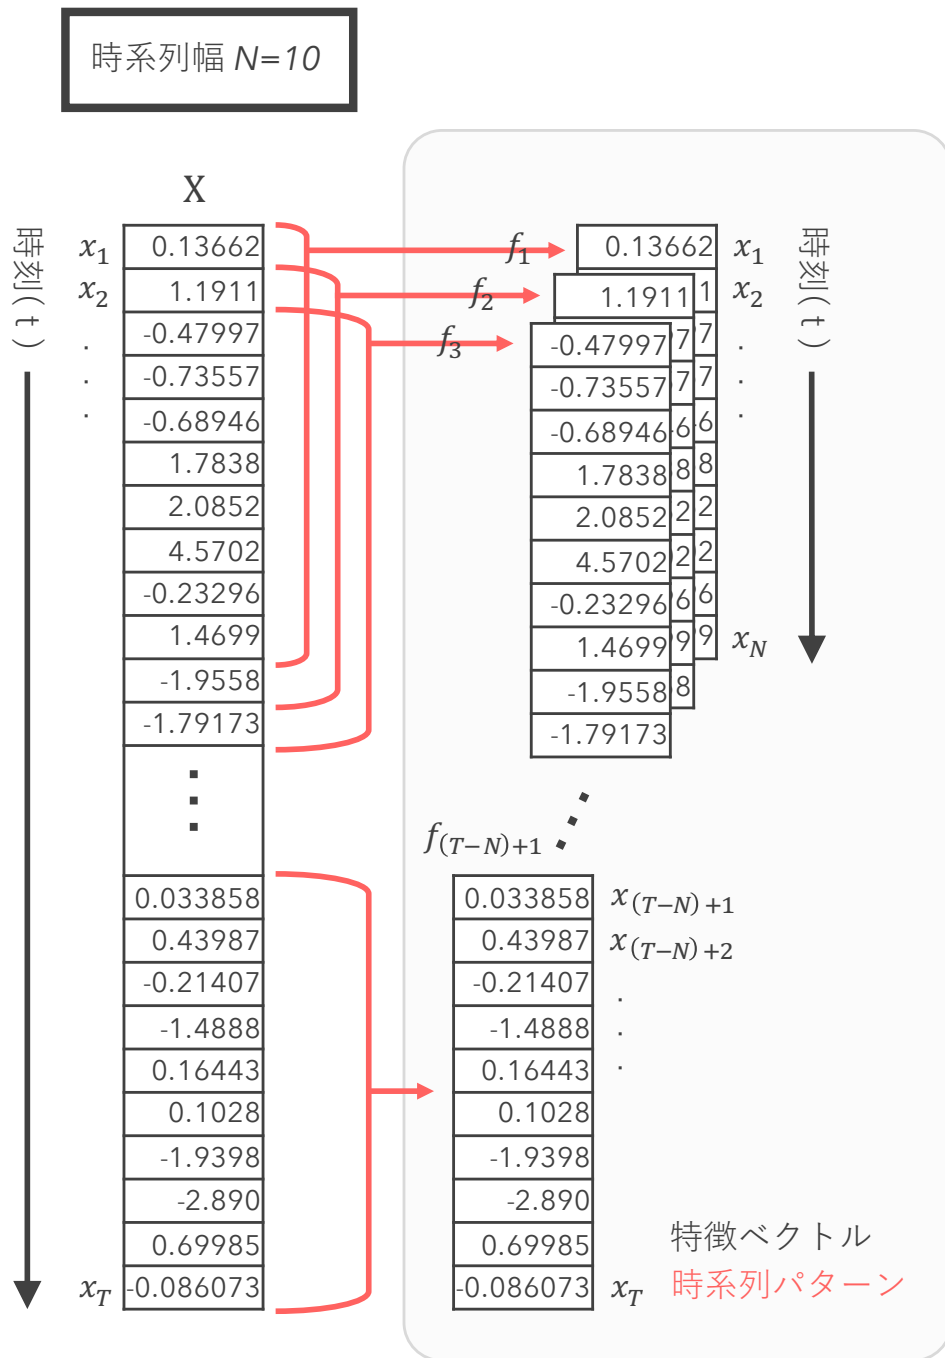


図 4.13 1 時系列脳活動値から得られる特徴ベクトル：単一ボクセルにおける時系列パターン

## 4.2 提案手法 2

### 4.2.7 機械学習・精度評価

機械学習には、SVM を用いる。精度評価には、交差検証法を用いる。推定精度は選択した各ボクセルごとで算出する。

### 4.2.8 機械学習アルゴリズム：SVM

SVM の実装には Python3.6.1 のライブラリ scikit-learn を使用する。scikit-learn にはいくつかの SVM の実装法があるが、本解析では svm.SVC(Support Vector Classifier) を用いる。このとき、カーネル関数は線形カーネル、誤分類をどの程度許容するかを決めるコストパラメータ  $C$  には 1 を設定する。

### 4.2.9 精度評価

本提案手法の精度評価では、データセット数が提案手法 1 と比較して多いため、分割数  $k$  を 10 に設定した 10-fold 交差検証法を用いる。ただし、生成した特徴ベクトルは 1 秒ずつらしたものであるため、最大で時系列幅  $N - 1$  秒分の Z 値が重複することになる。そのため、図 4.14 に示すようにデータセットを 10 グループに分割し、1 グループをテストデータ、残りのデータセットのうちテストデータとして選ばれた特徴ベクトルと Z 値の重複のない特徴ベクトルを教師データとする。

## 4.2 提案手法 2

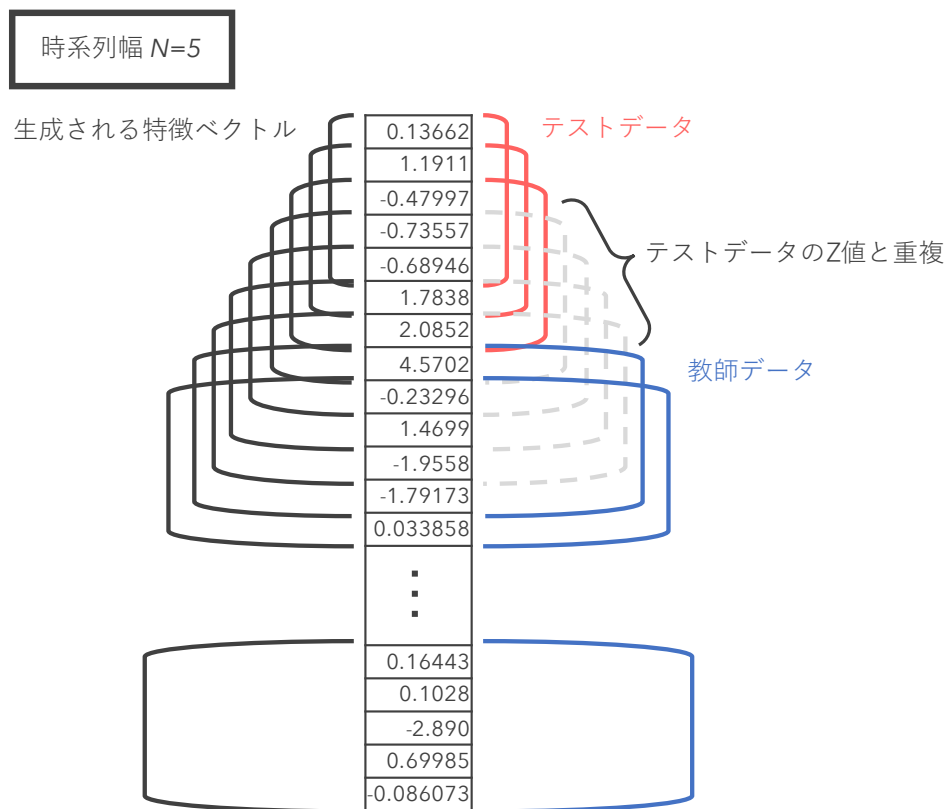


図 4.14 テストデータと教師データの Z 値の重複を考慮した交差検証法

## 第 5 章

# 結果および考察

本章では，実験および解析の結果を示し，提案手法の有用性，考察を述べる..

### 5.1 提案手法 1

Active Voxel と Motor Voxel のボクセル選択方法，Time Series Data と TDA Data の特徴ベクトル生成方法，SVM と 1dCNN の機械学習アルゴリズムのそれぞれを用いて得られた各タスクの推定精度を示す.

#### 5.1.1 タッピングタスク

全被験者の推定精度の平均を図 5.1 に示す. また，SVM を用いた場合の推定精度を表 5.1, 1dCNN を用いた場合の推定精度を表 5.2 に示す.

SVM を用いた場合は，全ての被験者において Time Series Data の推定精度が最も高い結果となった. 1dCNN を用いた場合は，被験者 A, 被験者 B は Time Series Data, 被験者 C は Active Voxel においては Time Series Data, Motor Voxel においては Time Series Data と TDA Data(012dim100) の推定精度が最も高い結果となった.

図 5.1 からは，Time Series Data の推定精度が全体的に高い傾向があることに加え，ボクセル選択法を比較した場合には全体的に Motor Voxel の方が高い推定精度であることが分かる. このことから，Time Series Data の有用性だけでなく，従来のボクセル選択法では着目されないボクセルにも人の状態推定に有効な特徴があることが示唆されたと考える.

TDA Data に関しては，Active Voxel と 1dCNN を用いた場合の TDA Data の推定精度

## 5.1 提案手法 1

はチャンスレベル以下であった。他の TDA Data の推定精度においてもチャンスレベルを超えたものの、Time Series Data より低い結果となった。

TDA Data の推定精度が低い要因として 3 つ考えられる。

1 つは、3 次元空間への埋め込み時の  $\tau$  が適切で無いため、時系列特徴を捉えきれていないというものである。本研究では、 $\tau$  には「自己相関関数が最初に極小値をとる時刻」を設定しているが、 $\tau$  の決定法は他にも存在する。そのため、最適な  $\tau$  の探索・決定により推定精度の向上は可能であると考えられる。

2 つは、1dCNN を適用時に脳波解析時に用いられたハイパーパラメータ使用したため、fMRI データの解析には適切ではなかったというものである。脳波と fMRI では計測時の時間分解能や空間分解能などの違いから、得られるデータ特性が異なる。そのため、fMRI データの特性を考慮したパラメータを設定することで、推定精度の向上は可能と考える。

3 つは、時系列パターンの特徴ではなく、何もしていない状態のレストとタッピング (何かしている状態) の脳活動値の絶対値の差を特徴として捉えているというものである。そのため、脳活動値をそのまま特徴とする Time Series Data では推定精度が高く、時系列特徴を捉えるために 3 次元空間への埋め込みや TDA 適用によるベクトル化を行う TDA Data の推定精度が低くなったということが考えられる。



## 5.1 提案手法 1




図 5.1 提案手法 1 : 全被験者のタッピングタスクの推定精度の平均 (%)

表 5.1 提案手法 1 : SVM を用いた場合のタッピングタスクの推定精度 (%)

使用ボクセル	被験者 A		被験者 B		被験者 C	
	Active	Motor	Active	Motor	Active	Motor
Time Series Data	<b>92.9</b>	<b>100.0</b>	<b>100.0</b>	<b>100.0</b>	<b>100.0</b>	<b>100.0</b>
TDA Data(01dim100)	57.1	85.7	50.0	57.1	71.4	64.3
TDA Data(012dim100)	57.1	85.7	50.0	57.1	71.4	50.0
TDA Data(01dim300)	50.0	85.7	50.0	42.9	71.4	57.1
TDA Data(012dim100)	50.0	85.7	50.0	57.1	71.4	57.1

表 5.2 提案手法 1 : 1dCNN を用いた場合のタッピングタスクの推定精度の平均 (%)

使用ボクセル	被験者 A		被験者 B		被験者 C	
	Active	Motor	Active	Motor	Active	Motor
Time Series Data	<b>92.9</b>	<b>100.0</b>	<b>64.3</b>	<b>85.7</b>	<b>92.9</b>	<b>85.7</b>
TDA Data(01dim100)	35.7	71.4	21.4	64.3	57.1	57.1
TDA Data(012dim100)	28.6	85.7	28.6	57.1	64.3	42.9
TDA Data(01dim300)	71.4	78.6	28.6	28.6	50.0	71.4
TDA Data(012dim100)	35.7	71.4	57.1	50.0	57.1	<b>85.7</b>

## 5.1 提案手法 1

### 5.1.2 ジャンケンタスク

全被験者の推定精度の平均を図 5.2 に示す. SVM を用いた場合の推定精度を表 5.3, 1dCNN を用いた場合の推定精度を表 5.4 に示す.

SVM, 1dCNN のいずれを用いた場合でも, 全ての被験者において Time Series Data の推定精度が最も高い結果となった.

図 5.2 からは, Time Series Data の推定精度が全体的に高い傾向があることに加え, ボクセル選択法を比較した場合には全体的に Motor Voxel の方が高い推定精度であることが分かる. このことから, Time Series Data の有用性だけでなく, 従来のボクセル選択法では着目されないボクセルにも人の状態推定に有効な特徴があることが示唆されたと考える.

TDA Data に関してはチャンスレベル以下のものが多く, Time Series Data より低い結果となった.

タッピングタスクと比較すると, Time Series Data の推定精度に大きな差はなかった. このことから, 何もしていない状態を含まない手をグー, チョキ, パーの形にする 3 状態のいずれであるか推定しているジャンケンタスクでも高い精度が得られたため, 脳活動値の絶対値の差を特徴として捉えているという可能性は低いと考える.




図 5.2 提案手法 1 : 全被験者のジャンケンタスクの推定精度の平均 (%)

## 5.1 提案手法 1

表 5.3 提案手法 1 : SVM を用いた場合のジャンケンタスクの推定精度 (%)

使用ボクセル	被験者 A		被験者 B		被験者 C	
	Active	Motor	Active	Motor	Active	Motor
Time Series Data	<b>95.2</b>	<b>95.2</b>	<b>100.0</b>	<b>100.0</b>	<b>95.2</b>	<b>100.0</b>
TDA Data(01dim100)	33.3	47.6	19.0	19.0	28.6	23.8
TDA Data(012dim100)	33.3	47.6	19.0	14.3	28.6	23.8
TDA Data(01dim300)	38.1	52.4	23.8	19.0	23.8	28.6
TDA Data(012dim100)	38.1	52.4	23.8	14.3	23.8	28.6

表 5.4 提案手法 1 : 1dCNN を用いた場合のジャンケンタスクの推定精度 (%)

使用ボクセル	被験者 A		被験者 B		被験者 C	
	Active	Motor	Active	Motor	Active	Motor
Time Series Data	<b>85.7</b>	<b>95.2</b>	<b>100.0</b>	<b>90.5</b>	<b>85.7</b>	<b>90.5</b>
TDA Data(01dim100)	33.3	28.6	23.8	28.6	23.8	33.3
TDA Data(012dim100)	28.6	28.6	19.0	23.8	23.8	28.6
TDA Data(01dim300)	23.8	47.6	28.6	9.5	33.3	47.6
TDA Data(012dim100)	33.3	57.1	19.0	23.8	23.8	42.9

### 5.2 提案手法 2

従来手法として単変量解析と多変量解析，提案手法による解析各タスクの推定精度比較を示す。

提案手法と単変量解析では，大脳における全ボクセルごとに推定精度を算出し，最も高かった推定精度を示す。多変量解析では，各ボクセルの Z 値とタスクの間の相関が高いボクセルを  $K$  個選択し，算出した推定精度を示す。 $K$  には，BDTB で既定の最大ボクセル数として設定されている 200 と，提案手法の時系列幅  $N$  と同様の 10, 15, 30, 45 を設定した。

また，単変量解析と提案手法は高い推定精度を算出したボクセルが含まれる脳部位，多変量解析は相関が高いものとして選択された上位 5 ボクセルが含まれる脳部位を示す。

#### 5.2.1 タッピングタスク

全被験者の推定精度の平均を図 5.3 に示す。また，被験者ごとの推定精度を表 5.5，推定時に選択されたボクセルが含まれる脳部位を表 5.6 に示す。表 5.6 において，運動タスクとの関連が予測される脳部位を太字で示す。

全ての被験者において，提案手法 ( $N=45$ ) の推定精度が高い結果となった。また，従来手法は全ての被験者において単変量解析の推定精度が最も高くなった，従来手法と提案手法を比較すると，被験者 A, B においては全ての提案手法，被験者 C においては  $N=30, 45$  の提案手法の推定精度が高い結果となった。また，全被験者の推定精度を比較すると，被験者 C の提案手法 ( $N=45$ ) の推定精度が 89.8% と最も高く，その推定精度を得られたボクセルが含まれる脳部位は運動タスクとの関連が予測される脳部位では無かった。このことから，提案手法の有用性だけでなく，従来のボクセル選択法では着目されないボクセルにも人の状態推定に有効な特徴があることが示唆されたと考える。

ただし，図 5.3 から，提案手法において  $N$  の違いによる大きな差は無かったことから，時系列パターンが存在するのか，存在するのであればどのような周期で存在するのかは特定できなかった。

## 5.2 提案手法 2

そこで、全体的に高い推定精度が得られた  $N=45$  の提案手法に着目して、時系列パターンの有無の検証を行った。検証では、 $N=45$  の提案手法の推定精度を得られたボクセルが有する脳活動値を 3 次元空間へ埋め込み、時系列パターンがあれば特徴的な軌道に収束するという特性をもとに、目視による主観的評価を行った。埋め込みのときの  $\tau$  は「自己相関関数が最初に極小値をとる値」とする。

タッピングタスクにおいては、全被験者においてレスト、タッピング時ともに特徴的な軌道への収束は見られなかったことから、時系列パターンの特徴の違いによって得られた推定精度であるという可能性が低いと考える。




図 5.3 従来手法と提案手法 2 の全被験者のタッピングタスクの推定精度の平均 (%)

## 5.2 提案手法 2

表 5.5 従来手法と提案手法 2 のタッピングタスクの推定精度比較 (%)

	被験者 A	被験者 B	被験者 C
単変量解析	71.4	75.5	86.6
多変量解析 (K=10)	36.1	36.6	58.0
多変量解析 (K=15)	34.3	41.5	58.2
多変量解析 (K=30)	34.3	48.2	57.7
多変量解析 (K=45)	40.7	50.6	56.8
多変量解析 (K=200)	21.9	34.8	42.5
提案手法 (N=10)	73.9	76.6	77.3
提案手法 (N=15)	74.8	79.8	85.0
提案手法 (N=30)	75.3	84.2	87.2
提案手法 (N=45)	<b>74.9</b>	<b>84.6</b>	<b>89.8</b>

表 5.6 タッピングタスクの推定時に選択されたボクセルが含まれる脳部位

	被験者 A	被験者 B	被験者 C
単変量解析	ブロードマンエリア 18	ブロードマンエリア 7	ブロードマンエリア 6
多変量解析	ブロードマンエリア <b>5</b>	ブロードマンエリア <b>11</b>	ブロードマンエリア 39
	ブロードマンエリア <b>11</b>	ブロードマンエリア 21	ブロードマンエリア <b>11</b>
	ブロードマンエリア <b>5</b>	ブロードマンエリア 21	ブロードマンエリア 39
	ブロードマンエリア <b>5</b>	ブロードマンエリア <b>11</b>	ブロードマンエリア 39
	ブロードマンエリア <b>2</b>	ブロードマンエリア <b>11</b>	ブロードマンエリア 39
提案手法 (N=10)	ブロードマンエリア 19	ブロードマンエリア 19	ブロードマンエリア 18
提案手法 (N=15)	ブロードマンエリア 19	ブロードマンエリア 19	ブロードマンエリア 6
提案手法 (N=30)	尾状核	ブロードマンエリア 31	ブロードマンエリア 6
提案手法 (N=45)	ブロードマンエリア 22	ブロードマンエリア <b>9</b>	ブロードマンエリア 6

## 5.2 提案手法 2

### 5.2.2 ジャンケンタスク

全被験者の推定精度の平均を図 5.4 に示す。また、被験者ごとの推定精度を表 5.7、推定時に選択されたボクセルが含まれる脳部位を表 5.8 に示す。表 5.8 において、運動タスクとの関連が予測される脳部位を太字で示す。

全ての被験者において、提案手法 ( $N=45$ ) の推定精度が高い結果となった。また、従来手法は全ての被験者において単変量解析の推定精度が最も高くなった。従来手法と提案手法を比較すると、被験者 B, C においては全ての提案手法、被験者 A においては  $N=15, 30, 45$  の提案手法の推定精度が高い結果となった。

ただし、図 5.4 から、提案手法において  $N$  の違いによる大きな差は無かった。また、タッピングタスクと同様に、 $N=45$  の提案手法の推定精度を得られたボクセルが有する脳活動値を 3 次元空間へ埋め込むことで時系列特徴の有無の検証を行った。ジャンケンタスクでは、図 5.5、図 5.6 に示すように、被験者 C の手をグー、チョキの形にしている時の脳活動値は特徴的な軌道へ収束した。このことから、安静時以外の脳活動値にも人の状態推定に有効な時系列特徴があることが示唆されたと考える。




図 5.4 従来手法と提案手法 2 の全被験者のジャンケンタスクの推定精度の平均 (%)

## 5.2 提案手法 2

表 5.7 従来手法と提案手法 2 のジャンケンタスクの推定精度比較 (%)

	被験者 A	被験者 B	被験者 C
単変量解析	70.1	83.7	65.6
多変量解析 (K=10)	67.3	46.5	44.8
多変量解析 (K=15)	65.7	49.8	49.3
多変量解析 (K=30)	71.4	59.5	44.9
多変量解析 (K=45)	72.0	60.7	51.1
多変量解析 (K=200)	63.5	63.0	59.6
提案手法 (N=10)	67.3	85.7	70.2
提案手法 (N=15)	71.4	86.8	72.7
提案手法 (N=30)	79.7	91.0	76.3
提案手法 (N=45)	<b>86.6</b>	<b>95.6</b>	<b>77.4</b>

表 5.8 ジャンケンタスクの推定時に選択されたボクセルが含まれる脳部位

	被験者 A	被験者 B	被験者 C
単変量解析	ブロードマンエリア 10	ブロードマンエリア 47	ブロードマンエリア 6
多変量解析	ブロードマンエリア 11	ブロードマンエリア 19	ブロードマンエリア 18
	ブロードマンエリア 11	ブロードマンエリア 19	ブロードマンエリア 18
	ブロードマンエリア 11	ブロードマンエリア 19	ブロードマンエリア 18
	ブロードマンエリア 11	ブロードマンエリア 19	ブロードマンエリア 18
	ブロードマンエリア 11	ブロードマンエリア 20	ブロードマンエリア 18
提案手法 (N=10)	ブロードマンエリア 20	ブロードマンエリア 47	ブロードマンエリア 18
提案手法 (N=15)	ブロードマンエリア 20	ブロードマンエリア 47	ブロードマンエリア 18
提案手法 (N=30)	脳梁	ブロードマンエリア 47	ブロードマンエリア 18
提案手法 (N=45)	脳梁	ブロードマンエリア 47	ブロードマンエリア 6



## 5.2 提案手法 2




図 5.5 被験者 C, ゲーム時の脳活動値： $\tau=1$  で 3 次元空間への埋め込み




図 5.6 被験者 C, チョキ時の脳活動値： $\tau=1$  で 3 次元空間への埋め込み

### 5.2.3 斜線動画順序提示タスク

全被験者の推定精度の平均を図 5.7 に示す。また、被験者ごとの推定精度を表 5.9, 推定時に選択されたボクセルが含まれる脳部位を表 5.10 に示す。表 5.10 において、視覚刺激動画提示タスクとの関連が予測される脳部位を太字で示す。

全ての被験者において、提案手法 ( $N=45$ ) の推定精度が高い結果となった。また、従来手法は全ての被験者において単変量解析の推定精度が最も高くなった、従来手法と提案手法を比較すると、全ての被験者において  $N=15, 30, 45$  の提案手法の推定精度が最も高い結果となった。また、全被験者の推定精度を比較すると、被験者 E の提案手法 ( $N=45$ ) のステイ精度が 93.8% と最も高く、その推定精度が得られたボクセルが含まれる脳部位は運動タスクとの関連が予測される脳部位ではなかった。このことから、提案手法の有用性だけでなく、従来のボクセル選択法では着目されないボクセルにも人の状態推定に有効な特徴が示唆されたと考える。

また、図 5.7 から、提案手法において時系列幅  $N=30, 45$  とした際に高い推定精度が得られたことから、0 から 45 秒または 45 秒以上の間の脳活動値のパターンに特徴があると考えられる。そこで、タッピングタスクと同様に、 $N=45$  の提案手法の推定精度を得られたボ

## 5.2 提案手法 2

クセルが有する脳活動値を 3 次元空間へ埋め込むことで時系列特徴の有無の検証を行った。

斜線動画順序提示タスクでは、図 5.8、図 5.9 に示すように、被験者 E に斜線動画順序提示タスク 4 試行目の脳活動値は特徴的な軌道へ収束した。他の試行、被験者においても、特徴的な軌道へ収束するものも見られたことから、安静時以外の脳活動値にも人の状態推定に有効な時系列特徴があることが示唆されたと考える。




図 5.7 従来手法と提案手法 2 の全被験者の斜線動画順序提示タスクの推定精度の平均 (%)

## 5.2 提案手法 2

表 5.9 従来手法と提案手法 2 の斜線動画順序呈示タスクの推定精度比較 (%)

	被験者 B	被験者 D	被験者 E
単変量解析	64.0	61.9	65.2
多変量解析 (K=10)	48.1	44.0	43.5
多変量解析 (K=15)	58.9	55.2	57.2
多変量解析 (K=30)	49.9	47.5	43.1
多変量解析 (K=45)	47.0	44.6	38.6
多変量解析 (K=200)	51.8	44.0	38.7
提案手法 (N=10)	61.7	66.8	61.8
提案手法 (N=15)	66.1	71.7	67.8
提案手法 (N=30)	76.3	78.6	79.3
提案手法 (N=45)	<b>88.7</b>	<b>92.9</b>	<b>93.8</b>

表 5.10 斜線動画順序呈示タスクの推定時に選択されたボクセルが含まれる脳部位

	被験者 B	被験者 D	被験者 E
単変量解析	ブロードマンエリア 40	ブロードマンエリア <b>19</b>	ブロードマンエリア <b>6</b>
多変量解析	ブロードマンエリア <b>18</b>	ブロードマンエリア 47	ブロードマンエリア <b>18</b>
	ブロードマンエリア <b>18</b>	ブロードマンエリア 47	ブロードマンエリア <b>18</b>
	ブロードマンエリア <b>18</b>	ブロードマンエリア 47	ブロードマンエリア <b>7</b>
	ブロードマンエリア <b>18</b>	ブロードマンエリア 47	ブロードマンエリア <b>18</b>
	ブロードマンエリア <b>18</b>	ブロードマンエリア 47	ブロードマンエリア <b>18</b>
提案手法 (N=10)	ブロードマンエリア 40	ブロードマンエリア <b>19</b>	ブロードマンエリア <b>5</b>
提案手法 (N=15)	不明	ブロードマンエリア <b>19</b>	ブロードマンエリア <b>5</b>
提案手法 (N=30)	ブロードマンエリア <b>6</b>	ブロードマンエリア <b>19</b>	尾状核
提案手法 (N=45)	ブロードマンエリア 11	ブロードマンエリア <b>19</b>	尾状核

## 5.2 提案手法 2




図 5.8 被験者 E, 45 度の斜線動画  
呈示 4 試行目の脳活動値 :  $\tau=1$  で  
3 次元空間への埋め込み




図 5.9 被験者 E, 135 度の斜線動  
画呈示 4 試行目の脳活動値 :  $\tau=1$   
で 3 次元空間への埋め込み

### 5.2.4 斜線動画ランダム呈示タスク

全被験者の推定精度の平均を図 5.10 に示す。また、被験者ごとの推定精度を表 5.11、推定時に選択されたボクセルが含まれる脳部位を表 5.12 に示す。表 5.12 において、視覚刺激動画呈示タスクとの関連が予測される脳部位を太字で示す。

全ての被験者において、提案手法 ( $N=45$ ) の推定精度が高い結果となった。また、従来手法は全ての被験者において単変量解析の推定精度が最も高くなった。従来手法と提案手法を比較すると、被験者 C においては  $N=15, 30, 45$  の提案手法、被験者 D, E においては  $N=30, 45$  の提案手法の推定精度が高い結果となった。また、全被験者の推定精度を比較すると、被験者 D の提案手法 ( $N=45$ ) の推定精度が 96.3% と最も高く、その推定精度が得られたボクセルが含まれる脳部位は運動タスクとの関連が予測される脳部位ではなかった。このことから、提案手法の有用性だけでなく、従来のボクセル選択法では着目されないボクセルにも人の状態推定に有効な特徴が示唆されたと考える。

また、図 5.10 から、提案手法において時系列幅  $N=30, 45$  とした際に高い推定精度が得られたことから、0 から 45 秒または 45 秒以上の間の脳活動値のパターンに特徴があると考えられる。そこで、タッピングタスクと同様に、 $N=45$  の提案手法の推定精度を得られたボ

## 5.2 提案手法 2

クセルが有する脳活動値を 3 次元空間へ埋め込むことで時系列特徴の有無の検証を行った。

斜線動画ランダム呈示タスクでは, 図 5.11, 図 5.12 に示すように, 被験者 E に斜線動画呈示タスク 4 試行目の脳活動値は特徴的な軌道へ収束した。他の試行, 被験者においても, 特徴的な軌道へ収束するものも見られたことから, 安静時以外の脳活動値にも人の状態推定に有効な時系列特徴があることが示唆されたと考える。




図 5.10 従来手法と提案手法 2 の全被験者の斜線動画ランダム呈示タスクの推定精度の平均 (%)

## 5.2 提案手法 2

表 5.11 従来手法と提案手法 2 の斜線動画ランダム呈示タスクの推定精度比較 (%)

	被験者 C	被験者 D	被験者 E
単変量解析	62.8	72.6	61.9
多変量解析 (K=10)	52.9	32.1	49.7
多変量解析 (K=15)	55.9	50.7	51.3
多変量解析 (K=30)	53.0	47.2	48.7
多変量解析 (K=45)	52.0	43.5	48.6
多変量解析 (K=200)	45.0	36.9	41.3
提案手法 (N=10)	61.0	65.8	56.1
提案手法 (N=15)	63.4	71.8	60.8
提案手法 (N=30)	78.5	85.5	75.4
提案手法 (N=45)	<b>91.1</b>	<b>96.3</b>	<b>88.3</b>

表 5.12 斜線動画ランダム呈示タスクの推定時に選択されたボクセルが含まれる脳部位

	被験者 C	被験者 D	被験者 E
単変量解析	ブロードマンエリア <b>7</b>	ブロードマンエリア 22	ブロードマンエリア <b>6</b>
多変量解析	ブロードマンエリア <b>18</b>	ブロードマンエリア <b>17</b>	ブロードマンエリア 40
	ブロードマンエリア <b>18</b>	ブロードマンエリア <b>17</b>	ブロードマンエリア 40
	ブロードマンエリア <b>18</b>	ブロードマンエリア <b>17</b>	ブロードマンエリア 40
	ブロードマンエリア <b>18</b>	ブロードマンエリア <b>17</b>	ブロードマンエリア 40
	ブロードマンエリア <b>18</b>	ブロードマンエリア <b>17</b>	ブロードマンエリア 40
提案手法 (N=10)	不明	ブロードマンエリア 40	ブロードマンエリア <b>37</b>
提案手法 (N=15)	ブロードマンエリア 47	ブロードマンエリア 40	ブロードマンエリア <b>37</b>
提案手法 (N=30)	ブロードマンエリア <b>18</b>	全腹側核	ブロードマンエリア 38
提案手法 (N=45)	ブロードマンエリア 28	ブロードマンエリア 10	脳梁

## 5.2 提案手法 2

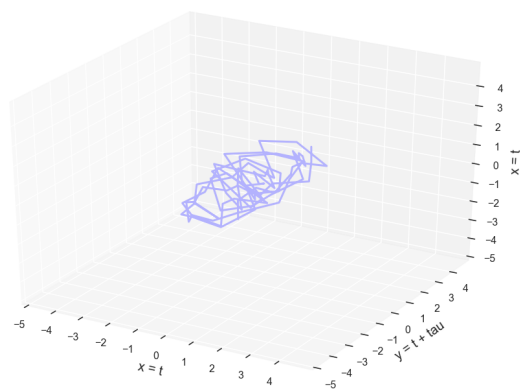


図 5.11 被験者 D, 45 度の斜線動  
画呈示 1 試行目の脳活動値 :  $\tau=1$   
で 3 次元空間への埋め込み




図 5.12 被験者 D, 135 度の斜線  
動画呈示 1 試行目の脳活動値 :  $\tau=5$   
で 3 次元空間への埋め込み

## 第6章

### 結論

本研究では、脳情報デコーディングにおける2つの時系列解析を提案した。

提案手法1では、個々ボクセルの脳活動値の時系列パターンを特徴としたものと、これにTDAを適用して得られたベッチ数を特徴とした時系列解析を提案した。有用性の検証のため、タッピングタスクとジャンケンタスクの2つの運動内容の推定を行った。タッピングタスクでは、指のタッピング時と安静時のfMRIデータを提案手法で解析を行い、どちらの状態であるかを推定した。ジャンケンタスクでは、手の形がジャンケンのグーの形するとき、チョキの形するとき、パーの形ときのfMRIデータを提案手法で解析を行い、どの状態であるかを推定した。

個々ボクセルの脳活動値の時系列パターンを特徴とした時系列解析では、タッピングタスク、ジャンケンタスクともに全被験者の推定精度の平均が約80%以上であったことから、人の状態推定に有効な手法であることを示した。

TDAを適用して得られたベッチ数を特徴とした時系列解析では、タッピングタスク、ジャンケンタスクともに低い推定精度であった。これは、TDA適用時のパラメータに脳波データ解析時に用いられた値を設定したこと、または、運動タスク時の脳活動値の時系列パターンに特徴がないということが原因として考えられる。前者の場合、fMRIデータに適したパラメータを探索・設定することで、より高い推定精度が得られると考える。後者の場合、それぞれのボクセルが有する脳活動値には同様の特徴が存在しているが、これは時系列パターンの特徴であるのか、別の特徴であるのかより詳細な検証が必要である。

提案手法2では、単一ボクセルにおける脳活動値の時系列パターンを特徴とした時系列解析を提案した。有用性の検証のため、提案手法1の有用性の検証時と同様にタッピングタス



クとジャンケンタスクの2つの運動内容の推定に加え、視覚刺激動画呈示タスクを行い、人の見ている内容の推定を行った。視覚刺激動画呈示タスクでは、45度の斜線動画と135度の斜線動画を被験者に呈示した時のfMRIデータの解析を行い、どちらを見ているかを推定した。解析では、提案手法である単一ボクセルにおける $N(=10, 15, 30, 45)$ 秒分の脳活動値の時系列パターンを特徴とした時系列解析に加え、従来手法である単変量解析(1つのボクセル値のみを用いるもの)、多変量解析(1スキャン内の複数のボクセル値の組を用いるもの)を行った。

提案手法と従来手法の解析結果を比較し、全てのタスク、被験者において提案手法( $N=45$ )の推定精度が最も高い結果となったことから、人の状態推定に有効な手法であることを示せたと考える。

また、最も高い推定精度が得られたボクセルにおいて、時系列パターンの有無の検証として3次元空間への埋め込みを行った。視覚刺激動画呈示タスクにおいては、複数被験者において埋め込んだ脳活動値は特徴的な軌道へ収束していることが分かった。運動タスクにおいては、1被験者においては埋め込んだ脳活動地は特徴的な軌道へ収束していることが分かった。このことから、安静時以外の脳活動値にも、人の状態推定に有効な時系列特徴があることが可能性を示した。

ただし、単変量解析や多変量解析などの従来手法はブロックデザインと呼ばれる2つ以上のタスクと何もしないレストを数10秒の長さで交互に配置する実験デザインで得られた脳活動の解析に有効であるとされており、本研究では提案手法と相性が良いと考えられる独自の実験デザインで得られた脳活動を従来手法でも解析を行い、提案手法との比較をしている。そのため、タスクは共通として、従来手法ではブロックデザインを用いた実験で得られた脳活動を解析、提案手法では独自の実験デザインを用いた実験で得られた脳活動を解析することで、より正確な比較・有用性の検証が必要である。

今後検証すべき事柄として、統計検定における多重比較の問題が挙げられる。本研究では、機械学習を用い交差検証法による評価を行っているが、ボクセルの数、その組み合わせの数は膨大であり、偶然による本研究結果の精度の達成も考えらる。人為的にタスクと関連

のない脳活動データによる検証なども今後は必要であると考える。

将来の展望として、提案手法では従来のボクセル選択法では着目されないボクセルが選択されたことから、大脳だけでなく全脳のボクセルを対象に解析を行うことで、より人の状態推定に有用な時系列特徴を有するボクセルの特定が可能になると考えられる。

# 謝辞

本研究を進めるにあたり、高知工科大学情報学群 吉田真一准教授に心より感謝いたします。本研究は試行錯誤の連続となりましたが、新しい技術の適用方法や解析手法で悩んだ際にはお時間を割いて何度も相談に応じてくださったり、度々の休日の MRI 実験に付き添ってくださるなど、終始サポートしていただいたおかげで本研究も形となり、論文を執筆することができました。学部の頃から修士まで一貫して挑戦的な研究ができたことや初めての海外での国際学会での発表など、吉田研究室で過ごした時間は私の学生生活における貴重な財産となりました。深く感謝いたします。

そして、本研究の副査を引き受けていただきました高知工科大学情報学群 岩田誠教授、並びに繁樹博昭准教授からは、脳科学の知見から多くのアドバイスをいただきましたことで、得られた結果において視野を広げて考察し、提案手法の改善などに取り組むことができました。お二方には、お忙しいにもかかわらず大変お世話になりました。深く感謝いたします。

吉田研究室の皆様にも大変お世話になりました。研究室で楽しく過ごしながら研究ができたのも皆様のおかげです。特に、同期とは研究室配属が行われた時から4年の付き合いであると考えると非常に感慨深いものがあります。佐々木泰一氏は、同じ脳情報デコーディングに関する研究テーマで、いろいろと相談に乗ってもらいました。また、お互い英語に苦勞して、単位が取れば最後の授業となる英語の授業では協力して課題に取り組んだり、朝までテスト勉強をした結果「これはやばい」と諦めモードになりましたね。佐々木氏だけ単位を取得したこと、一生忘れません。笹谷健文氏は、吉田研究室の全てを握る男であり、本研究を進めるにあたり研究環境を整えてもらいました。また、就職活動では一生頭が上がらないのではと思うほど助けて頂きました。私がこれから就職して、生活していけるのは笹谷氏のおかげだと言っても過言ではありません。領内あゆみ氏は、本当に多くの知識を持っており、研究を進めるにあたりたくさんの気づきやアドバイスをいただきました。一つ心残りなのは、領内氏がすごすぎて、何一つ恩返しができなかったのではと思っていることです。修

## 謝辞

士課程では、苦しいことも悩むこともたくさんありましたが、同期が3人もいるというのは本当に心強かったです。皆様が同期で本当に良かったと心より思っております。感謝しています。

4年生の皆様は、それぞれが強烈な個性を持っており、吉田研究室に入ってきてから卒業研究まで飽きることがなかったです。3年生の皆様は、2つ年下とは思えないほどフレンドリーで、これからどんな吉田研究室の空気を作ってくれるのかとても楽しみに思っております。これから、就職活動や院進学、研究と忙しくなると思いますが、悔いの残らない学生生活を送れるよう、心より応援しています。

最後に、4年間の学生生活に加え、2年間の大学院での生活を支援してくれた家族に深く感謝いたします。

皆様のおかげで、悔いの無い楽しい大学生活を送ることができました。私を支えてくれた皆様へ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] Kerri Smith, “Brain decoding: Reading minds,” *Nature*, Vol. 502, Issue 7472, pp. 428–430, 2013.
- [2] James V. Haxby, M. Ida Gobbini, Maura L. Furey, Almit Ishai, Jennifer L. Schouten, Pietro Pietrini, “Distributed and Overlapping Representations of Faces and Objects in Ventral Temporal Cortex,” *Science*, Vol. 293, Issue 5539, pp. 2425–2430, 2001.
- [3] Yukiyasu Kamitani & Frank Tong, “Decoding the visual and subjective contents of the human brain,” *Nature Neuroscience*, Vol.8, No.5, pp.679–685, 2005.
- [4] John-Dylan Haynes & Geraint Rees, “Predicting the orientation of invisible stimuli from activity in human primary visual cortex,” *Nature Neuroscience*, Vol. 8, No. 5, pp. 686–695, 2005.
- [5] David H. Hubel & Torsten Wiesel, “Receptive fields, binocular interaction and functional architecture in the cat’s visual cortex.” *The Journal of Physiology*, Vol. 160, No. 1, pp. 106-154, 1962.
- [6] James V. Haxby, “Multivariate pattern analysis of fMRI: The early beginnings,” *NeuroImage*, Vol. 62, pp. 852–855, 2012.
- [7] Yoichi Miyawaki, Hajime Uchida, Okito Yamashita, Masa-aki Sato, Yusuke Morito, Hiroki C. Tanabe, Norihiro Sadato, and Yukiyasu Kamitani, “Visual Image Reconstruction from Human Brain Activity using a Combination of Multiscale Local Image Decoders,” *Neuron*, Vol. 60, pp. 915–929, 2008.
- [8] Shinji Nishimoto, An T. Vu, Thomas Naselaris, Yuval Benjamini, Bin Yu, Jack L. Gallant, “Reconstructing Visual Experiences from Brain Activity Evoked by Natural Movies,” *Current Biology*, Vol. 21, pp. 1641–1646, 2011.

## 参考文献

- [9] T. Horikawa, M. Tamaki, Y. Miyawaki, Y. Kamitani, “Neural Decoding of Visual Imagery During Sleep,” *Science*, Vol. 340, pp. 639–642, 2013.
- [10] Tomoyasu Horikawa & Yukiyasu Kamitani, “Generic decoding of seen and imagined objects using hierarchical visual features,” *Nature Communications*, Vol. 8, Open Access Article number: 15037(2017), 2017.
- [11] 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.
- [12] R.Nakayama, et al., “Topological Data Analysis for Time Series of Functional Magnetic Resonance Imaging,” *ISCIIA2018*, Tengzhou, Shandong, China, Nov.2-6, 2018.
- [13] 菊池吉晃, “SPM8 脳画像解析マニュアル,” pp. 54–60, 医歯薬出版, 2012.
- [14] Matthew Brett, “Introduction to SPM statistics,”  
[http://www.nemotos.net/resources/intro\\_spm\\_statistics\\_ja.pdf](http://www.nemotos.net/resources/intro_spm_statistics_ja.pdf)
- [15] 岩渕俊樹, “fMRI による脳機能計測:基礎と展望,” *埼玉放射線*, Vol.61, No.3, pp.235–243, 2016. <https://bicr.atr.jp//dni/dni-content/uploads/downloads/2011/07/e3c183b0dbf5533642f3246694437699.pdf>
- [16] 中路友梨, “fMRI による脳情報デコーディングを用いた図形識別のための相関に基づく特徴抽出,” 平成 26 年度高知工科大学学士学位論文, 2015.
- [17] 小池規伎, “fMRI を用いた脳情報デコーディングに適した機械学習,” 平成 24 年度高知工科大学学士学位論文, 2015.
- [18] 高橋宏和, “fMRI による脳情報デコーディングを用いた快・不快画像の識別,” 平成 26 年度高知工科大学学士学位論文, 2015.
- [19] 山中康寛, “fMRI による感情のブレインデコーディングにおける OASIS の評価,” 平成 29 年度高知工科大学学士学位論文, 2018.
- [20] 前原春菜, “fMRI による脳情報デコーディングを用いた人の表情理解の推定,” 平成 27 年度高知工科大学学士学位論文, 2016.

## 参考文献

- [21] Yuhei Umeda, “Time Series Classification via Toporogical Data Analysis, ” 人工知能学会論文誌, Vol.32, No.3, pp.1-12, 2017.
- [22] 池口徹, 山田泰司, 小室元政, “カオス時系列解析の基礎と応用, ”pp.66–69, 産業図書館株式会社, 2005.
- [23] MRIConvert, yanifty DICOM file converter,  
<http://lcni.uoregon.edu/downloads/mriconvert>, 2016.
- [24] Scott A. uettle, Allen W.song, Gregory McCarthy, “fMRI 原理と実践, ” pp.3, pp.281-282, MEDSi, 2017.
- [25] Brede Database, “WOROI:43 - BRodmann area, ”  
[http://hendrix.imm.dtu.dk/services/jerne/brede/WOROI\\_43.html](http://hendrix.imm.dtu.dk/services/jerne/brede/WOROI_43.html), 2017.
- [26] PickAtlas, ANSIR Laboratory,  
<http://fmri.wfubmc.edu/software/PickAtlas>
- [27] ジョン・H・マーティン, “マーティン 神経解剖学 テキストとアトラス, ” p.38, 西村書店, 2007.

# 付録 A

## 脳部位の詳細

結果にて示した，推定時に選択されたボクセルが含まれる脳部位について記す [27].

表 A.1 には運動タスクとの関連が予測される部位名と機能，表 A.2 には視覚刺激動画呈示タスクとの関連が予測される部位名と機能，表 A.3 では本研究で取り扱ったタスクとの関連は無いと考えられるが選択されているボクセルが含まれる脳部位名と機能を示す.

表 A.1 運動タスクとの関連が予測される脳部位

ブロードマンエリア	部位名	機能
ブロードマンエリア 2	一次体性感覚野	触覚, 固有覚
ブロードマンエリア 5	頭頂連合野	視覚, 感覚・言語の情報統合
ブロードマンエリア 9	前頭全連合皮質	思考, 認知, 運動企画
ブロードマンエリア 10	前頭全連合皮質	思考, 認知, 運動企画
ブロードマンエリア 11	前頭全連合皮質	思考, 認知, 運動企画
ブロードマンエリア 47	前頭全連合皮質	思考, 認知, 行動企画



表 A.2 視覚刺激動画呈示タスクとの関連が予測される脳部位

ブロードマンエリア	部位名	機能
ブロードマンエリア 5	頭頂連合野	視覚, 感覚・言語の情報統合
ブロードマンエリア 6	前頭眼野	眼球運動
ブロードマンエリア 7	頭頂連合野後部	視運動
ブロードマンエリア 17	一次視覚野	視覚
ブロードマンエリア 18	二次視覚野	視覚
ブロードマンエリア 19	高次視覚皮質	視覚, 色覚, 動き, 奥行き
ブロードマンエリア 20	視覚性下側頭野	形態視
ブロードマンエリア 21	視覚性下側頭野	形態視
ブロードマンエリア 37	紡錘状回	視覚, 知覚, 読字, 言語
ブロードマンエリア 39	頭頂-側頭-後頭連合皮質	視覚, 知覚, 読字, 言語
-	脳梁	視覚野中継
-	全腹側核	脳機能中継 (感覚入力)

表 A.3 その他の脳部位

ブロードマンエリア	部位名	機能
ブロードマンエリア 22	高次聴覚皮質	聴覚, 言語
ブロードマンエリア 28	一次嗅覚野	嗅覚, 情動, 学習, 記憶
ブロードマンエリア 31	辺縁連合皮質	情動, 嗅覚
ブロードマンエリア 38	一次嗅覚野	嗅覚, 情動
ブロードマンエリア 40	縁上回	言語
-	尾状核	学習, 記憶