

令和元年度
学士学位論文

マルチバンド fMRI による
脳情報デコーディングのための時系列特徴

A Time Series Feature for Brain Decoding using
Multi-band functional Magnetic Resonance Imaging

1200327 高橋慎也

指導教員 吉田真一

2020年2月28日

高知工科大学 情報学群

要旨

マルチバンド fMRI による 脳情報デコーディングのための時系列特徴

高橋慎也

脳情報デコーディングは、人の見ているものや考えていること、性格や運動の内容などを人間の脳活動から推定する研究である。中山らの研究では、脳活動の時系列性に着目した特徴生成を行っており高い精度を得ている。そこで本研究では、時系列特徴による脳情報デコーディングの精度をさらに向上させるために、脳活動の計測結果にはノイズや識別したい内容などの様々な成分が含まれていると考え、音源分離などの分野で用いられる独立成分分析を fMRI データに適用することを提案し、有用性の検討を行う。その結果として提案手法の独立成分分析を適用した成分ごとの識別率は、従来手法であるボクセルごとの識別率と比較すると上下に変化が起っており、独立成分分析によって機械学習に有効である成分とそうではない成分に分離できていると考える。

キーワード functional MRI, 脳情報デコーディング, 時系列データ解析, 独立成分分析

Abstract

A Time Series Feature for Brain Decoding using Multi-band functional Magnetic Resonance Imaging

Shinya Takahashi

Brain decoding is a technique to predict human thoughts in brain, stimuli input to brain and so on from brain activity obtained by fMRI, EEG, etc. Nakayama has studied to use time-series features in fMRI signals for brain decoding. However fMRI signals includes not only brain signals but also noises and other signals from various sources. These mixed signals affect accuracies of brain decoding. Therefore, in this study, we propose to separate fMRI data from other components such as noise to improve the accuracy of prediction. We use ICA (independent component analysis) for the separation. The result shows that the accuracies using the separated signals by the proposed method are higher and lower accuracies compared to the conventional method. Therefore ICA can separate fMRI data for some beneficial components to machine learning from the original signals.

key words functional MRI, Brain Decoding, Time Series Analysis, Independent Component Analysis

目次

第 1 章	序論	1
第 2 章	関連技術	3
2.1	Functional Magnetic Resonance Imaging(fMRI)	3
2.2	脳情報デコーディング	3
2.3	独立成分分析	4
第 3 章	提案手法	5
3.1	ICA を用いた fMRI 成分の分離	5
3.1.1	データの選択	5
3.1.2	データの並べ替え	6
3.1.3	独立成分分析の適用	6
3.1.4	特徴抽出	6
3.1.5	機械学習	9
第 4 章	実験	10
4.1	実験装置	10
4.2	実験デザイン	10
4.3	前処理	11
4.4	データの整形	12
4.5	独立成分分析と特徴抽出	12
4.6	機械学習と精度評価	12
第 5 章	結果	13
5.1	結果	13

目次

5.1.1	被験者 A	13
5.1.2	被験者 B	17
5.1.3	被験者 C	21
第 6 章	考察	25
第 7 章	結論	26
	謝辞	27
	参考文献	28

目次

3.1	ボクセル選択後のデータ	6
3.2	データの分割と連結	7
3.3	独立成分分析の適用	7
3.4	特徴生成	8
4.1	45 度斜線動画	11
4.2	135 度斜線動画	11
4.3	レスト動画	11
4.4	被験者実験の手順	11
5.1	被験者 A : 第 1 試行 ($N = 10$)	13
5.2	被験者 A : 第 2 試行 ($N = 10$)	14
5.3	被験者 A : 第 3 試行 ($N = 10$)	14
5.4	被験者 A : 第 4 試行 ($N = 10$)	14
5.5	被験者 A : 第 1 試行 ($N = 15$)	14
5.6	被験者 A : 第 2 試行 ($N = 15$)	15
5.7	被験者 A : 第 3 試行 ($N = 15$)	15
5.8	被験者 A : 第 4 試行 ($N = 15$)	15
5.9	被験者 A : 第 1 試行 ($N = 30$)	15
5.10	被験者 A : 第 2 試行 ($N = 30$)	16
5.11	被験者 A : 第 3 試行 ($N = 30$)	16
5.12	被験者 A : 第 4 試行 ($N = 30$)	16
5.13	被験者 B : 第 1 試行 ($N = 10$)	17
5.14	被験者 B : 第 2 試行 ($N = 10$)	17

目次

5.15 被験者 B : 第 3 試行 ($N = 10$)	17
5.16 被験者 B : 第 4 試行 ($N = 10$)	18
5.17 被験者 B : 第 1 試行 ($N = 15$)	18
5.18 被験者 B : 第 2 試行 ($N = 15$)	18
5.19 被験者 B : 第 3 試行 ($N = 15$)	18
5.20 被験者 B : 第 4 試行 ($N = 15$)	19
5.21 被験者 B : 第 1 試行 ($N = 30$)	19
5.22 被験者 B : 第 2 試行 ($N = 30$)	19
5.23 被験者 B : 第 3 試行 ($N = 30$)	19
5.24 被験者 B : 第 4 試行 ($N = 30$)	20
5.25 被験者 C : 第 1 試行 ($N = 10$)	21
5.26 被験者 C : 第 2 試行 ($N = 10$)	21
5.27 被験者 C : 第 3 試行 ($N = 10$)	21
5.28 被験者 C : 第 4 試行 ($N = 10$)	22
5.29 被験者 C : 第 1 試行 ($N = 15$)	22
5.30 被験者 C : 第 2 試行 ($N = 15$)	22
5.31 被験者 C : 第 3 試行 ($N = 15$)	22
5.32 被験者 C : 第 4 試行 ($N = 15$)	23
5.33 被験者 C : 第 1 試行 ($N = 30$)	23
5.34 被験者 C : 第 2 試行 ($N = 30$)	23
5.35 被験者 C : 第 3 試行 ($N = 30$)	23
5.36 被験者 C : 第 4 試行 ($N = 30$)	24

第 1 章

序論

脳情報デコーディングとは MRI(核磁気共鳴画像) や EEG(脳波) などによって計測された人間の脳活動データからその人間の感情や性格, 運動している内容などを推定する技術である. その中でも fMRI(機能的 MRI) を用いた脳情報デコーディングにおいては, 撮像された 3 次元の画像を用いる方法や, fMRI 画像から求められる脳活動の賦活度合いを解析する方法が行われている.

脳活動の賦活度合いを用いる方法として, 中山ら [2] は脳の賦活度合いを標準化した Z 値を用いて, 脳活動の時系列性に着目した特徴を用いる手法を提案した. その手法では, 各ボクセルの Z 値を一定の時間幅で切り取ったもの特徴ベクトルとして機械学習に用いることで単変量解析や多変量解析などの従来手法によって得られた特徴を用いた場合に比べて精度が向上した.

しかし, fMRI によって計測されたデータには, 実験中の被験者の体の動きや, 測定の際の機器や実験内容とは関係ない被験者の脳活動などによって生じるノイズが含まれており, それが機械学習による識別に悪影響を及ぼしている可能性がある. そこで本実験では, 脳情報デコーディングの精度を先行研究から更に向上させるための方法として, 独立成分分析による, 脳活動の信号成分の分離を提案する.

本論文の第 2 章では本研究に関する技術として fMRI や脳情報デコーディング, 独立成分分析の概要を述べる. 続いて第 3 章では本研究の提案である fMRI データに対して独立成分分析を用いた結果を時系列パターンの特徴とする手法について述べる. 第 4 章では本実験の内容として fMRI 実験の内容や提案手法を含むデータの解析などについて述べる. 第 5 章では, 第 4 章の実験の結果を示し, 第 6 章でその結果についての考察を述べる. 最後に第 7

章では，本研究における結論を述べる．

第 2 章

関連技術

2.1 Functional Magnetic Resonance Imaging(fMRI)

Functional Magnetic Resonance Imaging(fMRI) とは，核磁気共鳴 (MR) 装置を用いることで人間の脳活動によって引き起こされる脳内の血流の変化を可視化する方法である．これによって脳機能を部位ごとに画像として表現する．MR 装置では，非常に強力な磁場 (1.5 ～7.0 テスラ) の中で水素原子核の分布を測定することにより，組織の形状などを計測し画像化する．

2.2 脳情報デコーディング

脳情報デコーディングとは，脳が情報を符号化 (コーディング) しているという仮定に則って，その脳活動を計測器で計測することで，人間が見ている物体や考えている内容などの状態を解読する (デコーディング) 技術である．この技術により，思考するだけでコンピュータなどの機械を操作する BMI(Brain Machine Interface) が実現できると医療や介護などの分野に期待されている．

脳情報デコーディングは基本的に

1. 被験者の脳活動の計測 (fMRI や EEG など)
2. 機械学習により計測されたデータから状態を推定するデコーダを作成
3. 新しく得られたデータを作成したデコーダで予測

という手順で実現される．

2.3 独立成分分析

独立成分分析 (Independent Component Analysis) とは、主に音源分離などの分野で用いられている、複数の音源から発せられた音を音源より多い個数の計測機で計測したデータから個々の音源を分離する技術である。

複数の計測機によって観測されたデータ $\mathbf{x}(t) (= (x_1(t), x_2(t), \dots, x_m(t))^T)$ と複数の信号源のデータ $\mathbf{s}(t) (= (s_1(t), s_2(t), \dots, s_m(t))^T)$ の間に、 $m \times n$ 定数行列 A による

$$\mathbf{x}(t) = A\mathbf{s}(t) \quad (2.1)$$

という関係を仮定し、 $\mathbf{x}(t)$ を n 個の独立な成分に分離するような

$$\mathbf{y}(t) = W\mathbf{x}(t) \quad (2.2)$$

となる実数行列 $W(n \times m)$ を求めるアルゴリズムが独立成分分析である。

第 3 章

提案手法

先行研究 [2] では、安静時の脳活動の時系列パターンに時間変化が存在するという Default Mode Network の研究から、安静時以外の場合でも脳活動には時系列変化が存在しているとした実験を行った結果、従来手法に比べて高い精度の結果が得られた。

本研究では、先行研究にて脳情報デコーディングに有効であると示された時系列特徴を用いた手法をさらに発展させるために、ノイズによる悪影響を低減させるための手法として、独立成分分析を用いて脳活動の成分を分離する方法を提案する。

3.1 ICA を用いた fMRI 成分の分離

本提案では、fMRI によって計測される脳活動には複数の成分 (視覚に関する活動、思考に関する活動、ノイズなど) が含まれていると仮定し、その成分の分離を目的とする独立成分分析の適用を行う。fMRI によって計測されたデータは、ボクセルごとに計測されており、それぞれの脳活動ごとに計測はできない。そこで、複数ボクセルによって計測された脳活動の時系列情報から独立成分分析を用いることで、脳活動の内容を表現できる成分を求めるところができると考え、複数ボクセルの脳活動値に対して独立成分分析を適用する。

3.1.1 データの選択

fMRI によって計測された Z 値に対して独立成分分析を適用するための前準備として、データの整形を行う。まず多数あるボクセルから、各タスクのスキャン数である 88 より少ないボクセルを選択する。今回はタスク間で相関の高い 88 ボクセルを選択した。これによ

3.1 ICA を用いた fMRI 成分の分離

り図 3.1 に示すようなサイズのデータが得られる。

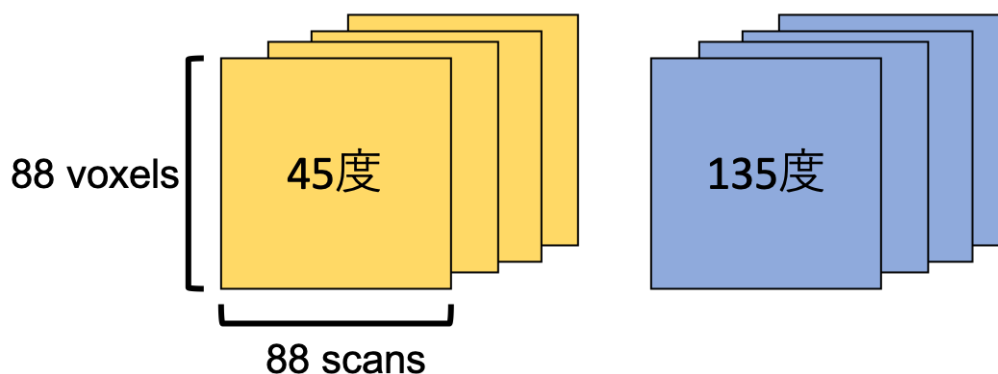


図 3.1 ボクセル選択後のデータ

3.1.2 データの並べ替え

続いて、そのデータから学習用のデータとテスト用のデータを用意するために、図 3.2 のように 45 度動画と 135 度動画のタスクごとのデータを分割し、各試行ごとに連結する。これにより、学習データとテストデータが 4 セット作成できる。

3.1.3 独立成分分析の適用

先の手順で作成した学習データに対して独立成分分析を適用し、64 個の独立成分に分割する。また、それによって得られた変換行列をテストデータに対しても同様に適用する (図 3.2)。

3.1.4 特徴抽出

得られた独立成分それぞれから、時系列幅 $N (= 10, 15, 30)$ 秒分の Z 値を切り取ることで、それぞれの独立成分の時系列パターンを特徴とした特徴ベクトルを生成する。ある独立成分の時系列データを試行とタスクごとに分割する。分割した Z 値の組を $X = \{x_t\}_{t=1}^T$ とする。ここでの T は 1 タスクのデータ数となっており、本実験では 88 である。

3.1 ICA を用いた fMRI 成分の分離

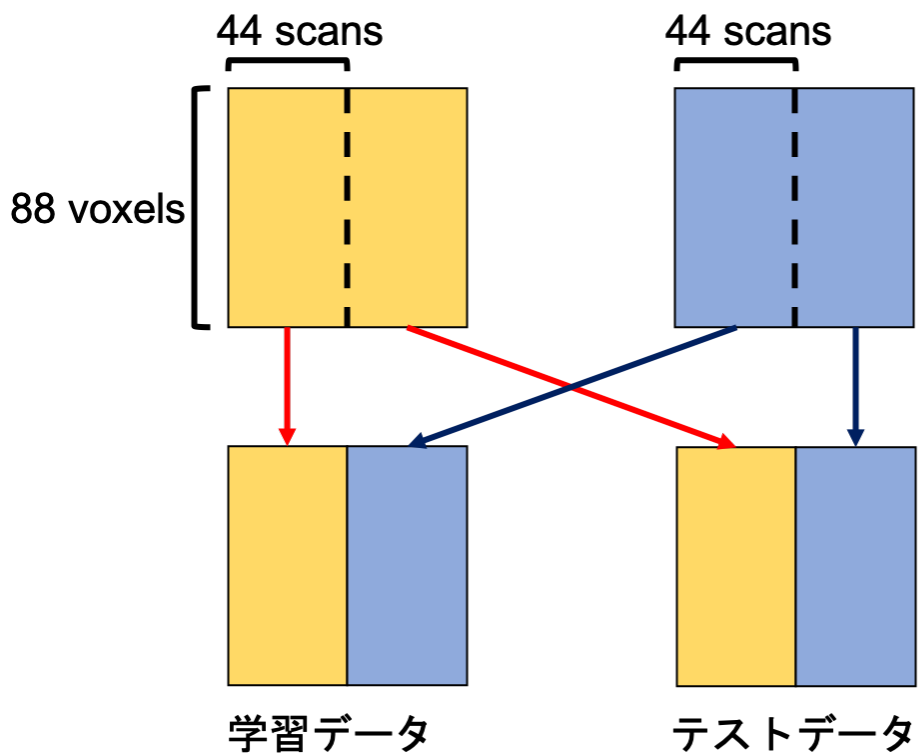


図 3.2 データの分割と連結

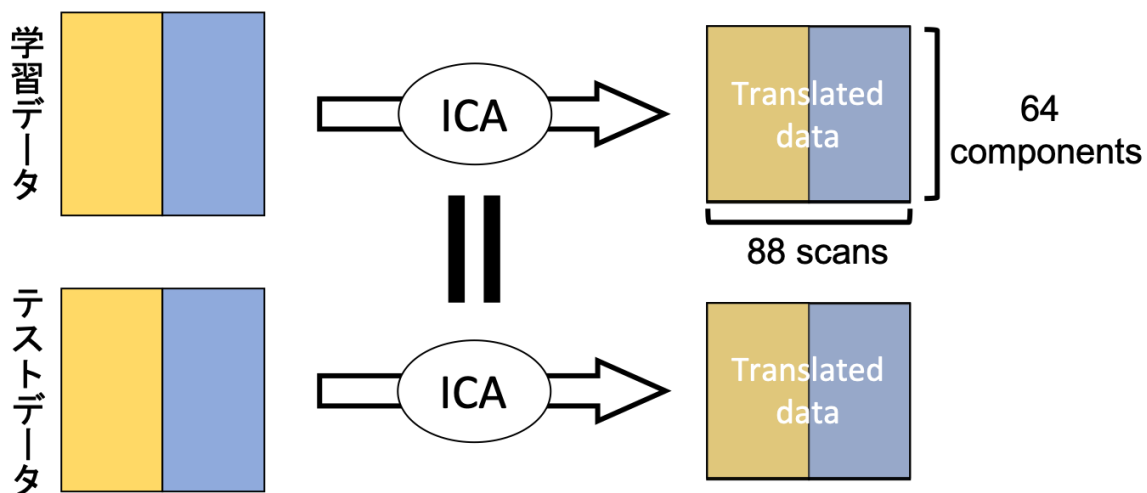


図 3.3 独立成分分析の適用

3.1 ICA を用いた fMRI 成分の分離

これにより分別された X から時系列幅 N 秒分の Z 値を抜き出す。抜き出したデータを独立成分の時系列の特徴ベクトルとする。ある時刻 t の時系列特徴ベクトル f_t は図 3.4 のように生成され、

$$f_t = [x_t, x_{t+1}, \dots, x_{t+N}]^T \quad (3.1)$$

で表せられる。

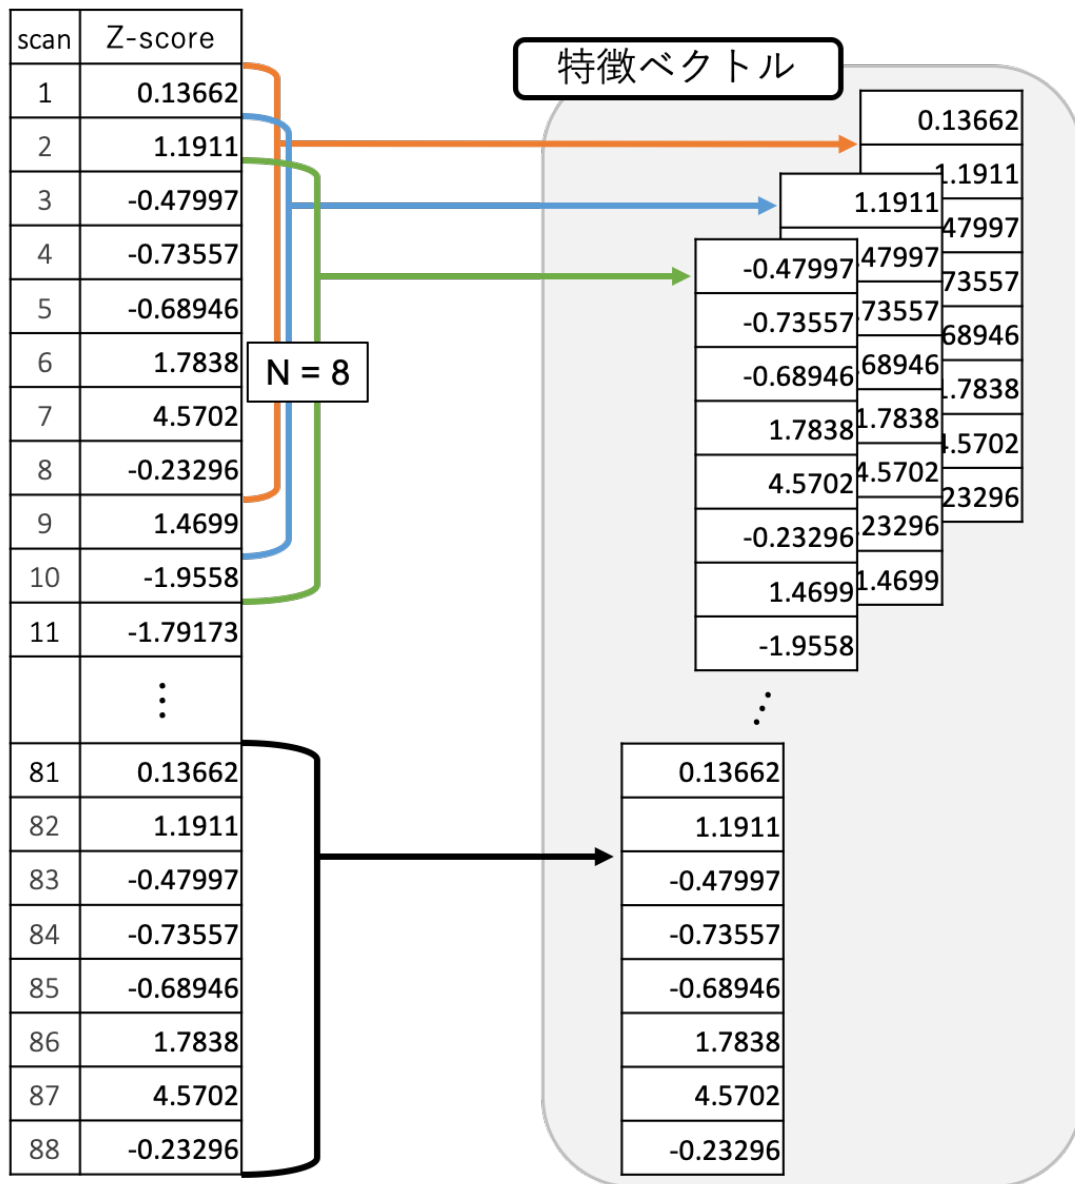


図 3.4 特徴生成

3.1 ICA を用いた fMRI 成分の分離

3.1.5 機械学習

機械学習には SVM(Support Vector Machine) アルゴリズムを用いる。本実験では、Python3 のライブラリである scikit-learn の svm.SVC クラスを用いた。パラメータとして、カーネル関数には線型カーネル、コストパラメータは 1 をそれぞれ設定した。

第 4 章

実験

本章では、提案手法を用いた実験の流れを述べる。本実験では中山らの先行研究にて得られたデータセットを用いて実験を行ったが、その内容について述べる。

4.1 実験装置

被験者の脳活動の計測には MRI 装置として、高知工科大学の所有している MRI 装置 (SIEMENS 社, MAGNETOM Prisma(3T)) を用いた。

4.2 実験デザイン

本実験では先行研究における斜線動画順序提示タスクについてのデータを用いた。

被験者は MRI 装置の中に入り、プロジェクターから装置内のスクリーンに投影された動画が呈示される。呈示される刺激は、図 4.1 と図 4.2 に示している画像が右へと流れていく動画である。図 4.4 に示すように実験の流れは、

1. 図 4.3 のようなレスト画像を 10 秒間呈示する。
2. 45 度斜線動画 (4.1 が横に動く) を 90 秒間呈示する。
3. レスト画像を 10 秒呈示する。
4. 135 度斜線動画 (4.2 が横に動く) を 90 秒間呈示する。
5. レスト画像を 10 秒呈示する。

という試行を 1 セットとし、各被験者に 4 試行ずつ行う。また、被験者が実験中に寝てしま

4.3 前処理

うことを防ぐために、動画が切り替わるたびに手元のボタンを押すように指示した。



図 4.1 45 度斜線動画



図 4.2 135 度斜線動画




図 4.3 レスト動画




図 4.4 被験者実験の手順

4.3 前処理

まず、fMRI 装置によって得られるデータは DICOM 形式であるため、前処理用ソフトウェア SPM で使える形式である NIFTI 形式に変換する必要がある。今回は、MRIConvert というフリーのソフトウェアを用いる。

次に、各タスクの最初と最後の 1 スキャンはノイズを含んでいるため取り除く。

続いて、ブロードマンエリアに基づく大脳新皮質領域の抜き出しを行う。まず SPM を用いて各スキャンごとの 3 次元 fMRI データを時系列順で並べて 4 次元 fMRI データへと変換する。次に人の脳のブロードマンエリアに対応する場所のみを抜き出すためのマスク画像を作成する。作成したマスク画像とスキャンデータとともに SPM を用いて Normalization 処理を行ったのちにマスク画像にはスキャンデータに合わせた Reslice 処理を適用する。

最後に Python のライブラリである PyMVPA を用いてスキャンデータに対してマスク画像を適用し、大脳新皮質に対応するボクセルごとの Z 値を取得する。

4.4 データの整形

4.4 データの整形

提案手法を得られたデータに適用するために、全ボクセルデータから指定ボクセル分のデータを抜き出す。その後抜き出したデータを分割して並び替えて連結する。

4.5 独立成分分析と特徴抽出

作成した学習データに対して独立成分分析を適用することでボクセルごとの時系列データから作成された独立成分ごとの時系列データとなる。加えて提案手法の評価のためにテストデータにも学習データに適用したものと同一の変換行列を適用する。

さらに作成した独立成分から時系列幅で切り取った時系列特徴を生成する。

4.6 機械学習と精度評価

作成した時系列特徴を用いて機械学習アルゴリズム SVM で学習を行う。

精度評価は学習データと同様の処理を行ったテストデータの特徴ベクトルを用いて行う。独立成分分析によって成分は分離されているため、共通の変換を行った学習データとテストデータの対を用いる。また独立成分間に対応はないため、同じ行のデータを用いて精度評価を行う。

第 5 章

結果

本章では，被験者ごとの実験の結果について述べ，提案手法の有用性などについての考察を行う．

5.1 結果

各被験者の結果を示す．各画像の左のグラフがボクセルごとの識別率の結果であり，右側が独立成分ごとのの識別率の結果である．被験者 A の実験結果を図 5.1 から図 5.12，被験者 B の結果を

5.1.1 被験者 A




図 5.1 被験者 A : 第 1 試行 ($N = 10$)

5.1 結果




図 5.2 被験者 A : 第 2 試行 ($N = 10$)




図 5.3 被験者 A : 第 3 試行 ($N = 10$)




図 5.4 被験者 A : 第 4 試行 ($N = 10$)




図 5.5 被験者 A : 第 1 試行 ($N = 15$)

5.1 結果




図 5.6 被験者 A : 第 2 試行 ($N = 15$)




図 5.7 被験者 A : 第 3 試行 ($N = 15$)




図 5.8 被験者 A : 第 4 試行 ($N = 15$)




図 5.9 被験者 A : 第 1 試行 ($N = 30$)

5.1 結果




図 5.10 被験者 A : 第 2 試行 ($N = 30$)




図 5.11 被験者 A : 第 3 試行 ($N = 30$)




図 5.12 被験者 A : 第 4 試行 ($N = 30$)

5.1 結果

5.1.2 被験者 B




図 5.13 被験者 B : 第 1 試行 ($N = 10$)




図 5.14 被験者 B : 第 2 試行 ($N = 10$)




図 5.15 被験者 B : 第 3 試行 ($N = 10$)

5.1 結果




図 5.16 被験者 B : 第 4 試行 ($N = 10$)




図 5.17 被験者 B : 第 1 試行 ($N = 15$)




図 5.18 被験者 B : 第 2 試行 ($N = 15$)




図 5.19 被験者 B : 第 3 試行 ($N = 15$)

5.1 結果




図 5.20 被験者 B : 第 4 試行 ($N = 15$)




図 5.21 被験者 B : 第 1 試行 ($N = 30$)




図 5.22 被験者 B : 第 2 試行 ($N = 30$)




図 5.23 被験者 B : 第 3 試行 ($N = 30$)

5.1 結果




図 5.24 被験者 B : 第 4 試行 ($N = 30$)

5.1 結果

5.1.3 被験者 C




図 5.25 被験者 C : 第 1 試行 ($N = 10$)




図 5.26 被験者 C : 第 2 試行 ($N = 10$)




図 5.27 被験者 C : 第 3 試行 ($N = 10$)

5.1 結果




図 5.28 被験者 C : 第 4 試行 ($N = 10$)




図 5.29 被験者 C : 第 1 試行 ($N = 15$)




図 5.30 被験者 C : 第 2 試行 ($N = 15$)




図 5.31 被験者 C : 第 3 試行 ($N = 15$)

5.1 結果




図 5.32 被験者 C : 第 4 試行 ($N = 15$)




図 5.33 被験者 C : 第 1 試行 ($N = 30$)




図 5.34 被験者 C : 第 2 試行 ($N = 30$)




図 5.35 被験者 C : 第 3 試行 ($N = 30$)

5.1 結果




図 5.36 被験者 C : 第 4 試行 ($N = 30$)

第 6 章

考察

提案手法での独立成分分析によって分離された独立成分ごとの識別率と従来手法でのボクセルごとの識別率を比較すると、全体の傾向としてボクセルごとの識別では識別率の差が比較的小さいことに対して、独立成分による分類では独立成分間の識別率の差が大きいことが考えられる。これは、識別において重要な脳活動の波形とノイズなどのあまり重要では無い脳活動が混ざって観測されていたボクセル単位でのデータに対し、独立成分分析によって重要な波形とそうでは無いものを分類することが出来ていることが示唆される。また、本実験は 2 クラス分類問題であることから、50%付近の識別率が最も正しく分類できていないということであり、独立成分ごとの結果に見られる識別率が特に低い成分も識別に不要であるとは断定できないと考えられる。

本実験では、独立成分分析の変換行列を各被験者の各試行ごとに作成していたことや、提案手法を適用するボクセルは与えられたクラス間の相関によって決定されていることから、ブレインデコーディングにおける汎化能力は認められない。そのため、汎化性能を向上させる方法として、

- 分離した独立成分から何らかの基準によって不要な成分を取り除き、逆変換によりボクセルごとのクラス表現力の向上
- ブロードマンエリアなどによる個人内の結果によらない選択ボクセルの決定

などが考えられる。

第 7 章

結論

脳情報デコーディングのための手法として、計測されたボクセルの賦活度合いを標準化した Z 値を時系列幅で抜き出すことによって作成した特徴ベクトルを機械学習に用いる手法が有用であることが示されている。しかし fMRI 実験は計測時に様々な要因でノイズが発生していることが考えられる。そこで本研究ではその影響を低減させるために時系列データに対して独立成分分析を適用し、ノイズなどの成分を分離させる実験を行った。

実験では、3 人の被験者の脳活動を標準化したボクセルごとの Z 値に対して、相関の高い 88 のボクセルを抽出して提案手法である独立成分分析を適用し、提案手法を適用していない手法の識別率との比較を行った。その結果として、一様出会ったボクセルごとの識別率に比べて提案手法では識別率に変化が見られ、独立成分分析によって機械学習による識別に有用である成分とそうでは無い成分に分離できている可能性が見られた。

しかし、汎化の面での検討ができていないため、今後の課題として、ボクセル選択基準の検討や、独立成分を一部取り除くことによってボクセルごとの識別におけるクラスを表現する特徴を強調する方法の検討などが挙げられる。

謝辞

本研究を進めるにあたり、高知工科大学情報学群の吉田真一准教授には心からの感謝を述べさせていただきます。研究活動では、締め切りにギリギリとなってしまう私に対して優しく付き添って頂き何度も助けて下さったことには、感謝の念は筆舌に尽くしがたいものがあります。また、研究活動以外の面でも、豊富な知識量から様々な面でも学ばせていただくことが多く、吉田研究室での日々を一層充実したものへと変えてくださいました。大学院に進学いたしますので、あと2年間よろしく申し上げます。

四宮友貴助教授にも、研究への姿勢などのアドバイスを頂いた他にも、私たちのくだらない雑談にも付き合ってくださいありがとうございました。

また、本研究の副査を引き受けて下さった高知工科大学情報学群の岩田誠教授、並びに中原潔教授に深く感謝いたします。発表の際にいただいたアドバイスを参考にこれからの研究を進めて行きたいと思えます。

そして、共に研究を進めてきた同期の方たちにも感謝申し上げます。元木氏は、趣味でのアドバイスなどを貰ったり、よくプライベートでもよく関わってくれてありがとうございました。また、高橋氏には、話した機会が多いわけではありませんでしたが面白い話をできたと思います。就職するお二人は仕事が始まってコロナに負けず頑張ってください。残りの同期は院進するので2年後にまた書きます。

さらに卒業して行った方たちを含む先輩方にも、研究室活動やプライベートでもとてもお世話になりました。先輩方の姿を目指してこれからも研究活動に勤し見たいと思えます。

後輩たちにも、イベントのセッティングなどをお世話していただきありがとうございました。私のような4年生にならないようにこれからも精進してください。

また、今まで22年の間私の生活、学習を支えてくださった家族にも感謝を述べたいと思えます。4年前にもあと4年と申しましたが、あと2年間よろしく申し上げます。

参考文献

- [1] Yukiyasu Kamitani, “Decoding the visual and subjective contents of the human brain, ” Nature Neuroscience, No.8, pp.679-685, 2005.
- [2] 中山梨奈, “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, ” 平成30年度高知工科大学修士学位論文, 2019.
- [3] 村木茂, “独立成分分析と医用画像処理, ”Medical Imaging Technology, Vol.20, No.1, pp.36-42, 2002.
- [4] Prantik Kundu, Souheil J. Inati, Jennifer W. Evans, Wen-Ming Luh, Peter A. Bandettini, “Differentiating BOLD and non-BOLD signals in fMRI time series using multi-echo EPI, ”NeuroImage, 60, pp.1759-1770, 2012.
- [5] 堀川友慈, 宮脇陽一, 神谷之康, “脳活動から心を可視化する, ”Japanese journal of optics : a publication of the Optical Society of Japan, the Japan Society of Applied Physics 43(3), pp.104-110, 2014.