

平成 26 年度

学士学位論文

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

Correlation Based Feature Extraction for Brain  
Decoding of Visual Stimuli

1150332 中路 友梨

指導教員 吉田 真一

2014 年 2 月 27 日

高知工科大学 情報学群

## 要 旨

# 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

中路 友梨

脳から直接コンピュータに情報を入力する BCI(Brain-Computer Interface) の研究が行われている。BCI に用いられる技術であるブレインデコーディングは脳活動情報を解読することで脳活動信号が測定されたときの状態を機械学習を用いて推定することである。ブレインデコーディングを行う際に、測定した脳活動情報から次元削減、特徴選択をする必要がある。本研究では、fMRI(functional Magnetic Resonance Imaging) を用いて脳活動を計測、その脳活動情報から図形識別 (7 種類, 3 種類の画像) に有効なボクセルを選択する方法を検討する。提案手法では、測定されたボクセル値と刺激の種類の違い (ラベル) の間の相関 (ピアソンの相関係数) を用いて特徴を抽出する。提案手法 1 では、ある図形とその他の図形の相関をすべての図形について求め、それらを平均する。提案手法 2 ではある図形と別の図形との相関を求め、それらをすべての図形間の組み合わせについて求めたものを平均する。求めた係数の絶対値の大きいものからボクセルを選択する。選択したボクセルに教師データとしてラベルを付加し、学習及びテストデータとする。機械学習アルゴリズムには SVM(Support Vector Machine) の線形カーネルを用い、3 フォールドのクロスバリデーションにより評価する。結果として 7 種類の画像に対しては、177 ボクセルを用いたとき既存の手法では 18%、提案手法 1 では 72%、提案手法 2 では 75%。3 種類の画像に対しては、145 ボクセルを用いたとき既存の手法では 44%、提案手法 1 では 74%、提案手法 2 では 88%となる。この結果より、個人レベルでは相関を用いることで、図形識別に有効なボクセルが選択できたといえる。

キーワード fMRI, 脳情報デコーディング, 図形識別, ボクセル選択

# Abstract

## Correlation Based Feature Extraction for Brain Decoding of Visual Stimuli

Nakaji Yuri

Brain Computer Interface (BCI), which input brain signal into computer directly, has been studied. Brain decoding is one of the BCI technology using functional Magnetic Resonance Imaging (fMRI) or other brain measuring devices. Brain decoding is used to estimate human brain 's internal condition by machine learning. Dimension reduction and feature selection are important to use machine learning for scanned brain signal. In this study, brain signal scanned by fMRI is used and two novel methods to select voxels for discrimination of seeing visual shapes (seven shapes and three shapes) are proposed. Proposed feature extraction methods are based on correlation voxels value and stimuli. The voxels whose absolute correlation values are high are selected as feature values. Training data and test data are produced by selected voxels append label for training and evaluation. The accuracy of support vector machine (SVM) by linear kernel using conventional approach is 18% and the first proposal approach is 72%, and the second proposal approach is 75% for seven shapes. Accuracy of conventional approach is 44% and the first proposal approach is 74%, and the second proposal approach is 88% for three shapes. From the result above, proposed methods can select effective voxels for the discrimination of visual shapes based on the relation.

**key words** fMRI, brain decoding discrimination shapes, voxel selection

# 目次

第 1 章	序論	1
第 2 章	要素技術と関連研究	3
2.1	ブレインデコーディング	3
2.2	fMRI 装置	4
2.3	相関	5
2.4	機械学習	7
2.5	クロスバリデーション	8
2.6	レチノトピー	9
2.7	関連研究 1	9
2.8	関連研究 2	10
第 3 章	実験内容	11
3.1	fMRI 実験	11
3.1.1	実験 1	12
3.1.2	実験 2	13
3.1.3	実験 3	15
3.2	SPM によるデータ解析	16
3.3	BDTB によるデコーディング	17
3.4	ボクセル選択提案手法	17
第 4 章	結果と考察	21
4.1	BDTB を用いた識別率	21
4.1.1	7 種類の図形識別	21
4.1.2	3 種類の図形識別	22

## 目次

4.2	提案手法を用いた識別率 . . . . .	22
4.2.1	7 種類の図形識別 . . . . .	22
4.2.2	3 種類の図形識別 . . . . .	27
<b>第 5 章</b>	<b>結論</b>	<b>31</b>
	謝辞	<b>33</b>
	参考文献	<b>35</b>
付録 A	追加実験	<b>37</b>
付録 B	脳画像と脳活動詳細	<b>38</b>
付録 C	各手法識別結果詳細	<b>47</b>
C.1	既存の手法 . . . . .	47
C.2	提案手法 1 . . . . .	51
C.3	提案手法 2 . . . . .	54
付録 D	提案手法で選択した上位 100 ボクセル	<b>59</b>

# 目次

2.1	ボールド効果 (oxy-Hb 濃度の変化)	5
2.2	DICOM ファイルの構成	5
2.3	SVM の分離超平面	8
2.4	特徴空間の写像	8
2.5	クロスバリデーション	9
2.6	学習に用いた画像	10
2.7	識別テストに用いた画像	10
3.1	実験 1 での提示画像	12
3.2	実験 2 での提示画像	14
3.3	提示画像拡大	14
3.4	実験デザイン (0.5 秒ごとにチェッカー反転)	15
3.5	提案手法の手順 (1)(2)	18
3.6	提案手法の手順 (3)	19
3.7	提案手法の手順 (4)	19
3.8	提案手法の手順 (5)(6)	20
4.1	特徴の次元に対する識別率の変化	23
4.2	特徴の次元に対する識別率の変化	24
4.3	特徴の次元に対する平均識別率 提案手法の比較	24
4.4	特徴の次元に対する識別率の変化	28
4.5	特徴の次元に対する識別率の変化	28
4.6	特徴の次元に対する平均識別率 提案手法の比較	29
A.1	特徴の次元に対する識別率の変化	37

## 図目次

B.1	被験者 A の賦活部位 . . . . .	39
B.2	被験者 B の賦活部位 . . . . .	40
B.3	被験者 C-1 の賦活部位 . . . . .	41
B.4	被験者 C-2 の賦活部位 . . . . .	42
B.5	被験者 C-3 の賦活部位 . . . . .	43
B.6	被験者 D の賦活部位 . . . . .	44
B.7	被験者 E の賦活部位 . . . . .	45
B.8	被験者 F の賦活部位 . . . . .	46
D.1	7 種類の図形識別で用いた上位 100 ボクセル 提案手法 1 . . . . .	60
D.2	7 種類の図形識別で用いた上位 100 ボクセル 提案手法 2 . . . . .	61
D.3	3 種類の図形識別で用いた上位 100 ボクセル 提案手法 1 . . . . .	62
D.4	3 種類の図形識別で用いた上位 100 ボクセル 提案手法 2 . . . . .	63

# 表目次

2.1	相関係数と関係の程度 . . . . .	6
3.1	実験 1, 2 の実験デザイン . . . . .	13
3.2	実験 3 の実験デザイン . . . . .	16
4.1	用いたボクセル数と識別率 . . . . .	21
4.2	用いたボクセル数と識別率 . . . . .	22
4.3	すべてのボクセルを用いたときの識別率とそのボクセル数 . . . . .	23
4.4	平均相関係数の上位 10 ボクセルの各組み合わせでの相関係数 . . . . .	25
4.5	平均相関係数の上位 10 ボクセルの各組み合わせでの相関係数 . . . . .	26
4.6	すべてのボクセルを用いたときの識別率とそのボクセル数 . . . . .	28
4.7	平均相関係数の上位 10 ボクセルの各組み合わせでの相関係数 . . . . .	29
4.8	平均相関係数の上位 10 ボクセルの各組み合わせでの相関係数 . . . . .	29
C.1	被験者 A . . . . .	47
C.2	被験者 B . . . . .	48
C.3	被験者 C-1 . . . . .	48
C.4	被験者 C-2 . . . . .	49
C.5	被験者 C-3 . . . . .	49
C.6	被験者 D . . . . .	50
C.7	被験者 E . . . . .	50
C.8	被験者 F . . . . .	50
C.9	被験者 A . . . . .	51
C.10	被験者 B . . . . .	52
C.11	被験者 C-1 . . . . .	52

## 表目次

C.12 被験者 C-2 . . . . .	53
C.13 被験者 C-3 . . . . .	53
C.14 被験者 D . . . . .	54
C.15 被験者 E . . . . .	54
C.16 被験者 F . . . . .	54
C.17 被験者 A . . . . .	55
C.18 被験者 B . . . . .	55
C.19 被験者 C-1 . . . . .	56
C.20 被験者 C-2 . . . . .	56
C.21 被験者 C-3 . . . . .	57
C.22 被験者 D . . . . .	57
C.23 被験者 E . . . . .	57
C.24 被験者 F . . . . .	58

# 第 1 章

## 序論

近年，fMRI から脳情報を取得しその情報から何を見ているのかを推定するブレインデコーディングという研究が行われている．Kamitani らの研究 [1] では，脳活動情報から線分の方位のデコーディングを行った．Miyawaki らの研究 [2] では，被験者の見ている 2 値画像をデコーディングし再構成した．このブレインデコーディングを用いて脳から直接コンピュータに情報を入力する BCI(Brain-computer Interface) を構成し，画像検索への応用も目指して，視覚に提示される図形の識別を行う研究がある [3]．先行研究では，3 種類の図形と 10 種類の図形を見ているときの脳活動情報をデコーディングし，3 種類のときの識別率は 77%，65%，10 種類のときの識別率は 14%であった．

BCI 実現のための要素技術として，脳活動の計測技術がある．脳活動の計測に用いられるのは主に，fMRI(functional Magnetic Resonance Imaging，機能的核磁気共鳴画像)，fNIRS(functional Near Infrared Spectroscopy，マルチチャンネル近赤外イメージング装置)，EEG(electroencephalogram，脳波計)がある．fNIRS や EEG は脳の表面の活動を計測するのに対し，fMRI は脳の内部の活動を計測することができる．本研究では，先行研究 [3] を基礎として fMRI で画像を見ている状態の脳活動を取得し，その内容から見ている画像を推定するものであるが，fMRI から得られる脳の信号そのものからは簡単には推定できないため，統計解析および機械学習を用いる．脳情報デコーディングを行うにあたり，図形識別に用いるボクセルを選択する．その際に，画像識別に有効なボクセル選択を行うことは識別率の向上につながると考える．そこで，本研究では画像の差異ベースとなる単純な図形の形状の識別を，脳活動を用いて行うためのボクセル選択方法を検討する．

本論文の構成は，第 2 章では，本研究に用いる要素技術であるブレインデコーディング，

fMRI 装置， 相関， 機械学習， クロスバリデーション， レチノトピーとブレインデコーディングの関連研究について記す． 第 3 章では， 実験内容として， fMRI 実験とボクセル選択方法の提案手法について記す． 第 4 章では第 3 章で行った実験の結果とそれに対する考察を述べる． 第 5 章で， 本研究の結論を述べる．

## 第 2 章

# 要素技術と関連研究

### 2.1 ブレインデコーディング

ブレインデコーディングは、見ているものや体を動かしている状態などを脳活動信号とし、その情報を解読することで脳活動信号が得られたときの状態を推測することである。この技術を用いることで、脳活動を直接入力し、コンピュータやロボットを動かす BCI(Brain Computer Interface) の研究が進められている。

ブレインデコーディングの流れを以下に示す [4]。

ステップ 1 脳活動を計測し「ラベル」つける

ステップ 2 ラベルごとの脳活動パターンを学習する

ステップ 3 学習した脳活動パターンを評価する

ステップ 1 では計測した脳活動情報にそのときの状態 (見ている状態や体を動かしている状態) を「ラベル」として付加する。ステップ 2 では付加したラベルごとに、機械学習などを用いて各ラベルのパターンを学習させ、統計的モデル (デコーダ) を構築する。ステップ 3 では新たな脳情報を与えたとき構築したデコーダがラベルを正確に予測できるかを評価する。この流れで、ブレインデコーディングを行う。

この技術が BCI の実現に必要不可欠であり、言い表しにくいことであっても考えるだけでコンピュータに入力することが可能となると考える。

## 2.2 fMRI 装置

機能的磁気共鳴画像法 (functional magnetic resonance imaging, fMRI) は, MRI 装置を用いて脳神経 (ニューロン) の活動の大小 (賦活) を計測する方法である。MRI 装置の本体は, 強力な磁石の中で原子核の共鳴周波数電磁波を使い, 体内の水素原子の原子核 (プロトン=陽子) の分布を測定することにより, 体内の組織の形状や働きを測定することができる。このため, 放射線に被爆することなく非侵襲的に計測を行うことができる。この装置は静磁場コイルの内側に磁場の均一性を高めるためのシムコイルがあり, その内側には磁場の大きさを空間的に変化させる目的の傾斜磁場コイルが  $x, y, z$  軸方向にひとつずつある。さらに頭部を撮像するため RF(Radio Frequency) 波を送信, MR(Magnetic Resonance) 信号を受信する頭部専用コイルを装着し計測を行う。MR 信号はボールド効果 (図 2.1) により引き起こされる。本研究で用いた fMRI 装置の静磁場強度は 3T であり, 通常の医療機関の診療で用いられる 1.5T の装置よりも高い S/N 比の MR 信号が計測できる。この強度は地磁気 (高知では  $46 \sim 47 \mu\text{T}$ ) の数万倍以上である。このため注意しなくてはならないのは, 金属の取り扱いであり, 体内に金属が入っている場合は fMRI で計測を行うことはできない。

### ボールド (blood oxygenation-level-dependent, BOLD) 効果 [5]

通常酸素は血中のヘモグロビンと結びついており酸化ヘモグロビン (oxy-Hb) の状態で組織に運ばれている。神経細胞が活動すると酸素が消費され酸化ヘモグロビンが還元ヘモグロビン (deoxy-Hb) となる (図 2.1[定常状態])。神経細胞が活発に活動すると, 酸素の消費量が増大し, 一時酸欠状態となる (図 2.1[賦活状態])。この酸欠状態を回避するために脳血流量が急激に増大する (図 2.1[血流量増大])。この血液量の増加は神経細胞が供給された酸素を消費しきれないほどであるため排出される血液中の酸化ヘモグロビンの濃度が上昇し, 還元ヘモグロビンの濃度が相対的に低下する。酸化ヘモグロビンは反磁性体であるのに対し, 還元ヘモグロビンは常磁性体であるため, この量の差が生じることで MR 信号に変化を引き起こす。これにより, 酸化ヘモグロビン濃度が増大することで MR 信号が増強する。これをボールド効果と呼ぶ。

## 2.3 相関

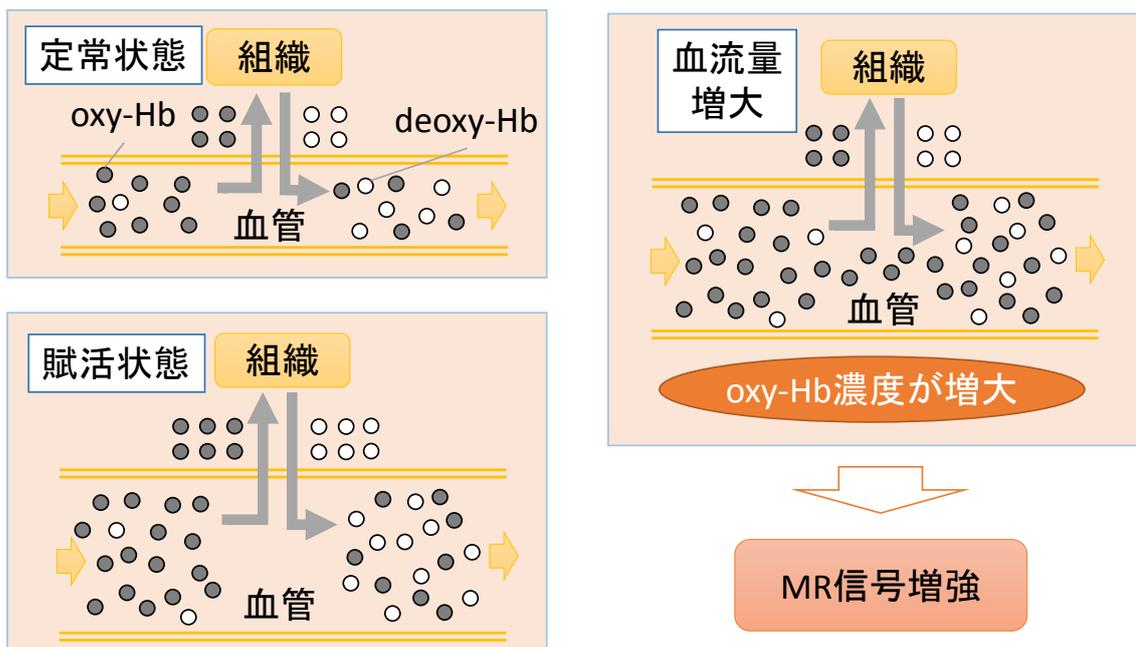


図 2.1 ボールド効果 (oxy-Hb 濃度の変化)

計測された脳活動情報は DICOM(Digital Imaging and Communications in Medicine) ファイルとして保存される。DICOM ファイルは画像ヘッダと画像データで構成されている(図 2.2)。画像ヘッダには患者の名前や画像のサイズ、撮像パラメータなどが格納されている。画像ヘッダの後に画像データがあり、この画像データの大きさはファイルの大きさからヘッダの大きさを引いたものとなる。



図 2.2 DICOM ファイルの構成

## 2.3 相関

相関とは数値データと数値データの関係のことである。相関係数は以下のように表される。

$$\text{相関係数} = \frac{\text{共分散}}{(\text{X の標準偏差})(\text{Y の標準偏差})}$$

## 2.3 相関

標準偏差は、データの分布のばらつきの程度を表す。平均値と標準偏差がわかればどの範囲にどのくらいのばらつきで分布しているかがわかる。共分散は2つの対応するデータ間の関係を表す。共分散が正のとき、 $X$  が大きければ  $Y$  も大きい傾向があるといえ、共分散が負のとき、 $X$  が大きいときに  $Y$  が小さい傾向にあるといえる。また、共分散が0に近いときは  $X$  と  $Y$  の間に関係はほとんどないといえる。相関係数  $r$  を  $X$  の標準偏差  $\sigma_X$ 、 $Y$  の標準偏差  $\sigma_Y$ 、 $X$  と  $Y$  の共分散  $\sigma_{XY}$  を用いてあらわすと式 2.1 のようになる。

$$r = \frac{\sigma_{XY}}{\sigma_X \sigma_Y} \quad (2.1)$$

$$= \frac{\frac{1}{N} \sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - \bar{X})^2} \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - \bar{Y})^2}} \quad (2.2)$$

$$= \frac{\sum_{i=1}^N (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^N (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^N (Y_i - \bar{Y})^2}} \quad (2.3)$$

ここで、 $\bar{X}$  は  $X$  の平均、 $\bar{Y}$  は  $Y$  の平均を表す。 $r$  は、 $-1 \leq r \leq 1$  の範囲の値をとる。相関係数を求めることでどの程度相関があるかがわかる。相関係数と関係の程度を表 2.1 に示す [6]。

相関係数 $r$	相関の程度
$0 \leq  r  \leq 0.2$	ほとんど相関がない
$0.2 \leq  r  \leq 0.4$	やや相関がある
$0.4 \leq  r  \leq 0.7$	かなり相関がある
$0.7 \leq  r  \leq 1.0$	強い相関がある

### 2.4 機械学習

機械学習とは人間が自然と行っているパターン認識や経験から行う活動をコンピュータを用いて実現させる技術である。訓練データからさまざまなアルゴリズムを用いることでそのデータの規則性や法則性、パターンを学習させ、学習結果を予測に活かす。機械学習の基本として、コンピュータが  $X$  と  $Y$  の関係を理解することで学習が行われる。 $X$  を入力データとし、その  $X$  に対応する  $Y$  を出力することを目的としたとき、大量の  $X$  と  $Y$  のデータを与えその 2 つのデータの間を学習させ、未知のデータを入力したときに対応するデータ  $Y$  を推定する。このような入力データ  $X$  と出力データ  $Y$  を大量に与える機械学習は教師あり学習と呼ばれる。機械学習には、ニューラルネットワーク [7] やランダムフォレスト、Sparse Logistic Regression などがあるが、本研究で用いる SVM(Support Vector Machine)[8] について解説する。

#### SVM

SVM は教師あり学習によって学習機を構成する手法のひとつであり、高次元特徴空間において線形関数の識別関数を用いて学習を行う。最適化問題を解くことでマージン(訓練サンプルから各データ点への距離)が最大になるような、訓練サンプルをできるだけ余裕を持った状態で 2 つのクラスを分ける識別平面が求められる。これにより未知のデータに対する正確な識別に期待できる。

基本的な SVM は図 2.3 に示した線形しきい素子であるが、この場合線形分離不可能なデータに対応することができない。そこでカーネルトリックを用いることで SVM で非線形的な分類を可能とする高次元を行うことができる。この方法は、元のデータを高次元特徴空間に写像(図 2.4)し、写像した特長空間内で線形分離を行う。こうすることで非線形的な分類を可能とし、高次元の入力データに対応できる。

## 2.5 クロスバリデーション

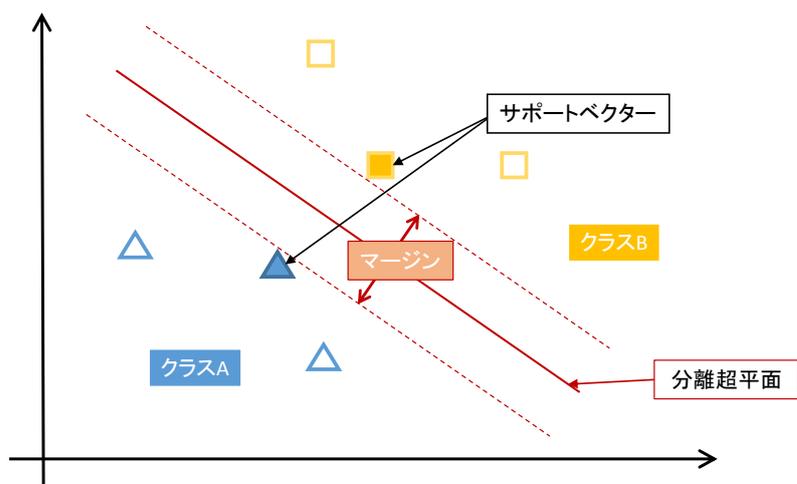


図 2.3 SVM の分離超平面

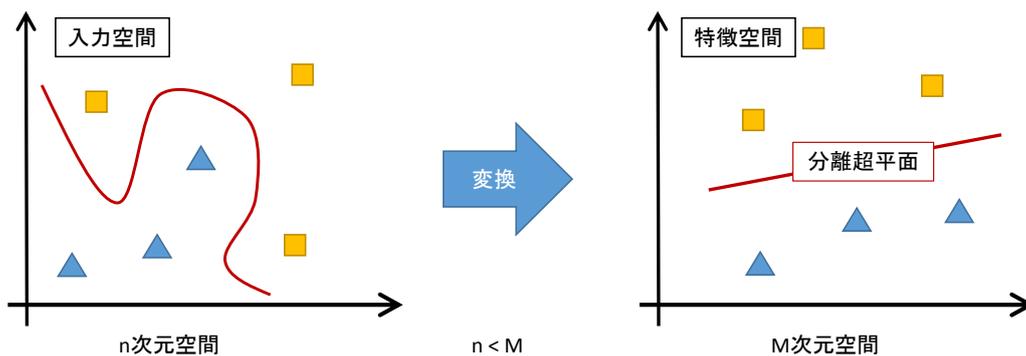


図 2.4 特徴空間の写像

## 2.5 クロスバリデーション

クロスバリデーション [8] は性能評価を行う際に用いる。図 2.5 に示すようにデータ全体を  $n$  等分し、そのうちの 1 個を評価用 (テストデータ) とし、 $n-1$  個を学習用 (学習データ) に用いる。学習データで学習し評価するためのモデルを作成、テストデータを用いてモデルを評価し、精度を求める。これを  $n$  回繰り返し、 $n$  回の平均的な性能を評価する。

## 2.6 レチノトピー

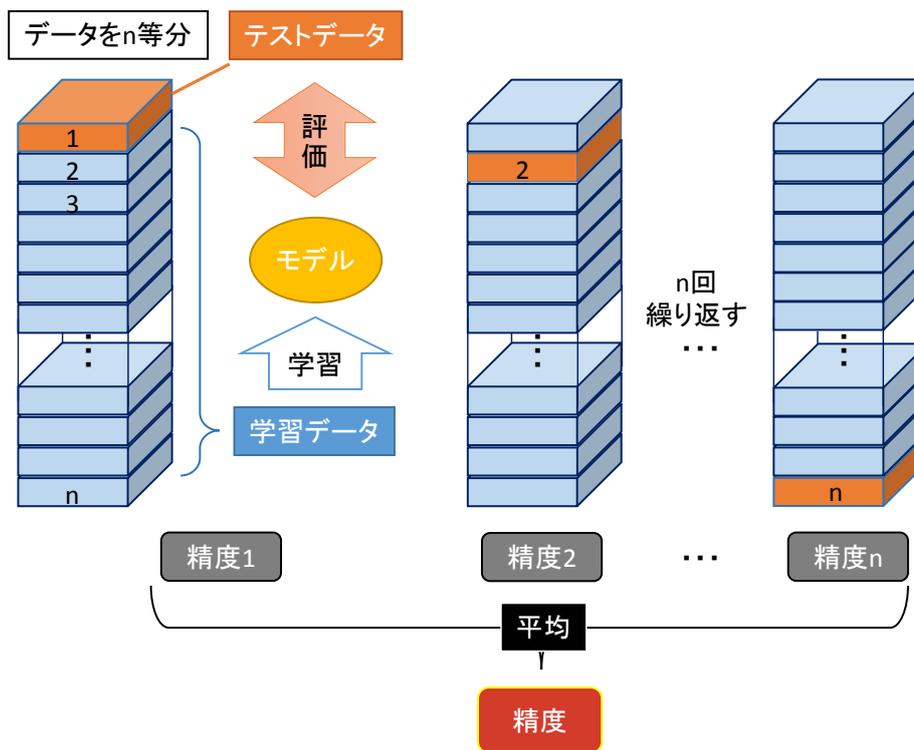


図 2.5 クロスバリデーション

## 2.6 レチノトピー

レチノトピー（網膜部位再現）[9] は視野の中心は V1 野の後部にマップされ、視野の中心から離れるにつれて前方へとマップされる。右視野は左半球にマップされ、左視野は右半球にマップされる。また、上視野は下側に、下視野は上側にマップされる。網膜上に視野で得た情報を位置関係を保ったままマップされ、視野の中心に近いほど皮質に占める割合が大きい。

## 2.7 関連研究 1

神谷らは、ブレインデコーディングの研究として、線分の傾きの識別推定を行った。被験者に図 2.6 の 4 条件 (45 °と 135 °, 白と黒の線の画像) を見せ、各画像を見ているときの脳

## 2.8 関連研究 2

活動を SVM で学習させ、デコーダを構築した。同じ被験者に図 2.7 の画像を見せた状態で 45 °か 135 °のどちらかに注目するよう指示を出す。このときの脳活動を先ほど構築したデコーダで評価する。この結果、90%を超える識別率となった。

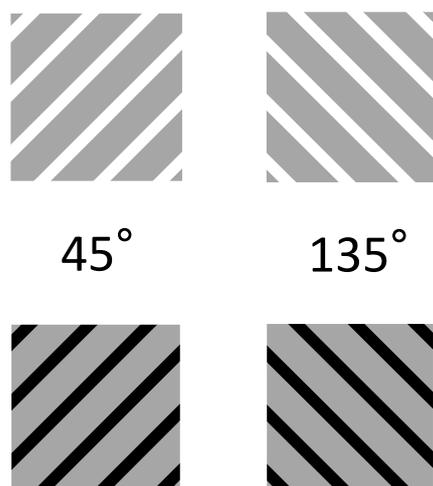


図 2.6 学習に用いた画像

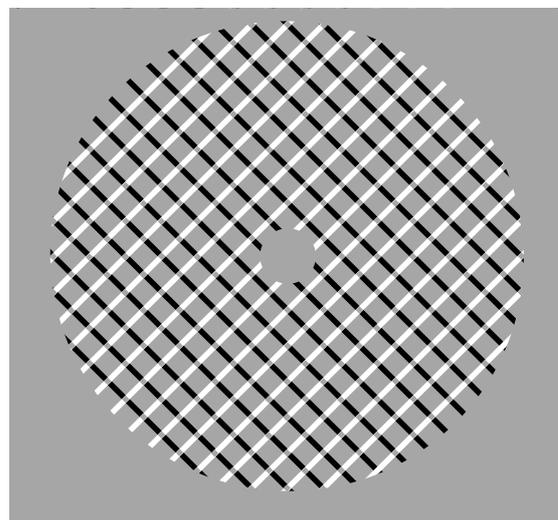


図 2.7 識別テストに用いた画像

## 2.8 関連研究 2

宮脇らは、ブレインデコーディングを用いて視覚像の再構成の研究を行った。10 × 10 の領域を設け、その 1 つずつにはランダムに 2 値 (白と黒) を表示させる。この 10 × 10、440 枚のランダムな画像を提示し、学習データとして V1 と V2 からの fMRI 信号を使用し、クロスバリデーションにより解析する。このデータは図形画像を再構成する際のモデル作成のためにも用いられる。

このデコーダを用いて、学習に用いていない 2 値図形画像や “neuron” の各文字の画像を推定し再構成に成功した。

## 第 3 章

# 実験内容

### 3.1 fMRI 実験

fMRI を用いて以下の実験を行う。測定のためのヘッドコイルにミラーを取り付け、ミラーにプロジェクターからの像を反射させ被験者の視界に納まるように調節する。ヘッドコイルには 2 種類 (12ch と 32ch) あり、12ch より 32ch の方がチャンネル数が多く、感度領域が狭くなるため、信号を得られやすくノイズの少ない脳活動が計測できる [10]。

ひとつの実験をいくつかに分けて行う。これは被験者の疲労軽減や、集中力を保つためである。本研究の 7 種類の識別実験の場合、7 種類の画像をランダムに 2 回ずつ同じ画像が連続しないよう (14 回画像が変更される) 表示し、最初と最後にレストを設けるため、合計 16 枚の画像を提示する。この 16 枚の画像の提示を 1 ランとする。

#### 被験者

6 名の被験者を対象として行う。被験者 A, B, C, E は成人男性 (右利き)、被験者 D, F は成人女性 (右利き) である。被験者は fMRI 装置についての説明、実験の内容、所要時間、安全性、個人情報保護についての説明を行い、文書にて同意を得る。

#### 計測装置と撮像パラメータ

本研究では、高知工科大学に設置されている fMRI 装置として SIEMENS 社の MAGNETOM Verio(3T) を用いる。撮像パラメータは、 $64 \times 64$ matrix, 1 ボクセルあたり  $3 \times 3 \times 4.5$ mm, フリップアングル 90 度とする。刺激提示には Presentation[11] を用いる。実験は以下の 3 種類行う。

## 3.1 fMRI 実験

### 3.1.1 実験 1

この実験では先行研究 [3] の 3 種類の図形の識別率と比較するため、7 種類の図形の識別率を明らかにすることを目的とする。

#### 被験者ごとのパラメータ

被験者 A 12ch, TR=3000ms, スライス数=36, 3 ラン

被験者 B 12ch, TR=3030ms, スライス数=47, 7 ラン

#### 提示画像

図 3.1 に実験 1 で用いた画像を示す。先行研究で用いられた画像は 3 種類、10 種類であったため、この実験では先行研究で用いられた 3 種類の図形を含む 7 種類の図形画像を用いる。各画像の白色の面積を統一する。また、rest は黒一色の画像とする。

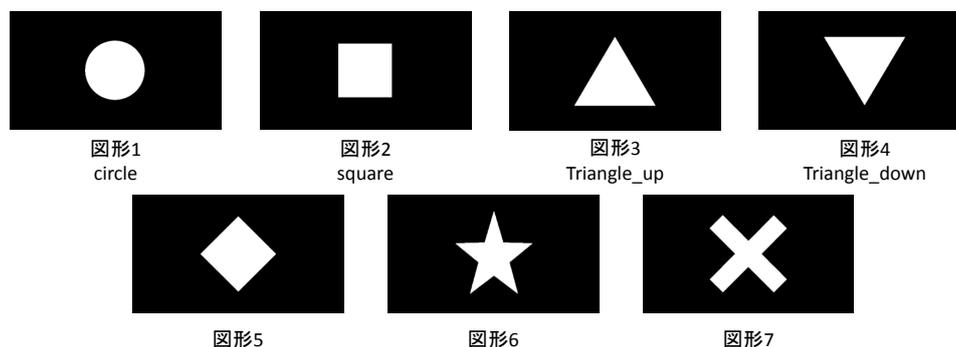


図 3.1 実験 1 での提示画像

#### 実験 1 の実験デザイン

被験者 A は 1 ラン目から 3 ラン目の 3 ラン、被験者 B は 4 ラン目から 10 ラン目の 7 ランの試行内容で実験を行う。各ランでランダムに同じ画像が続いて提示されないよう 7 種類の画像を 2 回ずつ提示する。各画像の提示時間は 12 秒とする。表 3.1 において circle=○, square=□, triangle\_up=△, triangle\_down=▽, diamond=◇, star=☆, cross=× と示す。

### 3.1 fMRI 実験

表 3.1 実験 1, 2 の実験デザイン

開始 scan 数	1	5	9	13	17	21	25	29	33	37	41	45	49	53	57	61
1 ラン目	rest	○	▽	◇	×	△	□	▽	△	*	◇	×	□	○	*	rest
2 ラン目	rest	▽	□	△	○	◇	×	□	*	▽	*	△	○	◇	×	rest
3 ラン目	rest	◇	*	×	△	○	□	▽	○	□	×	*	▽	◇	△	rest
4 ラン目	rest	□	△	*	×	▽	○	◇	×	△	▽	□	◇	*	○	rest
5 ラン目	rest	*	△	▽	◇	×	○	□	*	△	□	○	▽	×	◇	rest
6 ラン目	rest	□	△	◇	○	▽	*	×	○	*	×	▽	△	◇	□	rest
7 ラン目	rest	◇	□	△	○	*	×	▽	△	◇	▽	×	□	*	○	rest
8 ラン目	rest	◇	▽	×	△	○	*	□	▽	○	×	◇	*	□	△	rest
9 ラン目	rest	▽	◇	○	△	*	□	×	□	×	▽	○	△	*	◇	rest
10 ラン目	rest	△	○	×	□	▽	◇	*	△	×	*	○	□	◇	▽	rest

#### 3.1.2 実験 2

この実験では撮像パラメータを 3 種類用意し、同じ実験デザインで実験することにより、撮像パラメータの違いでの差を明らかにすること、また、提示画像をチェッカーにし、視覚刺激を強くしたときの識別率の差を明らかにすることを目的とする。

##### 被験者 C のパラメータ

32ch, TR=3000ms, スライス数=45, 5 ラン

32ch, TR=1000ms, スライス数=45, 5 ラン

12ch, TR=3000ms, スライス数=45, 5 ラン

##### 提示画像

### 3.1 fMRI 実験

図 3.2 に実験 2, 3 で用いた画像を示す．実験 1 で提示した図形画像の白い部分を白黒のチェッカー状にし，チェッカーの部分をも 0.5 秒ごとに反転させることで視覚により刺激を与える．また，rest は黒一色の画像とする．

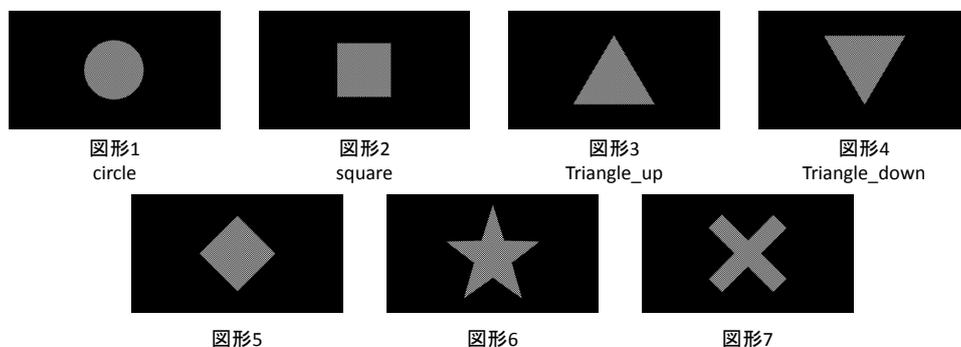


図 3.2 実験 2 での提示画像

図 3.3 にチェッカー状の部分の拡大を示す．

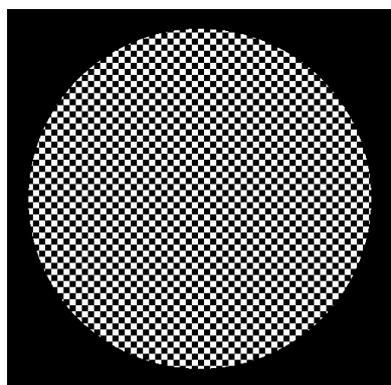


図 3.3 提示画像拡大

#### 実験 2 の実験デザイン

被験者 C は表 3.1 の 1 ラン目から 5 ラン目の試行内容で実験を行う．各ランでランダムに同じ画像が続いて提示されないよう 7 種類の画像を 2 回ずつ提示する．各画像の提示時間は 12 秒とし，0.5 秒ごとにチェッカーの部分をも反転させたものを提示する．例として，circle の画像のチェッカーの部分の反転前を circle1，反転後を circle2 としたと

### 3.1 fMRI 実験

きのデザインを図 3.4 に示す。

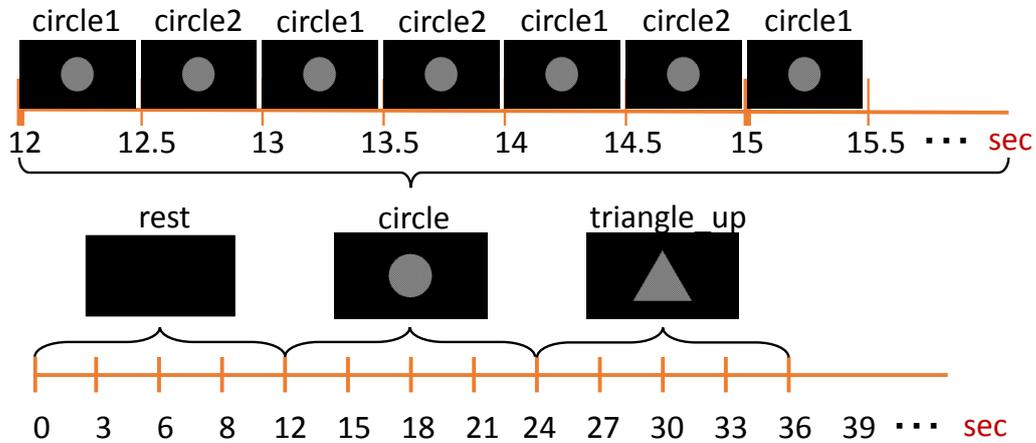


図 3.4 実験デザイン (0.5 秒ごとにチェッカー反転)

#### 3.1.3 実験 3

この実験では、先行研究 [3] で行われた 3 種類の図形識別と比較し、刺激画像をチェッカーにし、画像と画像の間に rest を設けたときの識別率を比較し差を明らかにすることを目的とする。

##### 被験者ごとのパラメータ

被験者 D 32ch, TR=3030ms, スライス数=47, 8 ラン

被験者 E 32ch, TR=3000ms, スライス数=45, 8 ラン

被験者 F 32ch, TR=3000ms, スライス数=45, 8 ラン

##### 実験 3 の実験デザイン

被験者 D, E, F それぞれ 1 ラン目から 8 ラン目の試行内容で実験を行う。各ランでランダムに同じ画像が続いて提示されないよう 3 種類の画像を 2 回ずつ提示する。表 3.2 においても circle=○, square=□, triangle\_up=△ と示す。

### 3.2 SPM によるデータ解析

表 3.2 実験 3 の実験デザイン

開始 scan 数	1	5	9	13	17	21	25	29	33	37	41	45	49
1 ラン目	rest	△	rest	○	rest	□	rest	○	rest	△	rest	□	rest
2 ラン目	rest	○	rest	△	rest	□	rest	○	rest	□	rest	△	rest
3 ラン目	rest	□	rest	△	rest	○	rest	△	rest	□	rest	○	rest
4 ラン目	rest	○	rest	△	rest	○	rest	□	rest	△	rest	□	rest
5 ラン目	rest	□	rest	△	rest	○	rest	□	rest	○	rest	△	rest
6 ラン目	rest	□	rest	○	rest	△	rest	○	rest	□	rest	△	rest
7 ラン目	rest	□	rest	○	rest	△	rest	○	rest	△	rest	□	rest
8 ラン目	rest	○	rest	△	rest	□	rest	△	rest	○	rest	□	rest

### 3.2 SPM によるデータ解析

SPM(Statistical Parametric Mapping) は Functional Imaging Laboratory, University College London のメンバーによって開発された統計画像解析パッケージであり, MALTLAB[12] 上で動作し脳機能画像の解析を行うことが可能である. fMRI 実験 1, 2, 3 によって得られた脳画像データを解析し, 賦活部位を特定する. 解析には, SPM8[13], SPM5[14] を用いる. fMRI から得られたデータは DIOCOM 形式で保存されているため, MRIConvert[15] を用いて Analyze 形式に変換し, SPM で処理を行う. まず, データの前処理として, Realignment(fMRI データの動きの補正), Slice timing correction(時間の補正), Normalization(fMRI データの標準脳への変換), Smoothing(Normalization 後の fMRI データの空間的平滑化) の順に行う. その後, はじめの 2 スキャン分はノイズが含まれるため, 除去し個人解析に入る.

個人解析では, 各条件での脳の賦活部位を求めるために, 統計的検定を行う. 条件 ( $l$ ) に

### 3.3 BDTB によるデコーディング

比べて条件 ( $k$ ) で有意に高い活動を示す脳の部位を求めるために、帰無仮説  $H_0 : \beta_k > \beta_l$  について検定する。本研究では統計的検定に  $t$  検定 (有意水準 0.001) を用いる。先行研究と比較するため検定後、単純な視覚特徴や輪郭、形に対して働きを持つブロードマンの 17, 18, 19 野のみに注目し結果を出力する。出力には閾値と、 $t$  値、 $z$ -score、賦活ボクセルのクラスタ、クラスタ内のボクセル数、賦活ボクセルの 3 次元座標が得られる。また、 $z$ -score の大きいボクセルから順に濃淡画像として示される。 $z$ -score が大きいボクセルを含むクラスタを関心領域 (ROI, region of interest) とする。

### 3.3 BDTB によるデコーディング

BDTB(Brain Decoder Toolbox)[16] は ATR 脳情報研究所 神経情報学研究室のメンバーによって開発された、MATLAB 上で動作する脳活動をデコーディングするための関数群である。各条件における脳活動のパターンの違いを学習し、その学習結果を用いて脳活動を分類することで脳活動のデコーディングを行う。SPM でのデータ解析で得られた ROI を用いて SVM(Support Vector Machine) の線形カーネルで学習を行い、ラン単位で分割したクロスバリデーションを行い評価する。

### 3.4 ボクセル選択提案手法

ボクセル選択の提案手法の手順を図 3.5 から図 3.8(被験者 C の場合) に示す。

#### (1) DICOM ファイルを CSV に変換する

このとき、1 スキャンで 1 枚得られる脳画像 ( $448 \times 448 \text{pixel} = 200704$ ) を 1 行の輝度値データとする。このように 65 スキャン  $\times$  5 ラン = 325 枚の画像を変換し、ひとつにまとめる。変換後は  $325 \times 200704$  の数値データとなる。変換は被験者もしくは条件ごとに作成する。

#### (2) 教師データを作成し、(1) に付加する

教師データを数値で表すために、0:rest, 1:circle, 2:square, 3:triangle\_up, 4:trian-

### 3.4 ボクセル選択提案手法

gle\_down, 5:diamond, 6:star, 7:cross とする．各行に対応する教師データを各行の最後の列に付加する．教師データ付加後は  $325 \times 200705$  の数値データとなる．

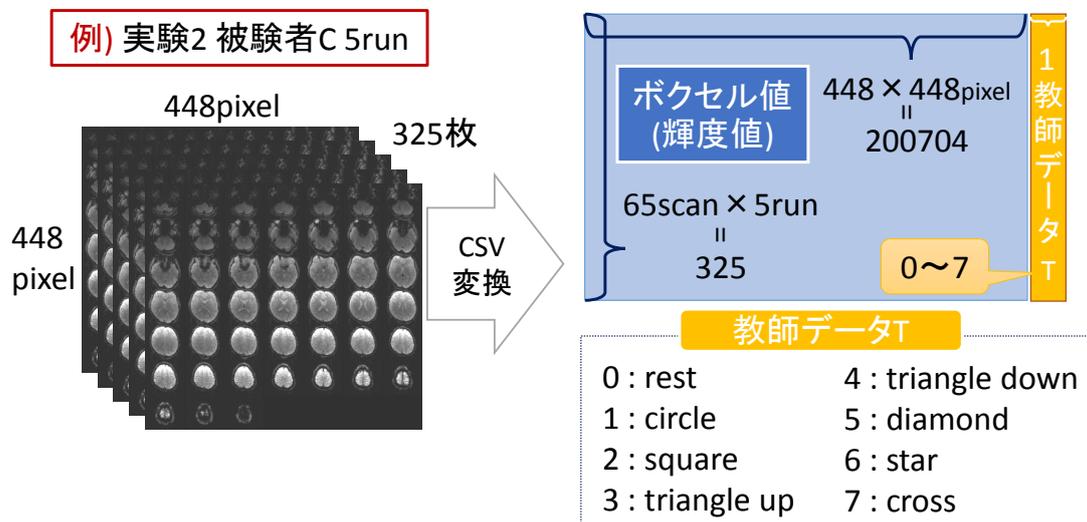


図 3.5 提案手法の手順 (1)(2)

#### (3) 教師データを 1, -1 に置き換える

教師データの置き換えを提案手法 1 と提案手法 2 で行う．提案手法 1 では，あるクラス  $k$  を 1 としたとき  $k$  以外のクラスを  $-1$  とする．これをすべてのパターン行くと 7 通りとなる．提案手法 2 では，あるクラスを 1，別のもうひとつのクラスを  $-1$  とし，その他のクラスは使用しない．これをすべてのパターン行くと 21 通りとなる．

### 3.4 ボクセル選択提案手法

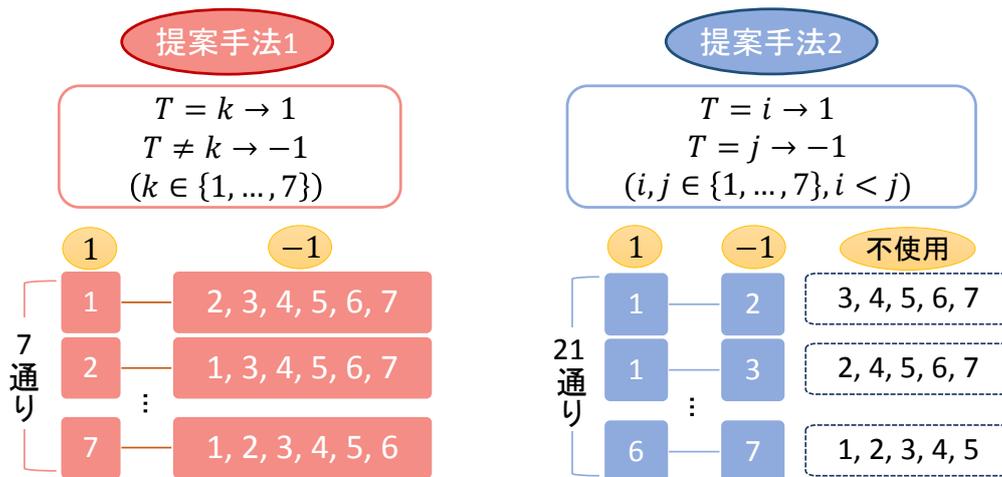


図 3.6 提案手法の手順 (3)

#### (4) 教師データと各列で相関係数を求める

データの 1 列目と教師データでの相関係数の絶対値を  $r_1$  とし, データの 2 列目と教師データでの相関係数の絶対値を  $r_2$ , これを全列分 ( $r_{200704}$  まで) 行う. 算出された相関係数は 1 行の配列  $R_1$  に格納する. これを各手法での組み合わせの数  $n$  回行い,  $R_1$  から  $R_n$  を生成する.



図 3.7 提案手法の手順 (4)

#### (5) 相関係数の配列の平均を $R$ とし, 降順にソートする

$R_1$  から  $R_n$  までの平均をとり,  $R$  とする. その後,  $R$  を降順にソートする.

#### (6) 上位 1 ~ 10000 の特徴量で識別率を算出する

### 3.4 ボクセル選択提案手法

上位 1 個の特徴量を用いたときの識別率から，10000 個の特徴量を用いたときまでの識別率を算出する．

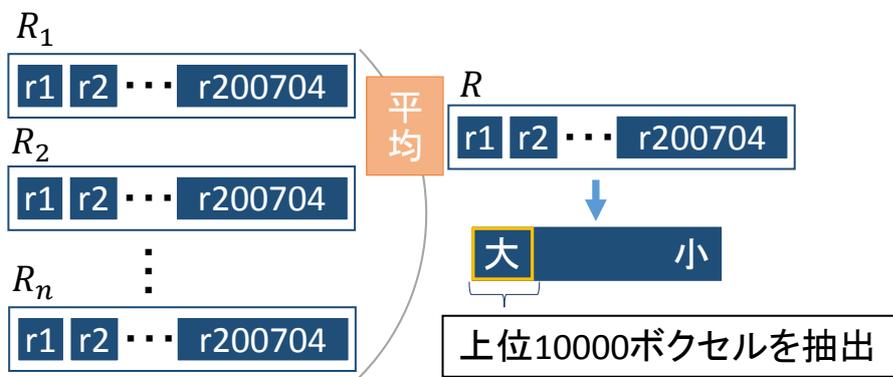


図 3.8 提案手法の手順 (5)(6)

## 第 4 章

# 結果と考察

### 4.1 BDTB を用いた識別率

BDTB を使用したときの各被験者の最大賦活ボクセルを含むクラスタのボクセル数と識別率を表 4.1, 表 4.2 に示す.

#### 4.1.1 7 種類の図形識別

表 4.1 用いたボクセル数と識別率

被験者	ボクセル数	識別率 (%)
被験者 A	84	7
被験者 B	200	15
被験者 C-1	200	37
被験者 C-2	200	10
被験者 C-3	200	19

表 4.1 より, 被験者 A はチャンスレベル (14%) に満たず, 被験者 B はチャンスレベルを 1 ポイント上回る程度である. 被験者 C-1 は, 37%とチャンスレベルの 2 倍近い識別率であるのに対して, 被験者 C-2 はチャンスレベル以下, C-3 はチャンスレベルより 5 ポイント高い識別率となっている.

被験者 A は 3 ラン, 被験者 B は 7 ラン実験を行ったためサンプル数の違いが影響し手い

## 4.2 提案手法を用いた識別率

ると考える。サンプル数が多い方が識別率が高くなることがわかる。実験 2 被験者 C に関しては、提示画像はチェッカーであるため、刺激が強くなっている。このため実験 1 の 12ch, TR3000 と同じ条件の C-3 は実験 1 の被験者 A と被験者 B のどちらよりも高い識別率となったと考える。被験者 C の撮像パラメータの違いでの識別率の差は C-1 がもっとも識別率がよく、C-2 がもっとも悪い結果となっている。このことから TR が長いよりもチャンネル数が大きいほうが図形識別には適していることがわかる。C-2 は TR が 1000 であるため、脳が反応するまでに撮像してしまうことが原因で識別率が低くなったと考える。

### 4.1.2 3 種類の図形識別

表 4.2 用いたボクセル数と識別率

被験者	ボクセル数	識別率 (%)
被験者 D	36	31
被験者 E	200	48
被験者 F	200	52

表 4.2 より、被験者はチャンスレベル (33%) に 2 ポイント及ばなかったが、被験者 E, F はそれぞれチャンスレベルより 15 ポイント、19 ポイント高い識別率となっている。被験者 D の識別率を算出する際に用いたボクセルが被験者 E, F よりも少なく被験者 E, F より低い識別率となった。ボクセルを選択する際に少ないボクセル数の場合、必要な情報を取り込みきれないため低い識別率となったと考える。また、パラメータは 3 被験者ともに同じであるため、個人差による識別率の違いが現れたと考える。

## 4.2 提案手法を用いた識別率

### 4.2.1 7 種類の図形識別

すべてのボクセルを用いたときの識別率を表 4.3 に示す。

## 4.2 提案手法を用いた識別率

表 4.3 すべてのボクセルを用いたときの識別率とそのボクセル数

被験者	ボクセル数	識別率 (%)
被験者 A	147456	16
被験者 B	200704	25
被験者 C-1	200704	28
被験者 C-2	200704	31
被験者 C-3	200704	24

提案手法 1 の結果としてそれぞれの識別率の変化を図 4.1 に示す。

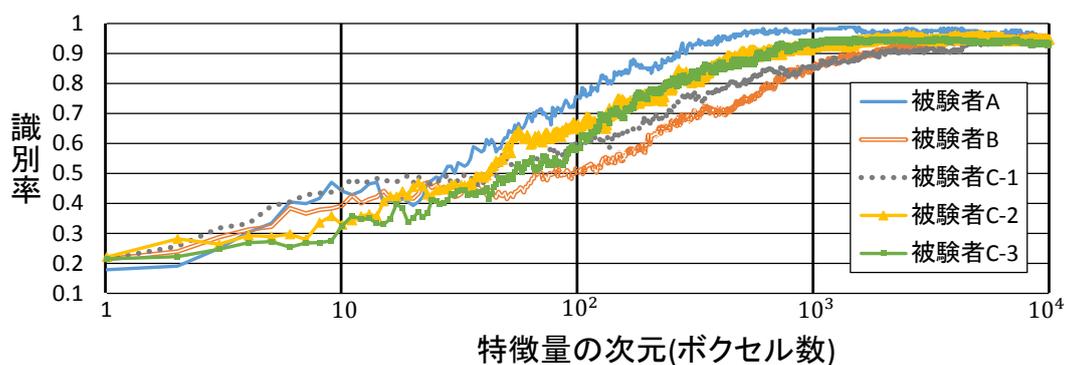


図 4.1 特徴の次元に対する識別率の変化

提案手法 2 の結果としてそれぞれの識別率の変化を図 4.2 に示す。

## 4.2 提案手法を用いた識別率

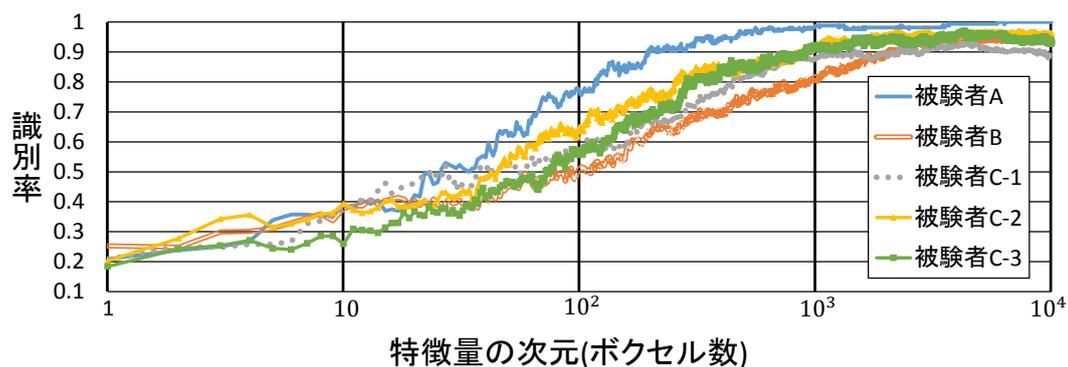


図 4.2 特徴の次元に対する識別率の変化

提案手法ごとの平均識別率の変化を図 4.3 に示す。

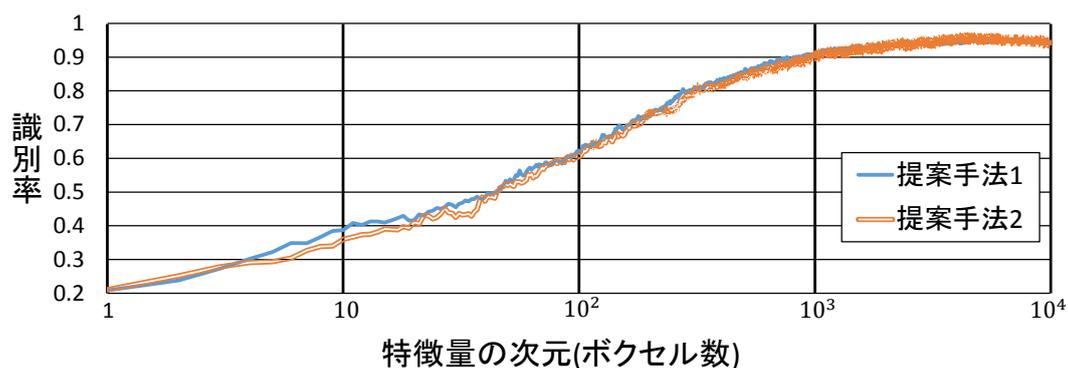


図 4.3 特徴の次元に対する平均識別率 提案手法の比較

提案手法 1 で識別に用いた上位 10 ボクセルの相関係数を表 4.4 に示す。

## 4.2 提案手法を用いた識別率

表 4.4 平均相関係数の上位 10 ボクセルの各組み合わせでの相関係数

上位のボクセル	1	2	3	4	5	6	7	8	9	10
1-それ以外	0.13	0.09	0.08	0.02	0.07	0.07	0.08	0.06	0.19	0.07
2-それ以外	0.08	0.08	0.06	0.03	0.04	0.07	0.01	0.01	0.13	0.16
3-それ以外	0.08	0.11	0.12	0.08	0.1	0.11	0.12	0.22	0.13	0.05
4-それ以外	0.12	0.13	0.07	0.1	0.01	0.06	0.18	0.08	0.05	0.12
5-それ以外	0.15	0.09	0.13	0.09	0.11	0.05	0.07	0.02	0.11	0.08
6-それ以外	0.22	0.11	0.08	0.25	0.27	0.12	0.13	0.3	0.05	0.21
7-それ以外	0.04	0.15	0.22	0.18	0.14	0.24	0.13	0.03	0.05	0.02
平均値	0.12	0.11	0.11	0.11	0.11	0.10	0.10	0.10	0.10	0.10

提案手法 2 で識別に用いた上位 10 ボクセルの相関係数を表 4.5 に示す。

## 4.2 提案手法を用いた識別率

表 4.5 平均相関係数の上位 10 ボクセルの各組み合わせでの相関係数

上位のボクセル	1	2	3	4	5	6	7	8	9	10
1-2	0.1	0.15	0.08	0.31	0.21	0.3	0.35	0.13	0.29	0.12
1-3	0.37	0.21	0.15	0.31	0.28	0.18	0.13	0.23	0.06	0.07
1-4	0.04	0.11	0.11	0.02	0.02	0.1	0.02	0.16	0.09	0.41
1-5	0.1	0.06	0.09	0.36	0.06	0.2	0.14	0.42	0.09	0.02
1-6	0.35	0.3	0.35	0.11	0.26	0.22	0.19	0.3	0.29	0.27
1-7	0.17	0.29	0.29	0.28	0.46	0.14	0.01	0.06	0.23	0.37
2-3	0.27	0.07	0.08	0	0.09	0.14	0.24	0.11	0.29	0.16
2-4	0.14	0.05	0.19	0.29	0.17	0.37	0.41	0.02	0.32	0.29
2-5	0.01	0.21	0.18	0.08	0.24	0.09	0.24	0.28	0.19	0.08
2-6	0.4	0.45	0.3	0.35	0.04	0.43	0.5	0.17	0.46	0.18
2-7	0.04	0.14	0.23	0.08	0.26	0.2	0.41	0.2	0.42	0.23
3-4	0.41	0.12	0.26	0.29	0.25	0.26	0.17	0.1	0.03	0.39
3-5	0.24	0.25	0.24	0.09	0.31	0.04	0	0.16	0.13	0.07
3-6	0.57	0.46	0.22	0.35	0.05	0.34	0.32	0.05	0.21	0.29
3-7	0.27	0.05	0.14	0.07	0.16	0.05	0.17	0.3	0.14	0.35
4-5	0.14	0.17	0.02	0.34	0.07	0.27	0.18	0.29	0.16	0.34
4-6	0.32	0.43	0.46	0.13	0.22	0.13	0.19	0.16	0.19	0.07
4-7	0.21	0.2	0.41	0.26	0.41	0.23	0.02	0.25	0.11	0.08
5-6	0.37	0.25	0.45	0.39	0.29	0.35	0.33	0.12	0.33	0.23
5-7	0.02	0.34	0.4	0.16	0.46	0.09	0.17	0.51	0.27	0.3
6-7	0.47	0.57	0.1	0.33	0.23	0.32	0.21	0.38	0.09	0
平均値	0.24	0.23	0.23	0.22	0.22	0.21	0.21	0.21	0.21	0.21

各提案手法で、実験パラメータの違いや個人差によってそれぞれの識別率に多少のばらつき

## 4.2 提案手法を用いた識別率

きはあるが，上昇および下降するタイミングはほぼ同様の結果である (図 4.1, 図 4.2)．被験者 A と被験者 B の差に関しては，被験者 A はサンプル数が少なく，被験者 B はサンプル数が多いため識別率が上昇する早さに差が出たと考える．被験者 C に関しては 10000 個のボクセルを用いるとき実験パラメータの違い (3 種類) による差はほとんどなく，提案手法ではパラメータの違いでは大きな違いは表れない．

各手法で 1 ボクセルを用いたとき 20%，5000 ボクセルを用いたとき最大 95% となっている．5000 ボクセルを超えると識別率が下降している．識別率のピークがくるまでは上昇し，ピークを超えると図形識別に適さないボクセルを用いることになるため，識別率は下降していくと考える．図 4.3 より，7 種類の図形を識別するとき，2 手法双方で識別率のピークがくるまでは上昇し，ピークを超えると図形識別に適さないボクセルを用いることになるため，識別率は下降していくと考える．

表 4.4 より，提案手法 1 で識別に用いた相関係数の平均値の上位 10 ボクセルの相関係数から，それぞれの相関係数での最大値は 0.3 であり，最小値は 0.01 であることがわかる．これに対して，提案手法 2 で識別に用いた相関係数 (4.5) の最大値は 0.57 であり，最小値は 0 である．それぞれのボクセルごとに相関係数の平均をとると，提案手法 2 は提案手法 1 と比べ 2 倍ほどの値となっている．また，提案手法 1 ではそれぞれの組み合わせでの相関係数は小さい値であるが，各組み合わせの間に大きな差はなく，提案手法 2 ではそれぞれの組み合わせで大きく差がある．これら 2 手法の相関係数に差が見られるものの，識別率に関してほぼ差はないといえる．これより，それぞれの手法で相関を求め，それぞれの間には差がある場合でも平均を求めることで平均的に相関の高いボクセルを選択できたため，7 種類の図形を識別するのにどちらの方法も同様の結果となったと考える．

### 4.2.2 3 種類の図形識別

すべてのボクセルを用いたときの識別率を表 4.6 に示す．

## 4.2 提案手法を用いた識別率

表 4.6 すべてのボクセルを用いたときの識別率とそのボクセル数

被験者	ボクセル数	識別率 (%)
被験者 D	200704	48
被験者 E	200704	39
被験者 F	200704	40

提案手法 1 の結果としてそれぞれの識別率の変化を図 4.4 に示す。

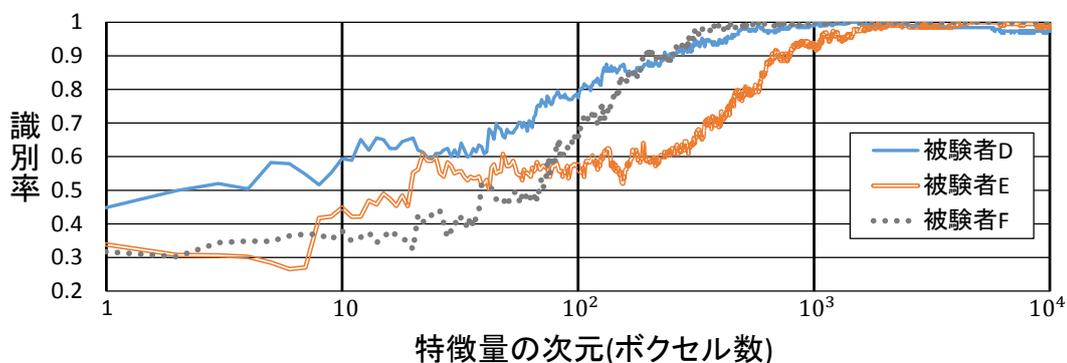


図 4.4 特徴の次元に対する識別率の変化

提案手法 2 の結果としてそれぞれの識別率の変化を図 4.5 に示す。

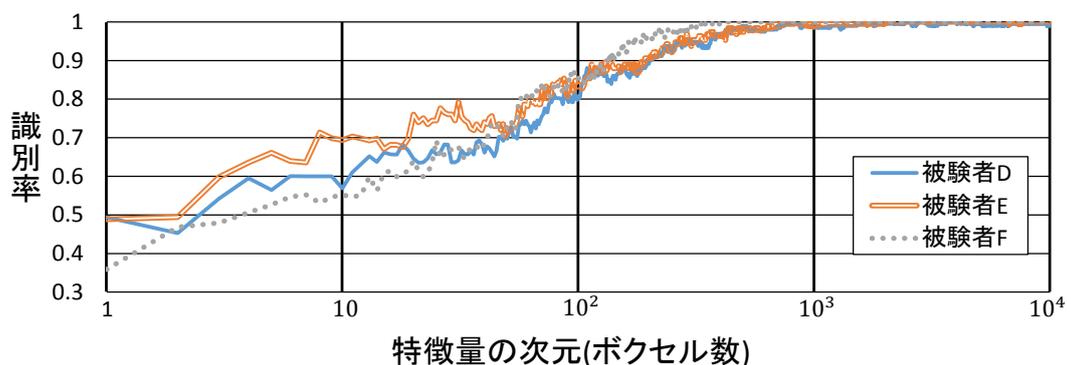


図 4.5 特徴の次元に対する識別率の変化

提案手法ごとの平均識別率の変化を図 4.6 に示す。

## 4.2 提案手法を用いた識別率

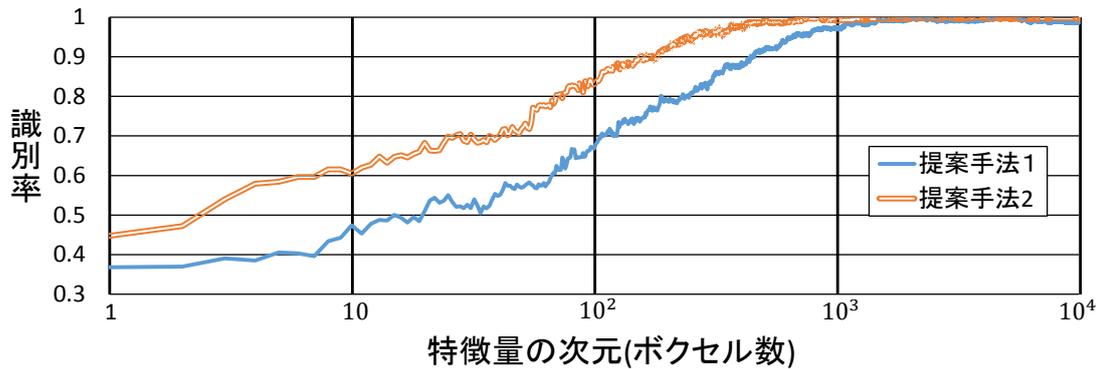


図 4.6 特徴の次元に対する平均識別率 提案手法の比較

提案手法 1 で識別に用いた上位 10 ボクセルの相関係数を表 4.7 に示す。

表 4.7 平均相関係数の上位 10 ボクセルの各組み合わせでの相関係数

上位のボクセル	1	2	3	4	5	6	7	8	9	10
1-それ以外	0.29	0.22	0.25	0.19	0.22	0.18	0.18	0.21	0.12	0.16
2-それ以外	0.2	0.22	0.21	0.19	0.22	0.23	0.23	0.2	0.24	0.24
3-それ以外	0.18	0.2	0.16	0.23	0.16	0.17	0.18	0.17	0.22	0.17
平均値	0.22	0.21	0.21	0.20	0.20	0.19	0.20	0.19	0.19	0.19

表 4.8 平均相関係数の上位 10 ボクセルの各組み合わせでの相関係数

上位のボクセル	1	2	3	4	5	6	7	8	9	10
1-2	0.07	0.13	0.01	0.18	0.28	0.16	0.09	0.39	0.13	0.1
1-3	0.53	0.46	0.48	0.48	0.18	0.41	0.33	0.24	0.4	0.32
2-3	0.48	0.33	0.42	0.25	0.41	0.28	0.42	0.2	0.28	0.37
平均値	0.36	0.31	0.30	0.30	0.29	0.28	0.28	0.28	0.27	0.26

図 4.6 より提案手法 1 では 2000 ボクセルを用いたとき 99%でピークを迎え，2000 ボクセル以上を用いたところ識別率は下降することがわかる．これに対し，提案手法 2 では 250

## 4.2 提案手法を用いた識別率

ボクセルを用いたとき 95%を超えており，515 ボクセルで 99%を超え，2110 ボクセルを用いたとき最大値 100 %となっている．図 4.7 より，提案手法 1 での各組み合わせでの相関係数は，最大 0.29，最小 0.12 である．これに対し，提案手法 2 での相関係数は，最大 0.53，最小 0.01 である．3 種類の図形を識別する際，提案手法 1 ではどの組み合わせでも 3 種類の画像を考慮した相関を求めているため，あまり差はないが，提案手法 2 では，各組み合わせで 1 つのラベルは用いずに相関を求めているため，平均の上位を選択すると 3 つの組み合わせ中 2 つの組み合わせで相関係数が大きく，もうひとつの相関係数は小さいボクセルが含まれている．この結果，3 分の 2 のクラスを用いて求めた提案手法 2 の方が，すべてを考慮して求めた提案手法 1 よりも 3 種類の図形識別に有効なボクセル選択が可能だといえる．

7 種類のときの各提案手法の組み合わせでは提案手法 1 では 6 通りに各ラベルが含まれているため 7 種類の図形識別の際の提案手法 1 と提案手法 2 の差はほぼないと考えられる．これに対して，3 種類の図形識別の場合提案手法 2 では，3 分の 2 のクラスを用いて相関を求めることで相関係数の値が大きいものが選択されたため，提案手法 1 と差が見られたのだと考えられる．これより，7 種類の図形識別には双方の提案手法どちらも差はないが，3 種類の図形識別には提案手法 1 よりも提案手法 2 の方が有効なボクセル選択が可能であることが確認できた．

ただし，本研究の結果は，識別率が 100%となる場合もあり，次元の高さによる影響が考えられるので，乱数による同次元同サンプルの議事データにて学習識別を行った結果，100 次元で 75%，650 次元で 100%の識別率となった（付録 A）．このことから，本手法の有効性については，更なる検証が必要と考える．

また，この結果の相関の高いボクセルには低次視覚野も含まれており，網膜上の像が低次視覚野の活動に強く影響するレチノトピーが識別に影響した可能性もあると考える．

## 第 5 章

# 結論

BCI による画像検索の実現に向けて、ブレインデコーディングを行うにあたり、画像の差異の基礎となる単純な図形の識別を脳活動から行う。その際に、識別に用いるボクセル選択をする必要があり、そのボクセル選択の方法を検討した。実験として 7 種類の画像、7 種類の画像 (チェッカー)、3 種類の画像 (チェッカー) の実験を計 6 名の被験者で行い脳活動を測定した。この脳活動情報を用いたボクセル選択の方法として DICOM データを CSV ファイルに変換しラベルと画像のボクセル値の相関を求め、相関係数が大きかったボクセルを特徴量として用いた。相関係数を求める際の組み合わせを提案手法 1(7 種類の場合 7 通り、3 種類の場合 3 通り) と提案手法 2(7 種類の場合、 ${}_{7}C_{2}(21)$  通り、3 種類の場合、 ${}_{3}C_{2}(3)$  通り) をそれぞれ用いて識別率を算出した。7 種類と 3 種類の画像を機械学習アルゴリズムには SVM の線形カーネルを用い、3 フォールドのクロスバリデーションで評価した。結果として、7 種類の図形識別に関しては、各提案手法で同様の結果となり、相関係数が大きい上位 1000 個のボクセルを用いることで識別率が 95% となる。また、3 種類の図形識別に関しては、提案手法 2 の方が図形識別に有効なボクセルを選択でき、515 ボクセルで 99% を超えることを確認している。

今後、より多くのサンプルを用いてデコーダを作成し今回用いた 7 種類、3 種類以外の図形に対応するボクセルの選択などを検証する必要がある。

本研究では相関を用いてボクセルを選択したが、用いた脳画像の中には脳以外の部分も含まれており、その部分が識別に用いられることがあるため、今後の課題として、用いる脳画像から脳の部分だけに絞った状態でボクセル選択を行う必要がある。また、脳は一つ一つ確立しているわけではなく繋がっているため、相関が高いとされるボクセルの周りのボクセル

も識別に有効であると考え、相関を求めることによって選択されたボクセルの周りのボクセルを用いて識別することは、今回求めた相関の上位 1000 個のボクセルを用いるよりも、相関係数の上位低次元のボクセルに対して周りのボクセルを同時に選択することで図形識別に適したボクセル選択ができると考え、今後の課題とする。

# 謝辞

本研究を進めるにあたり，終始丁寧なご指導いただきました高知工科大学 情報学群 吉田真一准教授に心より感謝いたします。本研究を進める際には，非常に多くの時間を割いていただきました。何度も研究の方向性に関しての相談に応じてくださり，吉田先生の的確なアドバイスにより研究の方向性も定まり，非常に面白い研究ができたと感じております。また，この論文が執筆し終えることができたのも，なかなかまとまらなかった論文に関して丁寧にご指導くださったおかげだと感謝しています。吉田先生には，研究室配属の相談や就職活動の相談にも丁寧にに応じてくださり，人生の選択という重要な場面で貴重なお話を伺えたことがより良い選択に繋がったと感じております。そして私自身の大学生活の中心となった吉田研究室に配属していただいたことに深く感謝いたします。研究室活動では，輪講や他研究室との合同セミナー，数多くの学会への参加など数え切れないほどの経験をさせていただきました。このさまざまな経験はこれからの人生で味方となってくれると思います。貴重な経験の機会をいただき経験させていただいたことに感謝いたします。

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 福本昌弘教授，並びに繁樹博昭准教授に深く感謝いたします。福本先生には，研究の面では貴重なご意見をいただきました。また，研究室活動でもアドバイスをいただいたり，至らない点をご指摘いただき大変勉強になりました。繁樹先生には，研究を行う際に実験の刺激画像について貴重なご意見をいただきました。脳の働きや視覚に関する的確に指摘していただき，視野を広げて研究を行うことができたと思います。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。

高知工科大学 脳コミュニケーション研究センターの方々には fMRI 実験を行う際，機器を使用させていただきました。いつも実験室は快適で実験しやすい環境が整えられており，良い環境で実験させていただきましたこと，深く感謝いたします。

同研究室の皆様にもお世話になりました。私の研究室生活が充実したのも，研究室の皆様

## 謝辞

のおかげです。たくさんイベントを行い、その都度親交が深まり、とても仲の良い研究室であったと感じています。特に共に研究室活動を行ってきた4年生の、江木史也氏、奥村順哉氏、奥山晃平氏、高橋宏和氏、竹中浩貴氏、矢野修平氏、山本朋依氏の存在は大きいものであったと感じております。

江木氏とは、笑うタイミングが似ていて、たくさんのお話の中でよくわからないことで一緒に笑い合い、楽しかったです。奥村氏は、寛大な心の持ち主で、いつも落ち着きを保っており、何度もその落ち着きに助けられました。奥山氏は、私が知らない専門用語を発する度に、その意味を説明していただき、非常に勉強になりました。この教えていただいた用語を使うときがくることを楽しみにしています。高橋氏は、意外な面もあり、会話のテンポや笑うタイミング、食事の時間など新鮮なことが多く、楽しかったです。竹中氏は、よく楽しい話をしてくれました。次々と出てくる面白い発想に何度もお腹を抱えました。矢野氏は、寡黙なのかと思っていましたが、話すと面白いことをさりげなく言うという技をお持ちで、笑わせていただきました。山本氏は、いつも明るく、面白い話をたくさん聞かせていただきました。また、いつも私たちの先頭を歩き、引っ張って行っていただきました。

そして、研究室活動および、研究に関して多くのアドバイスやご指摘をいただきました。小池規伎氏、藤森夏輝氏、松尾達郎氏に深く感謝いたします。林氏には、短い間でしたが、積極的に話しかけていただき嬉しかったです。また、英語を聞くという非日常的な時間は楽しく過ごすことができました。3年生の皆様は、いつも明るく活動的で頼りになる、個性あふれる後輩でした。楽しいお話に参加させていただき、たくさん笑わせていただき感謝いたします。これからより良い研究室を作り上げ、充実した生活を送られることを祈っています。

そして、最後に4年間遠い高知の地で学ぶ機会を与えていただき、慣れない独り暮らし生活を暖かく見守り、支え、応援していただいた家族に心より感謝いたします。また、4年間支えていただきました皆様に感謝の意を表し、御礼申し上げます。

## 参考文献

- [1] Yukiyasu Kamitani & Frank Tong, “Decoding the visual and subjective contents of the human brain,” *Nature Neuroscience*, vol.8, No.5, pp.679-pp.685, 2005
- [2] Youichi 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* 60, pp. 915-929, 2008.
- [3] 岩切雄希, “fMRI による脳活動からの図形識別,” 平成 25 年度学士学位論文, 2015 .
- [4] 「脳を活かす」研究会, “ブレインデコーディング,” オーム社, 2007.
- [5] 武田常広, “脳工学,” pp.78–79, コロナ社, 2003.
- [6] 石村貞夫, “すぐわかる統計解析”, pp.34–35, 東京図書, 2011.
- [7] 熊沢逸夫, “学習とニューラルネットワーク,” 森北出版, 2007.
- [8] 平井有三, “はじめてのパターン認識,” pp.14–15, pp.114–133, 森北出版, 2012.
- [9] 村上郁也, “イラストレクチャー 認知神経科学,” pp.56–57, オーム社, 2010.
- [10] 萩原典明, 藤田 智之, 村松 禎久, 小高喜久雄, “3T-MRI 用 32ch Head コイルの基本性能の評価,” 日本放射線技術学会 第 65 回東京部会春期大会 抄録, p9, 2011.
- [11] Presentation, neurobehavioral systems, <http://www.neurobs.com/>
- [12] Matlab, MathWorks 日本, <http://jp.mathworks.com/products/matlab/>, 2015.
- [13] SPM8-Statistical Parametric Mapping, <http://www.fil.ion.ucl.ac.uk/spm/software/spm8/>, 2015 .
- [14] SPM5-Statistical Parametric Mapping, <http://www.fil.ion.ucl.ac.uk/spm/software/spm5/>, 2015 .
- [15] MRIConvert, yanifty DICOM file converter, <http://lcn1.uoregon.edu/downloads/mriconvert>, 2015 .

## 参考文献

- [16] Brain Decoder Toolbox ATR - DNi, <http://www.cns.atr.jp/dni/download/brain-decoder-toolbox/>, 2015.
- [17] 根本清貴, “SPM のセットアップ方法”, [http://www.nemotos.net/wp-content/uploads/spm\\_setup.pdf](http://www.nemotos.net/wp-content/uploads/spm_setup.pdf), 2015.
- [18] 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 年度学士学位論文, 2015.

# 付録 A

## 追加実験

Python の Numpy モジュールの乱数（メルセンヌ-ツイスター法）にて生成した  $325 \times 200000$  の乱数行列と、被験者 C の 5 ランの教師データを用いて、上記の実験と同様の処理を行う。脳活動を用いたときの識別率と比較するため、被験者 C の結果と乱数を用いたときの結果を図 A.1 に示す。200 次元で 90%，650 次元で 100% となっている。

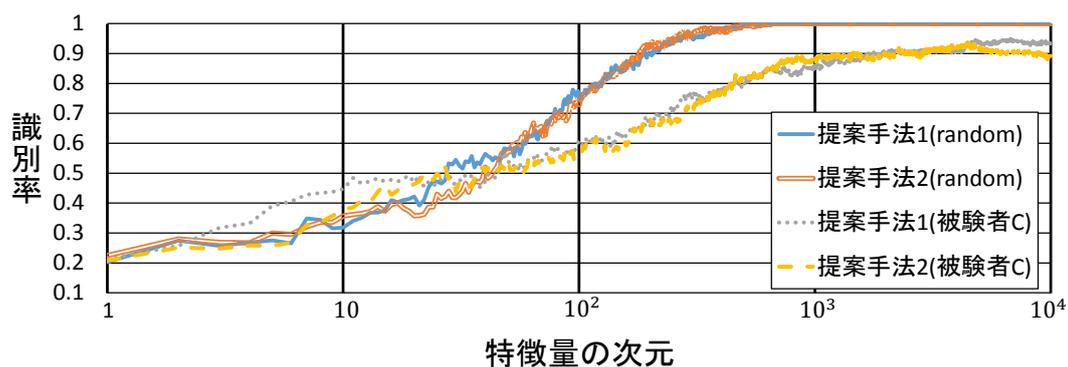
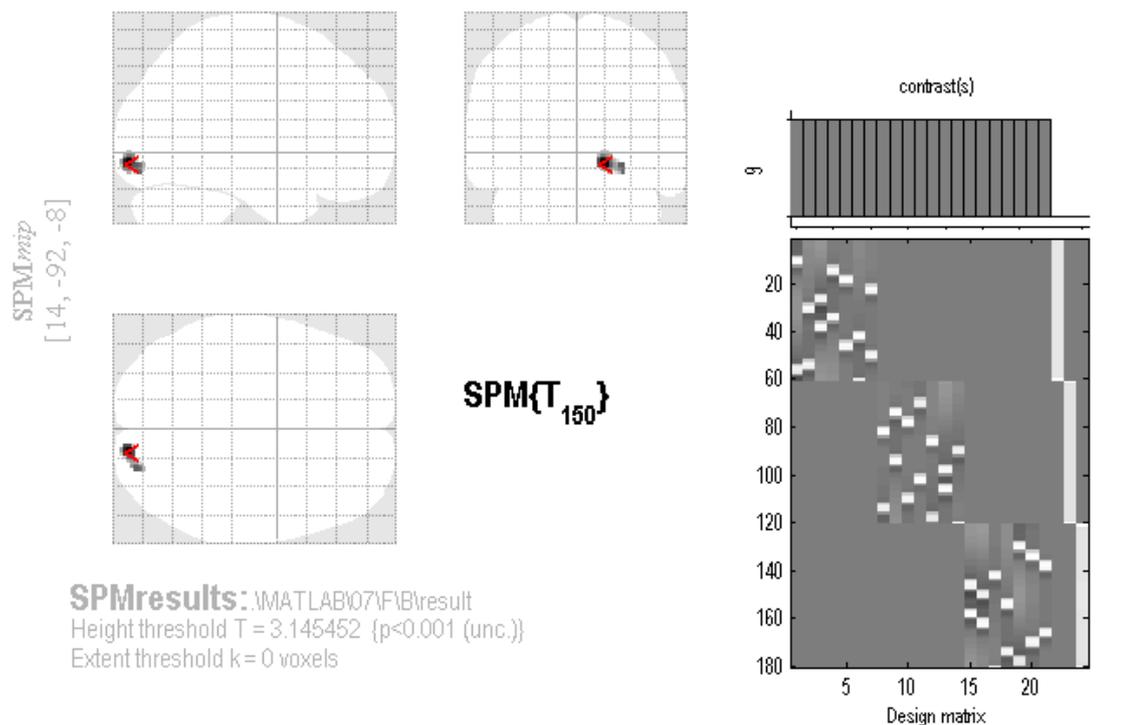


図 A.1 特徴の次元に対する識別率の変化

## 付録 B

# 脳画像と脳活動詳細

既存の手法で算出した各被験者の賦活部位を図 B.1 , 図 B.2 , 図 B.3 , 図 B.4 , 図 B.5 , 図 B.6 , 図 B.7 , 図 B.8 に示す .



**Statistics: p-values adjusted for search volume**

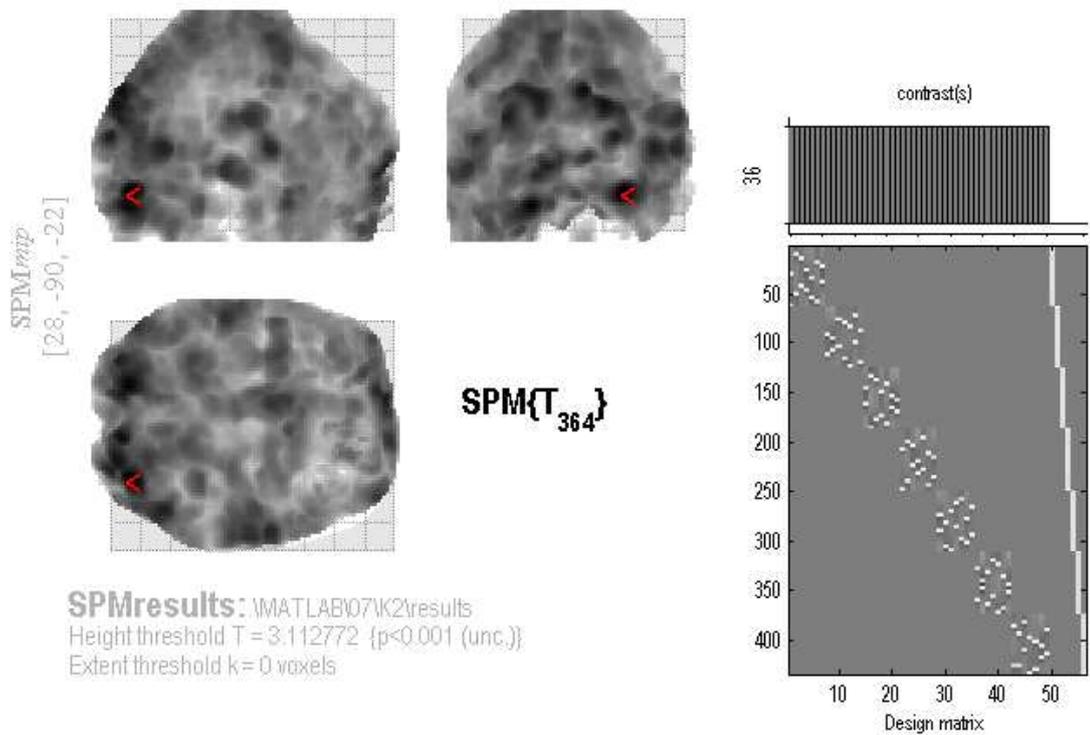
set-level		cluster-level				peak-level					mm mm mm		
p	c					$p_{FWE-corr}$	$q_{FDR-corr}$	T	(Z)	$p_{uncorr}$			
		0.328	0.017	84	0.017	0.993	0.475	3.74	3.65	0.000	14	-92	-8
						1.000	0.475	3.48	3.41	0.000	26	-88	-10

table shows 3 local maxima more than 8.0mm apart

Height threshold: T = 3.15, p = 0.001 (1.000)  
 Extent threshold: k = 0 voxels, p = 1.000 (1.000)  
 Expected voxels per cluster, <k> = 13.680  
 Expected number of clusters, <c> = 22.95  
 FWEp: 5.079, FDRp: Inf, FWEc: Inf, FDRc: 84

Degrees of freedom = [1.0, 150.0]  
 FWHM = 9.7 9.8 10.1 mm mm mm; 4.9 4.9 5.1 {voxels}  
 Volume: 2272848 = 284106 voxels = 2201.1 resels  
 Voxel size: 2.0 2.0 2.0 mm mm mm; (resel = 121.12 voxels)

図 B.1 被験者 A の賦活部位



**Statistics:  $p$ -values adjusted for search volume**

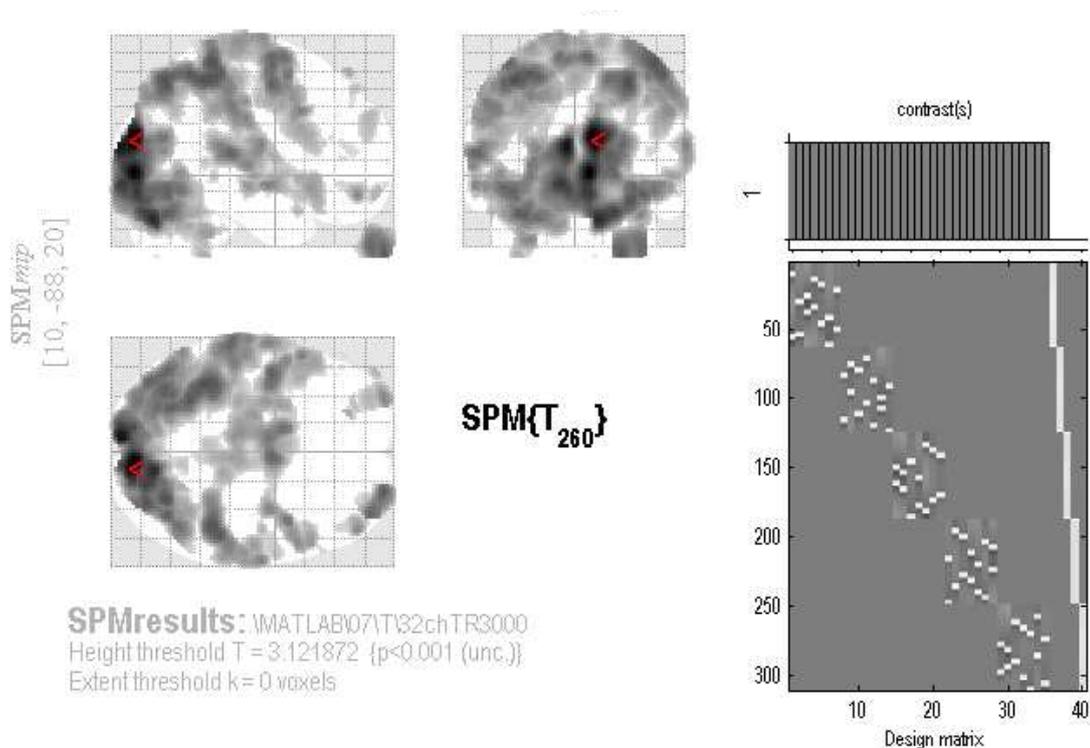
set-level		cluster-level				peak-level					mm mm mm		
$p$	$c$	$p_{FWE-corr}$	$q_{FDR-corr}$	$k_E$	$p_{uncorr}$	$p_{FWE-corr}$	$q_{FDR-corr}$	$T$	$(Z)$	$p_{uncorr}$			
0.949	12	0.000	0.000	137577	0.000	0.000	0.000	7.92	7.60	0.000	28	-90	-22
						0.000	0.000	7.60	7.32	0.000	-30	-92	-30
						0.000	0.000	7.47	7.20	0.000	2	-96	38
		0.006	0.002	290	0.000	0.240	0.025	4.47	4.40	0.000	4	-92	-50
		0.173	0.042	124	0.010	0.813	0.115	3.95	3.91	0.000	-30	-6	6
		0.936	0.364	33	0.152	0.983	0.246	3.67	3.63	0.000	28	-70	-46
		0.853	0.316	43	0.105	0.998	0.359	3.53	3.50	0.000	-32	-30	-32
		0.987	0.474	22	0.237	1.000	0.453	3.44	3.41	0.000	-48	-40	32
		0.999	0.622	13	0.363	1.000	0.580	3.34	3.31	0.000	-16	-8	4
		1.000	0.833	2	0.748	1.000	0.708	3.26	3.24	0.001	16	-64	-44
		1.000	0.833	4	0.630	1.000	0.747	3.24	3.21	0.001	10	-52	14
		1.000	0.833	2	0.748	1.000	0.918	3.15	3.13	0.001	6	0	-10
		1.000	0.833	1	0.833	1.000	0.924	3.15	3.12	0.001	4	0	10
		1.000	0.833	1	0.833	1.000	0.961	3.13	3.11	0.001	6	-2	12

table shows 3 local maxima more than 8.0mm apart

Height threshold:  $T = 3.11$ ,  $p = 0.001$  (1.000)  
 Extent threshold:  $k = 0$  voxels,  $p = 1.000$  (1.000)  
 Expected voxels per cluster,  $\langle k \rangle = 16.945$   
 Expected number of clusters,  $\langle c \rangle = 18.16$   
 FWEp: 4.888, FDRp: 4.250, FWEc: 290, FDRc: 124

Degrees of freedom = [1.0, 364.0]  
 FWHM = 10.4 10.6 10.6 mm mm mm; 5.2 5.3 5.3 {voxels}  
 Volume: 2205640 = 275705 voxels = 1775.4 resels  
 Voxel size: 2.0 2.0 2.0 mm mm mm; (resel = 145.84 voxels)

図 B.2 被験者 B の賦活部位



**Statistics: p-values adjusted for search volume**

set-level		cluster-level				peak-level					mm mm mm		
p	c	p <sub>FWE-corr</sub>	q <sub>FDR-corr</sub>	k <sub>E</sub>	p <sub>uncorr</sub>	p <sub>FWE-corr</sub>	q <sub>FDR-corr</sub>	T	(Z)	p <sub>uncorr</sub>			
0.163	20	0.000	0.000	28302	0.000	0.000	0.000	7.22	6.89	0.000	10	-88	20
						0.000	0.000	7.05	6.73	0.000	6	-88	0
						0.000	0.000	6.79	6.51	0.000	-6	-96	14
		0.000	0.000	579	0.000	0.004	0.003	5.48	5.33	0.000	26	64	-48
						0.012	0.004	5.23	5.10	0.000	38	56	-44
		0.000	0.000	755	0.000	0.070	0.014	4.80	4.69	0.000	66	-10	16
						0.280	0.045	4.40	4.32	0.000	66	-20	10
						0.381	0.060	4.29	4.22	0.000	56	-16	-2
		0.039	0.010	166	0.003	0.091	0.018	4.73	4.63	0.000	-30	64	-40
		0.060	0.011	148	0.004	0.106	0.019	4.69	4.59	0.000	48	48	-14
						1.000	0.618	3.34	3.31	0.000	46	38	-8
		0.024	0.008	187	0.002	0.314	0.049	4.36	4.28	0.000	56	18	-10
						1.000	0.862	3.20	3.16	0.001	48	8	-10
		0.988	0.438	16	0.285	0.704	0.117	4.02	3.96	0.000	-22	42	58
		0.762	0.183	42	0.092	0.795	0.146	3.94	3.88	0.000	-46	58	-14
						1.000	0.652	3.32	3.28	0.001	-36	64	-8
		0.911	0.281	29	0.155	0.822	0.157	3.91	3.85	0.000	48	-10	54
		0.052	0.011	154	0.003	0.837	0.163	3.90	3.84	0.000	-28	56	32
		0.709	0.176	46	0.079	0.948	0.239	3.74	3.69	0.000	-26	46	50
						1.000	0.898	3.17	3.14	0.001	-30	44	38
		0.243	0.044	92	0.018	0.992	0.364	3.57	3.52	0.000	32	56	30

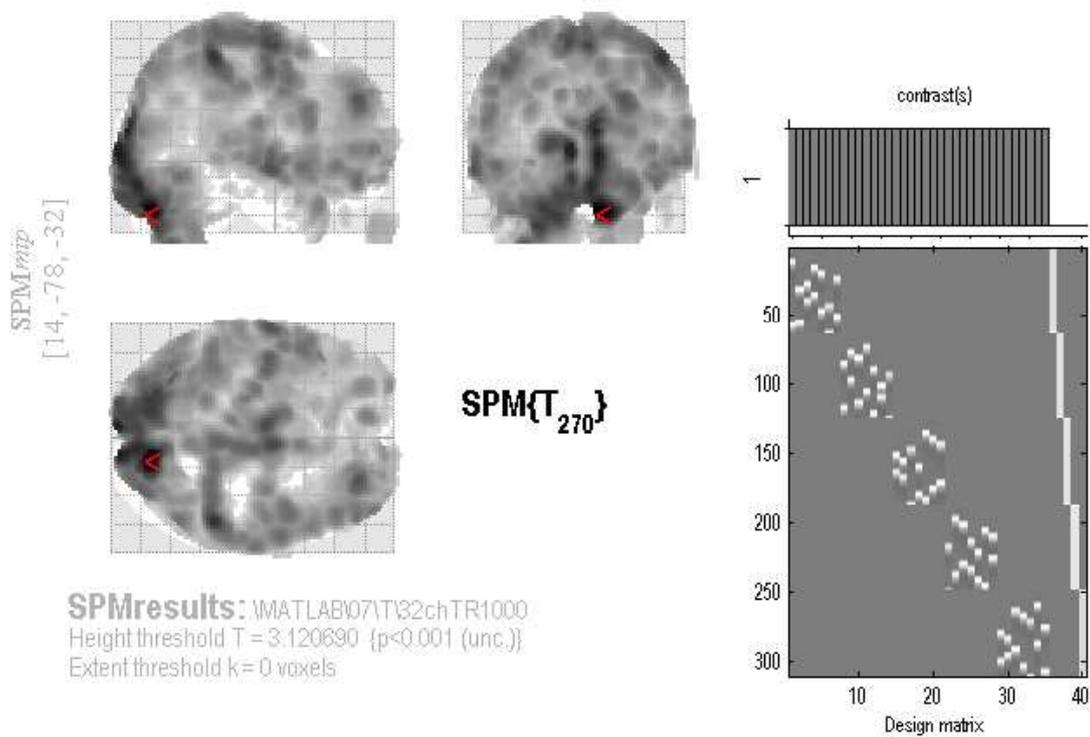
table shows 3 local maxima more than 8.0mm apart

Height threshold: T = 3.12, p = 0.001 (1.000)  
 Extent threshold: k = 0 voxels, p = 1.000 (1.000)  
 Expected voxels per cluster, <k> = 15.122  
 Expected number of clusters, <c> = 15.63  
 FWEp: 4.883, FDRp: 4.362, FWEc: 166, FDRc: 92

Degrees of freedom = [1.0, 260.0]  
 FWHM = 10.2 10.5 9.9 mm mm mm; 5.1 5.2 4.9 {voxels}  
 Volume: 1649872 = 206234 voxels = 1444.2 resels  
 Voxel size: 2.0 2.0 2.0 mm mm mm; (resel = 131.18 voxels)  
 Page 1



図 B.3 被験者 C-1 の賦活部位



**Statistics: p-values adjusted for search volume**

set-level		cluster-level				peak-level					mm mm mm		
p	c	p <sub>FWE-corr</sub>	q <sub>FDR-corr</sub>	k <sub>E</sub>	p <sub>uncorr</sub>	p <sub>FWE-corr</sub>	q <sub>FDR-corr</sub>	T	(Z)	p <sub>uncorr</sub>			
0.586	19	0.000	0.000	84044	0.000	0.000	0.000	19.50	Inf	0.000	14	-78	-32
						0.000	0.000	17.09	Inf	0.000	12	-96	2
						0.000	0.000	16.72	Inf	0.000	-4	-98	2
		0.000	0.000	504	0.000	0.000	0.000	7.19	6.87	0.000	38	58	-38
						0.000	0.000	7.09	6.79	0.000	28	64	-40
						0.000	0.000	6.45	6.21	0.000	36	56	-46
		0.370	0.075	62	0.024	0.000	0.000	5.99	5.80	0.000	18	-6	24
		0.013	0.004	169	0.001	0.001	0.000	5.73	5.56	0.000	-18	-10	22
		0.169	0.045	86	0.009	0.026	0.002	5.09	4.97	0.000	-30	68	-42
		0.764	0.200	36	0.074	0.033	0.002	5.04	4.92	0.000	54	40	-34
		0.370	0.075	62	0.024	0.091	0.006	4.78	4.68	0.000	-64	-30	-18
		0.972	0.384	19	0.182	0.819	0.098	3.99	3.93	0.000	-12	-48	-6
		0.998	0.569	10	0.329	0.970	0.195	3.76	3.71	0.000	-18	50	-20
		0.999	0.608	8	0.384	0.986	0.232	3.69	3.64	0.000	34	10	-20
		0.958	0.384	21	0.162	0.987	0.237	3.68	3.64	0.000	4	36	26
		1.000	0.787	2	0.684	0.996	0.293	3.61	3.56	0.000	10	40	64
		0.990	0.443	15	0.233	1.000	0.649	3.31	3.27	0.001	10	-50	46
		1.000	0.787	3	0.608	1.000	0.653	3.30	3.27	0.001	-8	48	4
		1.000	0.787	3	0.608	1.000	0.737	3.25	3.22	0.001	-54	-2	-40
		1.000	0.787	1	0.787	1.000	0.782	3.23	3.19	0.001	4	-70	4
		1.000	0.787	1	0.787	1.000	0.915	3.16	3.13	0.001	-48	6	-42

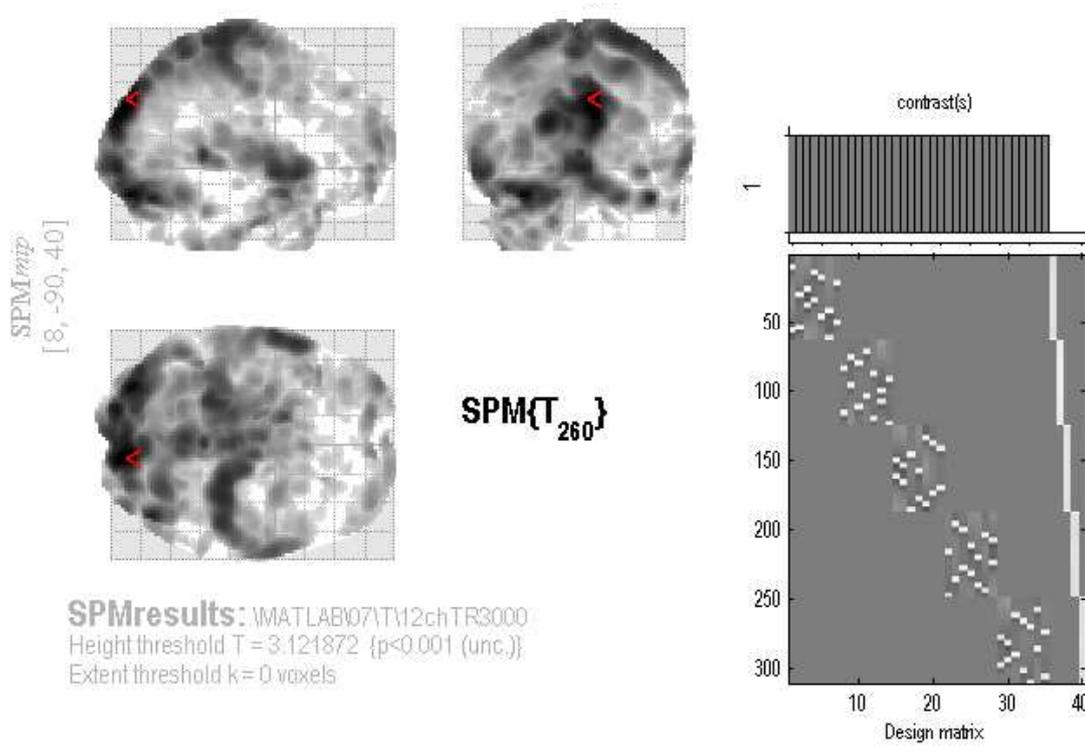
table shows 3 local maxima more than 8.0mm apart

Height threshold: T = 3.12, p = 0.001 (1.000)  
 Extent threshold: k = 0 voxels, p = 1.000 (1.000)  
 Expected voxels per cluster, <k> = 11.360  
 Expected number of clusters, <c> = 19.62  
 FWEp: 4.935, FDRp: 4.205, FWEc: 169, FDRc: 86

Degrees of freedom = [1.0, 270.0]  
 FWHM = 9.2 9.5 9.0 mm mm mm; 4.6 4.7 4.5 {voxels}  
 Volume: 1580888 = 197611 voxels = 1841.5 resels  
 Voxel size: 2.0 2.0 2.0 mm mm mm; (resel = 98.45 voxels)  
 Page 1



図 B.4 被験者 C-2 の賦活部位



**Statistics: p-values adjusted for search volume**

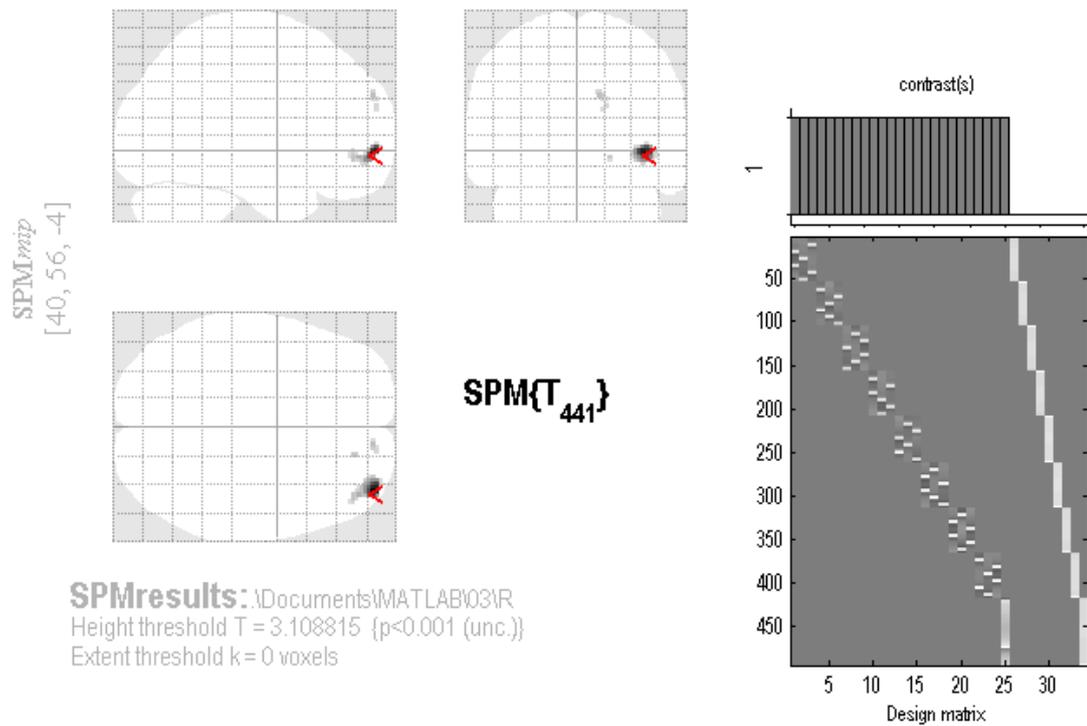
set-level		cluster-level				peak-level					mm mm mm		
p	c	p <sub>FWE-corr</sub>	q <sub>FDR-corr</sub>	k <sub>E</sub>	p <sub>uncorr</sub>	p <sub>FWE-corr</sub>	q <sub>FDR-corr</sub>	T	(Z)	p <sub>uncorr</sub>			
0.000	42	0.000	0.000	47536	0.000	0.000	0.000	9.37	Inf	0.000	8	-90	40
						0.000	0.000	9.37	Inf	0.000	10	-96	32
						0.000	0.000	8.96	Inf	0.000	-32	-90	-18
		0.000	0.000	1012	0.000	0.000	0.000	7.03	6.72	0.000	64	-2	2
						0.000	0.000	6.28	6.05	0.000	62	6	-4
						0.004	0.001	5.46	5.31	0.000	58	2	-26
		0.013	0.010	238	0.001	0.001	0.000	5.73	5.56	0.000	-4	-18	12
						0.644	0.112	4.05	3.99	0.000	-2	-6	6
		0.000	0.000	1571	0.000	0.004	0.001	5.44	5.29	0.000	38	56	26
						0.008	0.002	5.31	5.17	0.000	0	66	18
						0.015	0.003	5.16	5.03	0.000	16	68	16
		0.885	0.397	34	0.148	0.034	0.007	4.96	4.85	0.000	22	28	-24
						0.958	0.274	3.69	3.64	0.000	32	28	-28
		0.211	0.136	108	0.016	0.092	0.016	4.71	4.61	0.000	62	-46	14
						0.347	0.059	4.31	4.23	0.000	54	-40	10
						0.177	0.030	4.53	4.44	0.000	-56	-8	-34
		0.928	0.397	29	0.180	0.248	0.041	4.42	4.34	0.000	-24	-2	-42
		0.866	0.397	36	0.138	0.440	0.076	4.22	4.15	0.000	-16	-24	-12
		0.912	0.397	31	0.166	0.550	0.095	4.13	4.06	0.000	-18	-36	4
		0.411	0.190	78	0.036	0.555	0.095	4.13	4.06	0.000	0	-74	-40
		0.402	0.190	79	0.035	0.564	0.097	4.12	4.05	0.000	-40	-14	36

table shows 3 local maxima more than 8.0mm apart

Height threshold: T = 3.12, p = 0.001 (1.000)  
 Extent threshold: k = 0 voxels, p = 1.000 (1.000)  
 Expected voxels per cluster, <k> = 17.147  
 Expected number of clusters, <c> = 14.61  
 FWEp: 4.868, FDRp: 4.379, FWEc: 238, FDRc: 238

Degrees of freedom = [1.0, 260.0]  
 FWHM = 10.6 10.8 10.3 mm mm mm; 5.3 5.4 5.2 {voxels}  
 Volume: 1768568 = 221071 voxels = 1384.5 resels  
 Voxel size: 2.0 2.0 2.0 mm mm mm; (resel = 148.75 voxels)

図 B.5 被験者 C-3 の賦活部位



**Statistics: p-values adjusted for search volume**

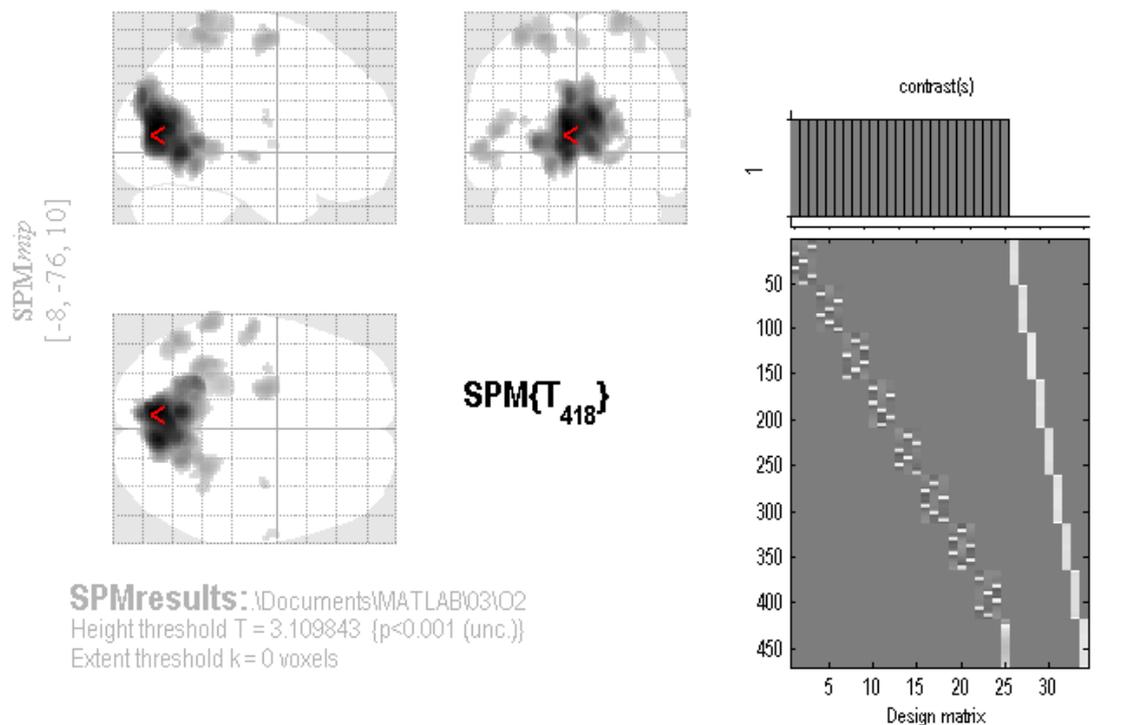
set-level		cluster-level				peak-level					mm mm mm		
p	c	p <sub>FWE-corr</sub>	q <sub>FDR-corr</sub>	k <sub>E</sub>	p <sub>uncorr</sub>	p <sub>FWE-corr</sub>	q <sub>FDR-corr</sub>	T	(Z)	p <sub>uncorr</sub>			
1.000	4	0.244	0.057	78	0.014	0.516	0.250	4.21	4.17	0.000	40	56	-4
		1.000	0.691	7	0.426	1.000	0.860	3.35	3.32	0.000	42	48	-6
		1.000	0.691	3	0.616	1.000	0.860	3.27	3.25	0.001	12	56	30
		1.000	0.691	3	0.616	1.000	0.860	3.23	3.21	0.001	18	44	-6
		1.000	0.691	2	0.691	1.000	0.904	3.15	3.13	0.001	16	58	24

table shows 3 local maxima more than 8.0mm apart

Height threshold: T = 3.11, p = 0.001 (1.000)  
 Extent threshold: k = 0 voxels, p = 1.000 (1.000)  
 Expected voxels per cluster, <k> = 11.819  
 Expected number of clusters, <c> = 19.71  
 FWEp: 4.890, FDRp: Inf, FWEc: Inf, FDRc: Inf

Degrees of freedom = [1.0, 441.0]  
 FWHM = 9.2 9.4 9.3 mm mm mm; 4.6 4.7 4.7 {voxels}  
 Volume: 1655976 = 206997 voxels = 1879.3 resels  
 Voxel size: 2.0 2.0 2.0 mm mm mm; (resel = 101.37 voxels)

図 B.6 被験者 D の賦活部位



**Statistics: p-values adjusted for search volume**

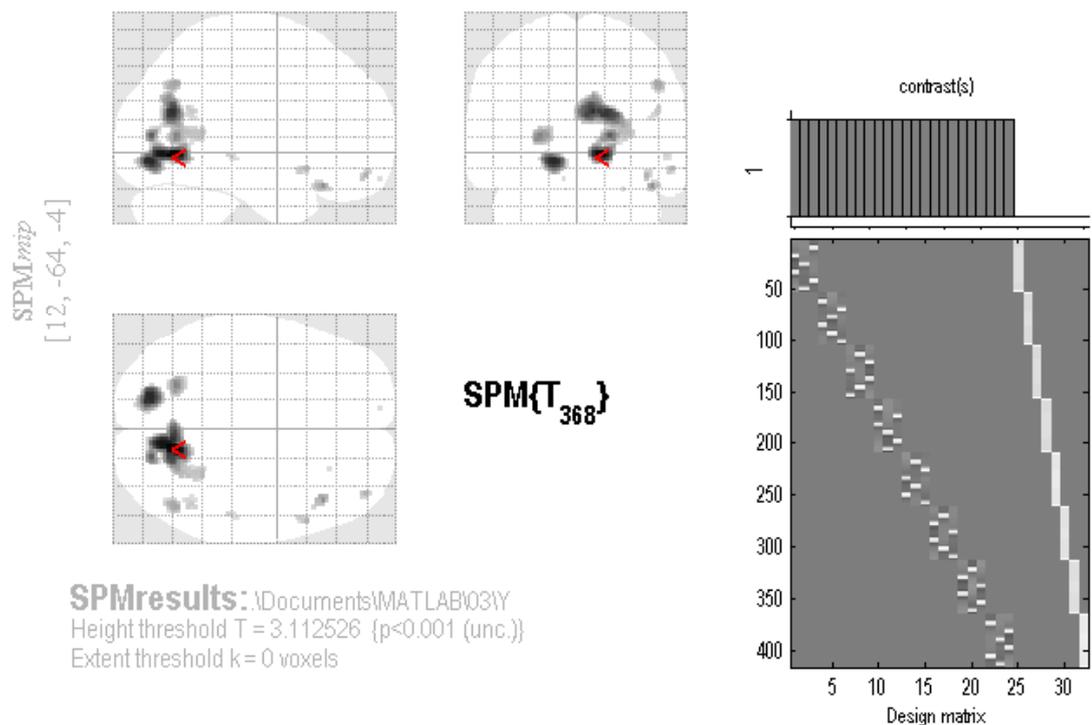
set-level		cluster-level				peak-level					mm mm mm		
$p$	$c$	$p_{FWE-corr}$	$q_{FDR-corr}$	$k_E$	$p_{uncorr}$	$p_{FWE-corr}$	$q_{FDR-corr}$	$T$	$(Z)$	$p_{uncorr}$			
0.785	13	0.000	0.000	4717	0.000	0.000	0.000	8.60	Inf	0.000	-8	-76	10
						0.000	0.000	8.09	7.78	0.000	8	-74	20
						0.000	0.000	7.62	7.37	0.000	-8	-62	-2
		0.000	0.000	410	0.000	0.178	0.032	4.50	4.45	0.000	-36	-48	66
						0.621	0.104	4.06	4.02	0.000	-30	-42	70
		0.019	0.004	196	0.001	0.190	0.032	4.48	4.43	0.000	-50	-62	10
						0.850	0.193	3.86	3.83	0.000	-46	-68	18
		0.024	0.004	184	0.002	0.195	0.032	4.48	4.42	0.000	-22	-8	66
		0.050	0.007	154	0.003	0.234	0.036	4.42	4.37	0.000	-60	-42	0
		0.004	0.001	262	0.000	0.294	0.044	4.35	4.30	0.000	24	-46	76
						0.989	0.400	3.58	3.55	0.000	36	-48	68
		0.464	0.065	65	0.040	0.455	0.069	4.20	4.15	0.000	-56	-18	-4
		0.282	0.039	85	0.021	0.989	0.400	3.58	3.55	0.000	0	-52	64
						0.999	0.488	3.44	3.42	0.000	-6	-58	66
		0.996	0.457	12	0.351	0.995	0.431	3.52	3.50	0.000	36	-10	72
		0.999	0.488	9	0.422	0.999	0.488	3.44	3.41	0.000	-34	-10	18
		0.995	0.457	13	0.332	0.999	0.488	3.43	3.40	0.000	-52	-64	-10
		1.000	0.558	5	0.558	1.000	0.554	3.36	3.34	0.000	66	-8	20
		0.999	0.488	8	0.450	1.000	0.736	3.23	3.21	0.001	64	-6	4

table shows 3 local maxima more than 8.0mm apart

Height threshold:  $T = 3.11$ ,  $p = 0.001$  (1.000)  
 Extent threshold:  $k = 0$  voxels,  $p = 1.000$  (1.000)  
 Expected voxels per cluster,  $\langle k \rangle = 14.920$   
 Expected number of clusters,  $\langle c \rangle = 15.68$   
 FWEp: 4.838, FDRp: 4.351, FWEc: 154, FDRc: 85

Degrees of freedom = [1.0, 418.0]  
 FWHM = 10.1 10.3 9.8 mm mm mm; 5.1 5.2 4.9 {voxels}  
 Volume: 1641440 = 205180 voxels = 1477.4 resels  
 Voxel size: 2.0 2.0 2.0 mm mm mm; (resel = 128.08 voxels)

図 B.7 被験者 E の賦活部位



**Statistics: p-values adjusted for search volume**

set-level		cluster-level				peak-level					mm mm mm		
p	c	p <sub>FWE-corr</sub>	q <sub>FDR-corr</sub>	k <sub>E</sub>	p <sub>uncorr</sub>	p <sub>FWE-corr</sub>	q <sub>FDR-corr</sub>	T	(Z)	p <sub>uncorr</sub>			
0.999	11	0.000	0.000	831	0.000	0.075	0.052	4.86	4.78	0.000	12	-64	-4
						0.153	0.056	4.67	4.60	0.000	10	-72	-2
						0.320	0.066	4.45	4.39	0.000	8	-66	22
		0.005	0.001	183	0.000	0.285	0.066	4.49	4.43	0.000	-16	-78	-8
		0.098	0.015	95	0.004	0.977	0.386	3.79	3.75	0.000	-24	-64	8
		0.963	0.298	21	0.135	0.993	0.464	3.70	3.66	0.000	44	26	-22
		0.603	0.104	44	0.038	1.000	0.598	3.56	3.53	0.000	48	-64	38
		1.000	0.567	5	0.464	1.000	0.713	3.46	3.43	0.000	40	52	-16
		0.999	0.464	10	0.295	1.000	0.713	3.43	3.41	0.000	56	16	-12
		0.998	0.462	12	0.252	1.000	0.810	3.28	3.26	0.001	46	-54	22
		1.000	0.526	7	0.382	1.000	0.872	3.20	3.18	0.001	52	-32	-4
		1.000	0.769	1	0.769	1.000	0.918	3.16	3.13	0.001	-10	60	-18
		1.000	0.769	1	0.769	1.000	0.918	3.15	3.13	0.001	26	30	-24

table shows 3 local maxima more than 8.0mm apart

Height threshold: T = 3.11, p = 0.001 (1.000)  
 Extent threshold: k = 0 voxels, p = 1.000 (1.000)  
 Expected voxels per cluster, <k> = 9.866  
 Expected number of clusters, <c> = 24.47  
 FWEp: 4.958, FDRp: Inf, FWEc: 183, FDRc: 95

Degrees of freedom = [1.0, 368.0]  
 FWHM = 8.7 8.9 8.8 mm mm mm; 4.4 4.5 4.4 {voxels}  
 Volume: 1753400 = 219175 voxels = 2398.1 resels  
 Voxel size: 2.0 2.0 2.0 mm mm mm; (resel = 84.89 voxels)

図 B.8 被験者 F の賦活部位

# 付録 C

## 各手法識別結果詳細

### C.1 既存の手法

既存の手法での識別結果の被験者ごとの詳細を示す。

表 C.1 被験者 A

提示画像 \ 識別画像	○	□	△	▽	◇	★	×
○	1	1	1	1	0	1	1
□	1	0	0	0	1	2	2
△	2	0	0	1	0	2	1
▽	2	0	1	1	0	1	1
◇	1	1	0	3	0	0	1
★	2	0	1	1	1	0	1
×	0	1	0	2	0	2	1

C.1 既存の手法

表 C.2 被験者 B

提示画像 \ 識別画像	○	□	△	▽	◇	★	×
○	<b>2</b>	1	2	3	0	4	2
□	1	<b>4</b>	3	1	1	1	3
△	0	3	<b>1</b>	3	1	3	3
▽	0	3	3	<b>2</b>	1	4	1
◇	0	2	2	2	<b>1</b>	4	3
★	2	1	3	1	1	<b>3</b>	3
×	1	2	2	2	1	4	<b>2</b>

表 C.3 被験者 C-1

提示画像 \ 識別画像	○	□	△	▽	◇	★	×
○	<b>4</b>	1	1	1	0	0	3
□	1	<b>2</b>	3	1	2	0	1
△	1	1	<b>5</b>	1	1	1	0
▽	0	0	1	<b>4</b>	2	2	1
◇	4	3	1	1	<b>1</b>	0	0
★	2	0	0	1	1	<b>5</b>	1
×	2	0	2	0	0	1	<b>5</b>

## C.1 既存の手法

表 C.4 被験者 C-2

提示画像 \ 識別画像	○	□	△	▽	◇	★	×
○	2	0	1	2	0	2	3
□	1	2	2	2	1	1	1
△	1	1	2	2	1	0	3
▽	0	1	2	1	3	1	2
◇	0	2	3	4	0	0	1
★	0	4	0	1	4	0	1
×	0	4	2	2	1	1	0

表 C.5 被験者 C-3

提示画像 \ 識別画像	○	□	△	▽	◇	★	×
○	2	2	2	0	2	2	0
□	4	2	1	3	0	0	0
△	2	4	2	0	0	2	0
▽	3	1	0	0	4	1	1
◇	2	4	1	2	0	1	0
★	1	1	2	1	0	4	1
×	2	1	0	0	0	4	3

表 C.1 より提示画像に対して、正確に識別できたのは 42 画像中 3 画像である。1 と識別されるのが 9 回と一番多いのに対して、5 と識別されるのは 2 回と一番少ないことがわかる。表 C.2 より提示画像に対して、正確に識別できたのは 98 画像中 15 画像である。6 と識別されるのが 23 回と一番多いのに対して、1 と識別されるのは 6 回と一番少ないことがわかる。表 C.3 より提示画像に対して、正確に識別できたのは 70 画像中 26 画像である。1 と

## C.1 既存の手法

識別されるのが 14 回と一番多いのに対して，2，5 と識別されるのはそれぞれ 7 回と少ないことがわかる．表 C.4 より提示画像に対して，正確に識別できたのは 70 画像中 7 画像である．2，4 と識別されるのがそれぞれ 14 回と一番多いのに対して，1 と識別されるのは 4 回と一番少ないことがわかる．表 C.5 より提示画像に対して，正確に識別できたのは 70 画像中 13 画像である．1 と識別されるのが 16 回と一番多いのに対して，7 と識別されるのは 5 回と一番少ないことがわかる．

表 C.6 被験者 D

提示画像 \ 識別画像	○	□	△
○	<b>6</b>	3	7
□	4	<b>7</b>	5
△	8	6	<b>2</b>

表 C.7 被験者 E

提示画像 \ 識別画像	○	□	△
○	<b>8</b>	4	4
□	4	<b>7</b>	5
△	4	4	<b>8</b>

表 C.8 被験者 F

提示画像 \ 識別画像	○	□	△
○	<b>9</b>	3	4
□	7	<b>5</b>	4
△	3	2	<b>11</b>

表 C.6 より提示画像に対して，正確に識別できたのは 48 画像中 15 画像である．1 と 2 の

## C.2 提案手法 1

画像はそれぞれ 6, 7 回正確に識別できているのに対し, 3 の図形に関しては, 2 回の正確な識別にとどまっている。

表 C.7 より提示画像に対して, 正確に識別できたのは 48 画像中 23 画像である。3 種類それぞれの画像に対して 7, 8 回正確に識別できており, 誤った識別をしている場合は, 4 か 5 回となっている。

表 C.8 より提示画像に対して, 正確に識別できたのは 48 画像中 25 画像である。3 の図形が最も識別率がよく 11 回正確に識別できているのに対して, 2 の図形は 5 回となっている。

## C.2 提案手法 1

以下に, 提案手法 1 で 177 ボクセルを用いたときの結果の詳細を示す。

表 C.9 被験者 A

提示画像 \ 識別画像	○	□	△	▽	◇	★	×
○	2	1	1	0	0	1	1
□	3	1	1	0	0	0	2
△	2	0	0	0	1	2	1
▽	3	3	2	0	2	2	1
◇	3	0	0	0	1	1	2
★	0	1	0	0	1	3	3
×	0	3	3	0	0	1	2

C.2 提案手法 1

表 C.10 被験者 B

提示画像 \ 識別画像	○	□	△	▽	◇	★	×
○	<b>3</b>	0	3	0	6	1	4
□	2	<b>6</b>	1	0	3	0	4
△	1	5	<b>2</b>	4	0	3	1
▽	2	4	4	<b>4</b>	7	1	3
◇	1	2	2	0	<b>7</b>	2	0
★	2	2	4	4	5	<b>5</b>	2
×	0	3	1	1	4	0	<b>8</b>

表 C.11 被験者 C-1

提示画像 \ 識別画像	○	□	△	▽	◇	★	×
○	<b>4</b>	2	0	1	1	1	4
□	5	<b>4</b>	1	1	0	1	2
△	1	1	<b>4</b>	1	1	1	3
▽	3	0	3	<b>3</b>	3	1	3
◇	0	0	1	2	<b>4</b>	3	3
★	2	0	0	1	7	<b>3</b>	2
×	1	1	1	0	1	2	<b>4</b>

C.2 提案手法 1

表 C.12 被験者 C-2

提示画像 \ 識別画像	○	□	△	▽	◇	★	×
○	<b>3</b>	1	1	0	3	1	4
□	4	<b>5</b>	2	0	0	1	2
△	1	2	<b>5</b>	1	0	1	2
▽	1	3	1	<b>6</b>	0	1	4
◇	0	4	3	0	<b>2</b>	1	3
★	3	1	2	0	2	<b>3</b>	4
×	0	0	2	0	3	0	<b>5</b>

表 C.13 被験者 C-3

提示画像 \ 識別画像	○	□	△	▽	◇	★	×
○	<b>4</b>	0	3	0	1	1	4
□	3	<b>4</b>	2	0	0	4	1
△	2	2	<b>5</b>	0	0	3	0
▽	4	1	3	<b>1</b>	2	4	1
◇	6	1	0	0	<b>2</b>	1	3
★	2	0	2	0	1	<b>5</b>	5
×	0	0	5	0	3	1	<b>1</b>

以下に，提案手法 2 で 145 ボクセルを用いたときの結果の詳細を示す．

### C.3 提案手法 2

表 C.14 被験者 D

提示画像 \ 識別画像	○	□	△
○	<b>12</b>	4	2
□	6	<b>10</b>	7
△	7	7	<b>9</b>

表 C.15 被験者 E

提示画像 \ 識別画像	○	□	△
○	<b>13</b>	3	2
□	11	<b>7</b>	5
△	8	10	<b>5</b>

表 C.16 被験者 F

提示画像 \ 識別画像	○	□	△
○	<b>11</b>	5	2
□	8	<b>9</b>	6
△	7	10	<b>6</b>

### C.3 提案手法 2

以下に、提案手法 2 で 177 ボクセルを用いたときの結果の詳細を示す。

C.3 提案手法 2

表 C.17 被験者 A

提示画像 \ 識別画像	○	□	△	▽	◇	★	×
○	<b>3</b>	0	0	0	0	0	
□	3	<b>6</b>	0	0	0	0	1
△	0	0	<b>8</b>	0	0	0	0
▽	1	0	0	<b>3</b>	0	0	0
◇	0	0	0	0	<b>4</b>	0	0
★	0	0	0	0	0	<b>7</b>	0
×	0	0	0	0	1	0	<b>5</b>

表 C.18 被験者 B

提示画像 \ 識別画像	○	□	△	▽	◇	★	×
○	<b>11</b>	0	0	4	0	3	0
□	2	<b>5</b>	1	1	2	1	1
△	1	1	<b>8</b>	0	1	0	2
▽	1	0	3	<b>11</b>	0	0	2
◇	0	0	1	2	<b>11</b>	0	0
★	0	3	0	0	0	<b>10</b>	0
×	0	0	0	0	2	2	<b>6</b>

C.3 提案手法 2

表 C.19 被験者 C-1

提示画像 \ 識別画像	○	□	△	▽	◇	★	×
○	<b>8</b>	0	0	1	0	2	0
□	4	<b>7</b>	1	0	1	0	0
△	0	1	<b>7</b>	0	0	0	1
▽	1	1	0	<b>9</b>	0	1	0
◇	2	0	0	0	<b>9</b>	0	1
★	1	0	2	0	1	<b>4</b>	0
×	0	0	0	0	0	0	<b>5</b>

表 C.20 被験者 C-2

提示画像 \ 識別画像	○	□	△	▽	◇	★	×
○	<b>5</b>	0	0	0	0	0	0
□	3	<b>10</b>	1	0	0	0	0
△	0	1	<b>10</b>	0	1	0	1
▽	2	0	0	<b>8</b>	0	0	0
◇	0	1	0	1	<b>8</b>	0	1
★	0	0	0	0	0	<b>6</b>	2
×	1	0	0	0	1	2	<b>5</b>

C.3 提案手法 2

表 C.21 被験者 C-3

提示画像 \ 識別画像	○	□	△	▽	◇	★	×
○	<b>8</b>	1	1	0	0	0	0
□	1	<b>7</b>	0	1	0	0	0
△	0	0	<b>7</b>	0	0	2	0
▽	0	0	1	<b>10</b>	0	0	0
◇	1	0	0	0	<b>10</b>	0	1
★	2	1	1	1	0	<b>7</b>	0
×	0	0	0	1	0	0	<b>6</b>

以下に，提案手法 2 で 145 ボクセルを用いたときの結果の詳細を示す．

表 C.22 被験者 D

提示画像 \ 識別画像	○	□	△
○	<b>10</b>	11	0
□	2	<b>9</b>	0
△	0	0	<b>16</b>

表 C.23 被験者 E

提示画像 \ 識別画像	○	□	△
○	<b>8</b>	4	0
□	6	<b>11</b>	0
△	2	0	<b>17</b>

### C.3 提案手法 2

表 C.24 被験者 F

提示画像 \ 識別画像	○	□	△
○	14	8	0
□	5	5	1
△	0	0	15

## 付録 D

# 提案手法で選択した上位 100 ボクセル

各提案手法，7 種類と 3 種類それぞれの識別に用いた上位 100 ボクセルを以下に示す．

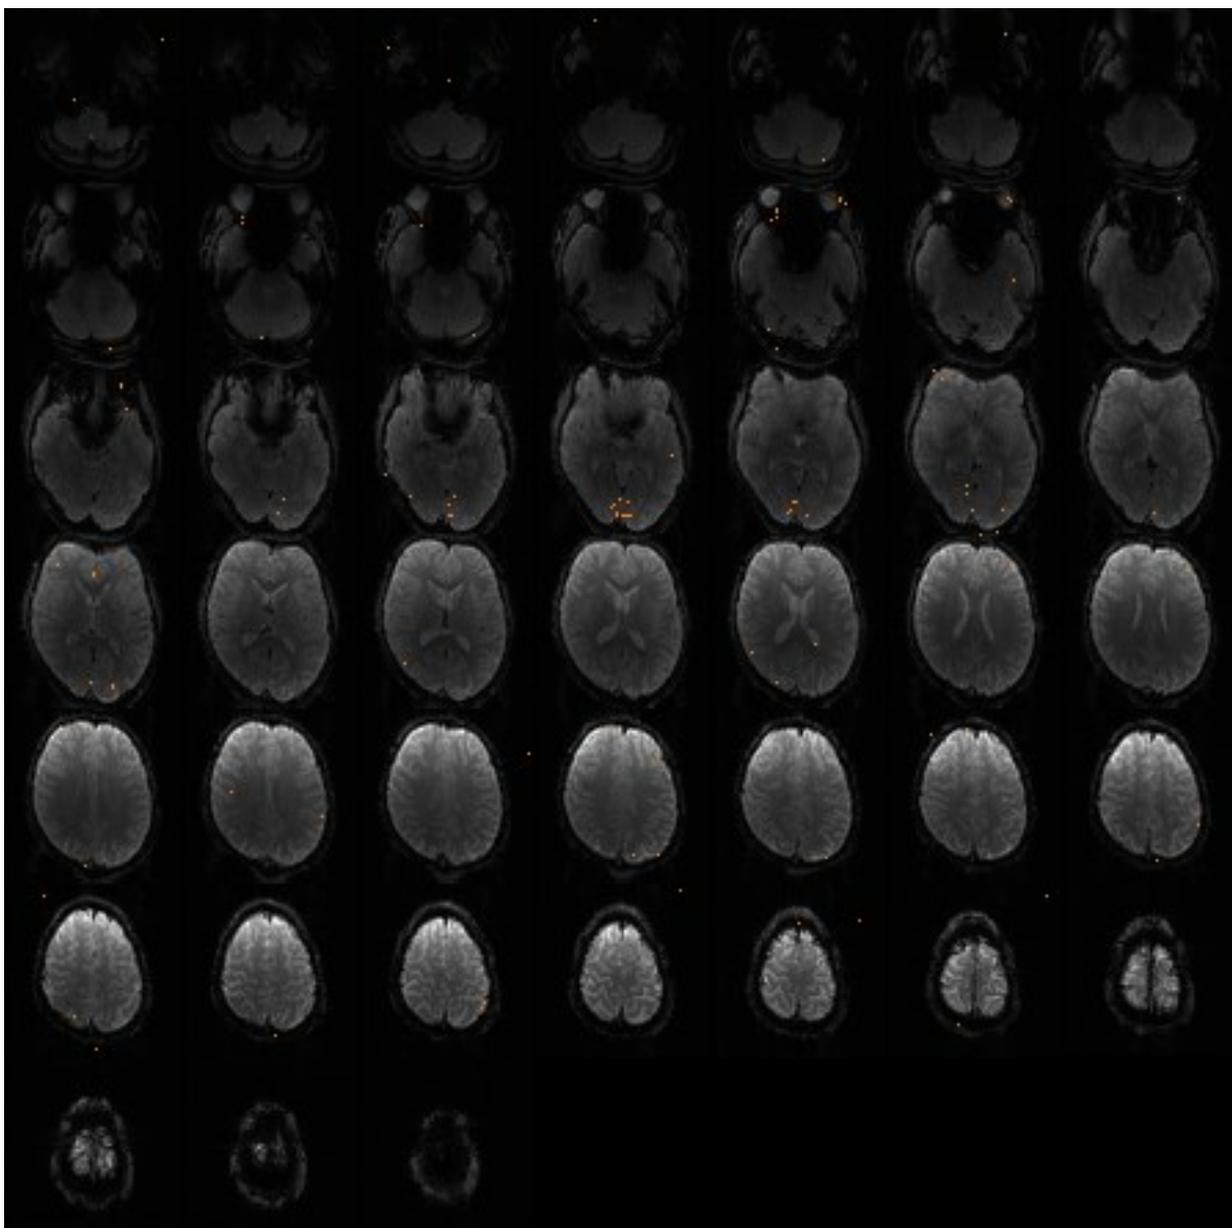


図 D.1 7 種類の図形識別で用いた上位 100 ボクセル 提案手法 1

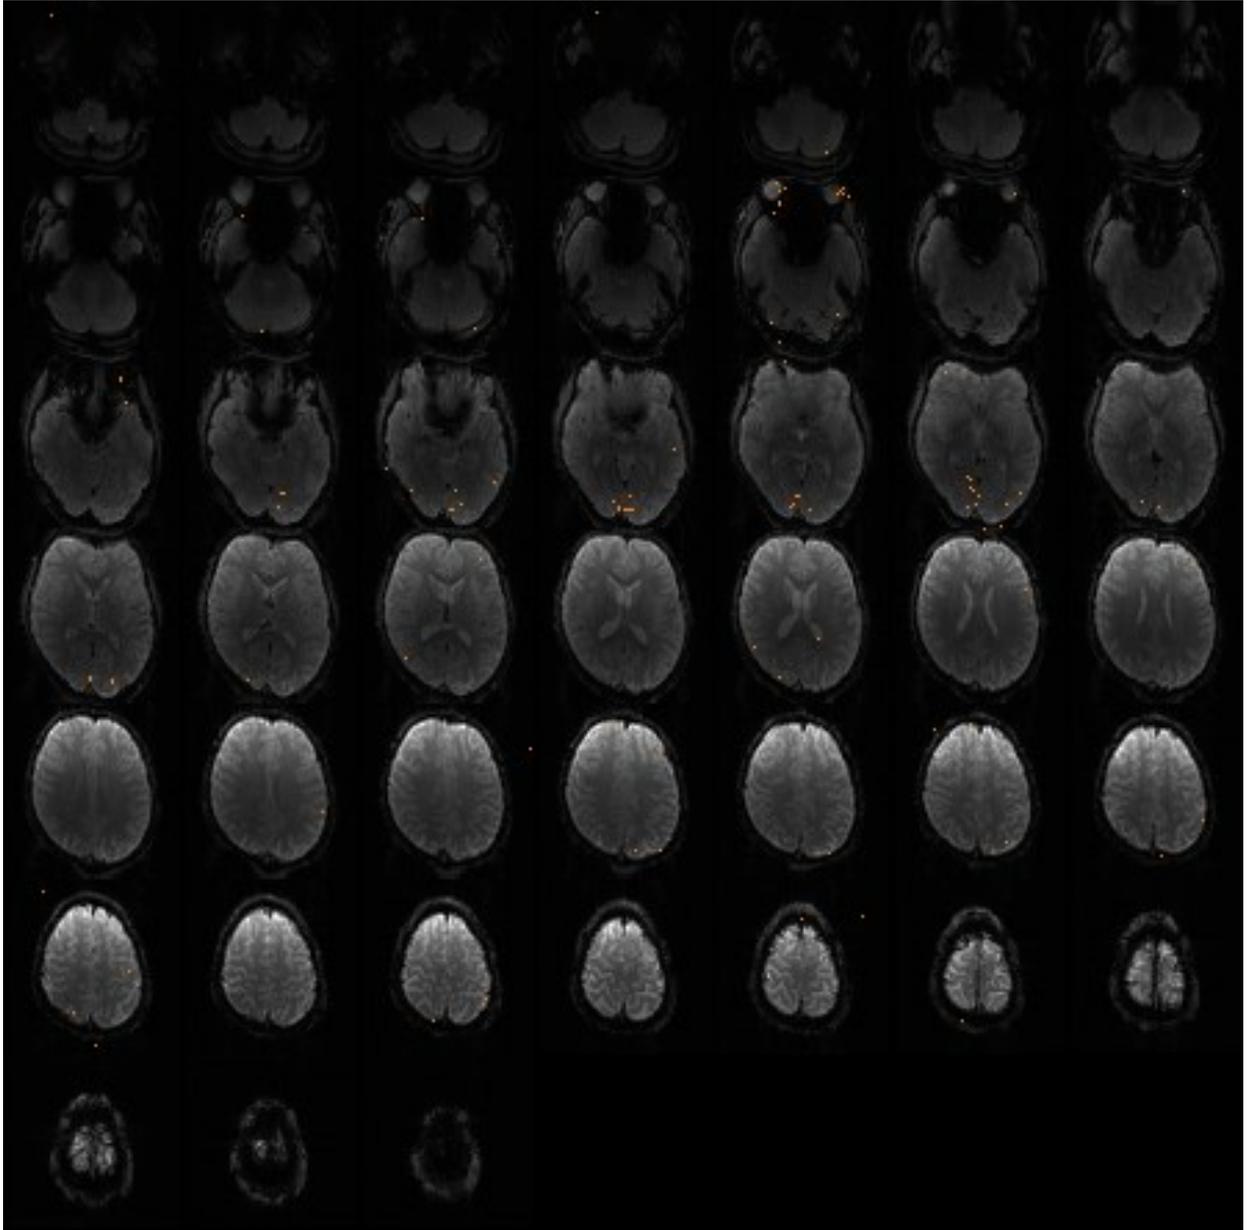


図 D.2 7 種類の図形識別で用いた上位 100 ボクセル 提案手法 2

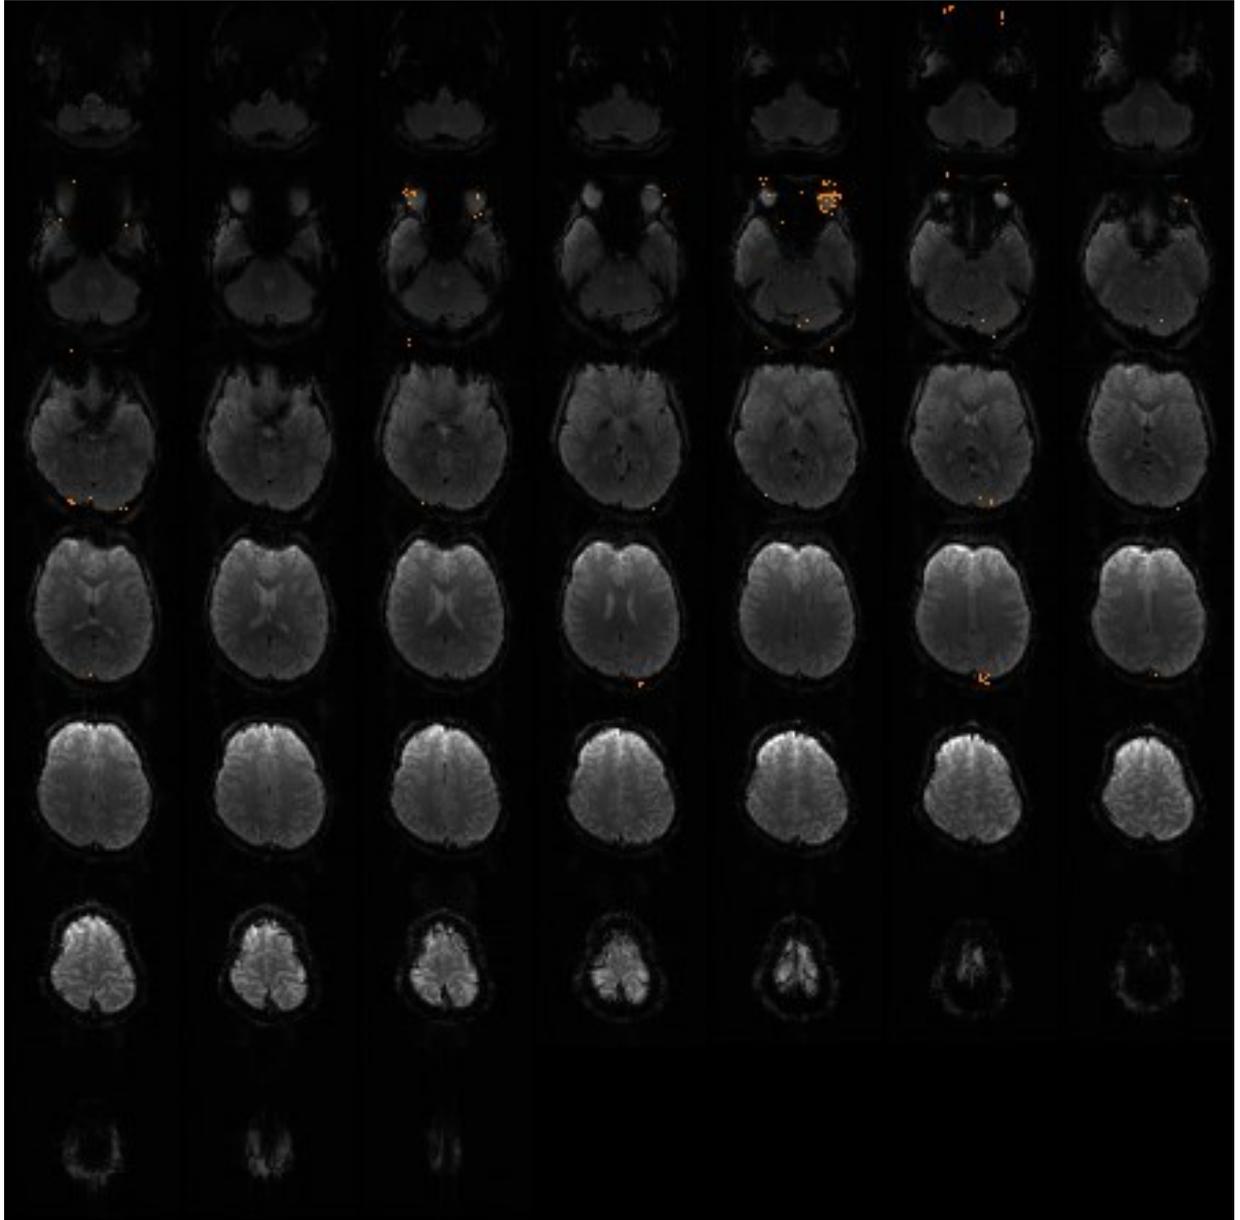


図 D.3 3 種類の図形識別で用いた上位 100 ボクセル 提案手法 1

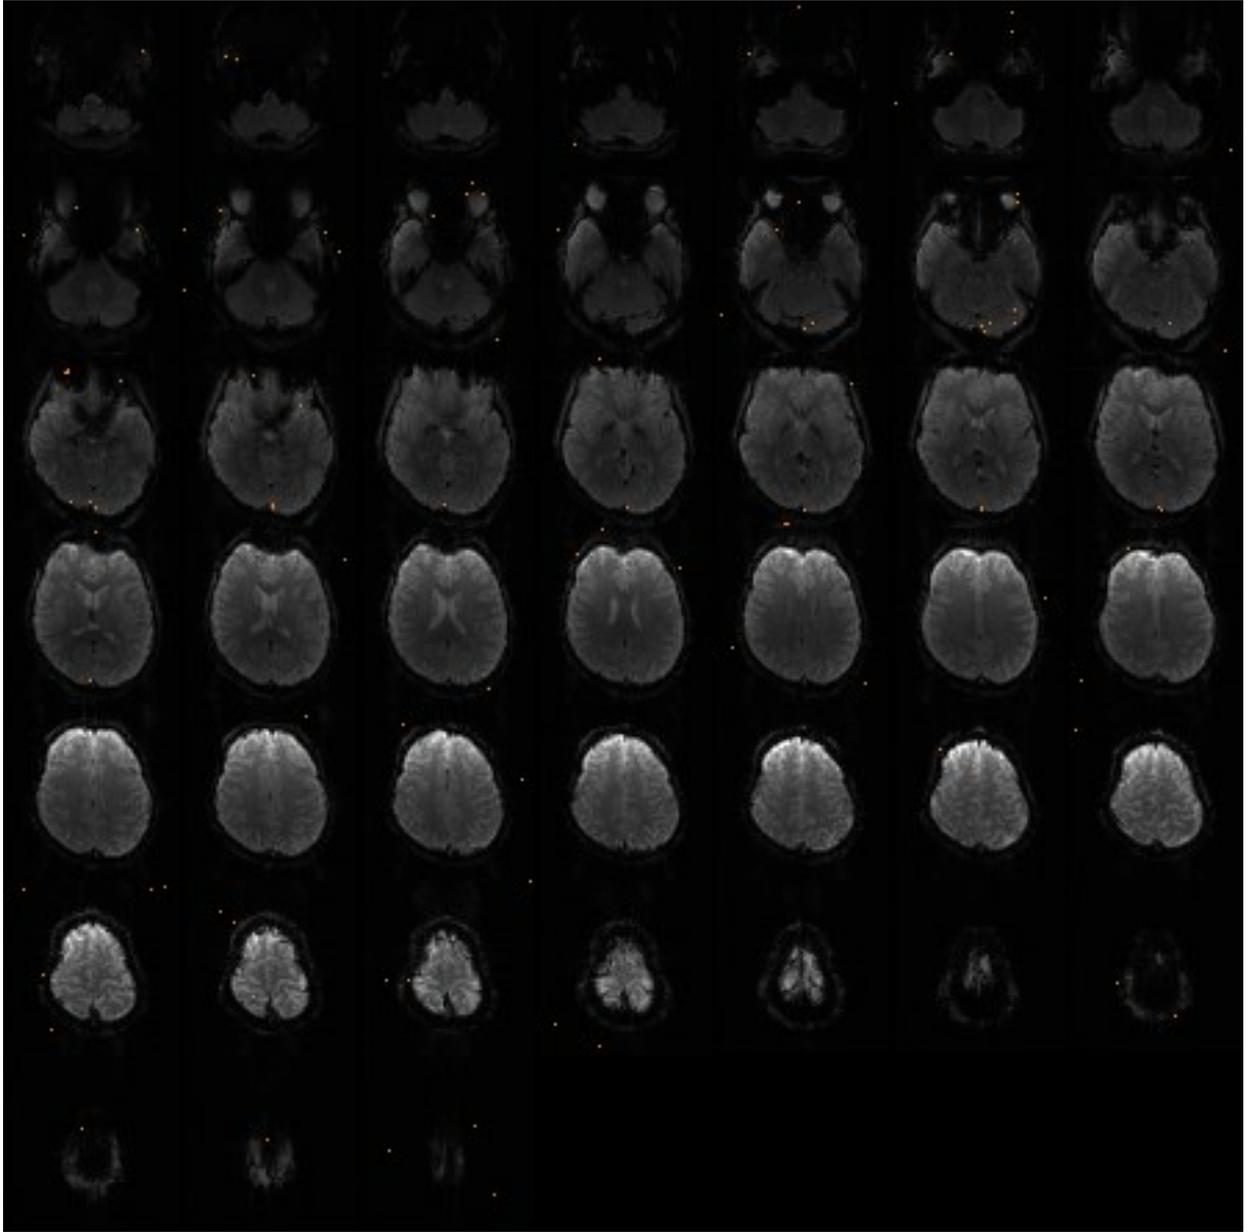


図 D.4 3 種類の図形識別で用いた上位 100 ボクセル 提案手法 2