

平成 26 年度

修士学位論文

# fMRI 信号を用いた脳情報デコーディング における特徴選択法に関する研究

A Study of Feature Selection for Brain Decoding  
from fMRI Signals

1175076 小池 規伎

指導教員 吉田 真一

2015 年 2 月 27 日

高知工科大学大学院 工学研究科 基盤工学専攻  
情報システム工学コース

# 要 旨

## fMRI 信号を用いた脳情報デコーディングにおける特徴選択法 に関する研究

小池 規伎

脳情報デコーディングとは、機器で計測した脳活動から機械学習アルゴリズムを用いて人間の活動や認知状態を推定する手法である。現在、主流である MVPA(Multi-Voxel Pattern Analysis) を用いる方法は、fMRI により脳活動の撮像を行い、単体では情報量の少ないボクセルの組み合わせをパターンとして扱うことで、高精度な推定を行うものである。fMRI は高い空間分解能を持ち、ボクセル情報は一般に高次元なデータとなるため、機械学習手法を適用するには ROI(Region of Interest; 関心領域) 解析をはじめとした統計処理によって、次元を削減する必要がある。本研究では、それぞれ異なる脳の領域を使うと考えられている 3 つのタスクを選択し、脳機能の計測を行うことで傾向の異なるデータセットを生成する。選択したタスクは、手指の運動タスク、視覚刺激タスク、感情誘発タスクの 3 種類である。そして生成したデータセットに対し、サポートベクターマシン、ニューラルネットワーク、ランダムフォレスト、スパースロジスティック回帰の 4 つの機械学習手法を適用し、比較検討を行う。実験の結果、前処理によるボクセル選択が有効に働く運動タスクにおいてはサポートベクターマシンが、特徴選択が難しい感情誘発タスクのような高次脳機能課題においてはスパースロジスティック回帰が有効であることを示す。

キーワード fMRI, 脳情報デコーディング, 特徴選択, サポートベクターマシン, ランダムフォレスト, ニューラルネットワーク, スパースロジスティック回帰

# Abstract

## A Study of Feature Selection for Brain Decoding from fMRI Signals

Noriki Koike

Brain decoding is a method to predict human activity or internal state of brain from brain neural activity information. MVPA(Multi-Voxel Pattern Analysis) is usually employed for brain decoding. Each brain voxel has small information and it is insufficient to predict. MVPA use a combination of multiple voxels as a pattern for recognition. The dimension of signals retrieved from fMRI is too high to employ machine learning algorithm. It is required to reduce dimensions by statistical analysis like ROI(Region of Interest) analysis. In this research, we select 3 tasks which are considered to activate different brain regions and generate datasets from brain activity of human subjects in the tasks. Imitate hand motion task, watch visual stimulus task, and evoke emotion task are selected. We apply 4 machine learning methods, support vector machines, neural networks, random forests, and sparse logistic regressions. The results show that support vector machines achieves the best accuracy in situation of the imitate hand motion task, and sparse logistic analysis achieves the best accuracy in the emotion task. It is because the feature selection is more difficult in the emotion task.

**key words** fMRI, brain decoding, feature selection, support vector machine, random forest, neural network, sparse logistic regression

# 目次

第 1 章	序論	1
第 2 章	脳情報デコーディング	3
第 3 章	機械学習手法	5
3.1	サポートベクターマシン (SVM)	5
3.2	ニューラルネットワーク (NN)	6
3.3	ランダムフォレスト (RF)	9
3.4	スパースロジスティック回帰 (SLR)	10
第 4 章	実験内容	13
4.1	運動 (手の形) 模倣タスク	13
4.1.1	被験者	14
4.1.2	fMRI 計測パラメータ	14
4.1.3	タスク内容	15
4.1.4	ROI 解析によるデータセットの生成	15
	被験者 1	16
	被験者 2	20
4.2	RGB 刺激提示タスク	25
4.2.1	被験者	25
4.2.2	fMRI 計測パラメータ	25
4.2.3	タスク内容	25
4.2.4	ROI 解析によるデータセットの生成	26
4.3	画像による感情誘発タスク	32
4.3.1	被験者	32

## 目次

4.3.2	fMRI 計測パラメータ . . . . .	32
4.3.3	タスク内容 . . . . .	32
4.3.4	ROI 解析によるデータセットの生成 . . . . .	33
<b>第 5 章</b>	<b>データ解析</b>	<b>35</b>
5.1	前処理 . . . . .	35
5.2	デコーダの構成と評価 . . . . .	35
5.2.1	SVM デコーダ . . . . .	36
5.2.2	ニューラルネットワークデコーダ . . . . .	37
5.2.3	ランダムフォレストデコーダ . . . . .	37
5.2.4	スパースロジスティック回帰デコーダ . . . . .	37
<b>第 6 章</b>	<b>結果と考察</b>	<b>38</b>
<b>第 7 章</b>	<b>結論</b>	<b>41</b>
	謝辞	43
	参考文献	44
<b>付録 A</b>	<b>各データセットの識別における混同行列</b>	<b>48</b>
A.1	運動模倣タスク (被験者 1) における混同行列 . . . . .	48
A.2	運動模倣タスク (被験者 2) における混同行列 . . . . .	52
A.3	RGB 刺激提示タスクにおける混同行列 . . . . .	56
A.4	画像による感情誘発タスクにおける混同行列 . . . . .	59

# 目次

3.1	Support Vector Machine . . . . .	7
3.2	ニューラルネットワーク . . . . .	8
3.3	ランダムフォレスト . . . . .	10
3.4	Sparse Logistic Regression . . . . .	12
4.1	被験者実験の様子 . . . . .	14
4.2	運動模倣タスク (1 ラン分) . . . . .	14
4.3	運動模倣タスク中の被験者 1 の右小脳における賦活領域 . . . . .	17
4.4	運動模倣タスク中の被験者 1 の左第 4 ブロードマン領野における賦活領域 . . . . .	18
4.5	運動模倣タスク中の被験者 1 の左補足運動野における賦活領域 . . . . .	19
4.6	運動模倣タスク中の被験者 2 の左小脳における賦活領域 . . . . .	20
4.7	運動模倣タスク中の被験者 2 の右小脳における賦活領域 . . . . .	21
4.8	運動模倣タスク中の被験者 2 の左第 4 ブロードマン領野における賦活領域 . . . . .	22
4.9	運動模倣タスク中の被験者 2 の右第 4 ブロードマン領野における賦活領域 . . . . .	23
4.10	運動模倣タスク中の被験者 2 の右補足運動野における賦活領域 . . . . .	24
4.11	RGB 刺激提示タスク (1 ラン分) . . . . .	25
4.12	RGB 刺激提示タスク中の左第 17 ブロードマン領野における賦活領域 . . . . .	27
4.13	RGB 刺激提示タスク中の右第 17 ブロードマン領野における賦活領域 . . . . .	28
4.14	RGB 刺激提示タスク中の左第 18 ブロードマン領野における賦活領域 . . . . .	29
4.15	RGB 刺激提示タスク中の右第 18 ブロードマン領野における賦活領域 . . . . .	30
4.16	RGB 刺激提示タスク中の右第 19 ブロードマン領野における賦活領域 . . . . .	31
4.17	画像による感情誘発タスク (1 ラン分) . . . . .	32
4.18	感情誘発タスク中の全脳における感情誘発タスク中の賦活領域 (1) . . . . .	34
4.19	感情誘発タスク中の全脳における感情誘発タスク中の賦活領域 (2) . . . . .	34

# 表目次

4.1	運動模倣タスクにおける刺激の提示順 . . . . .	15
4.2	RGB 刺激提示タスクにおける刺激の提示順 . . . . .	26
4.3	画像による感情誘発タスクにおける刺激の提示順 (r: レスト) . . . . .	33
6.1	実験結果 (Precision±S.D.(%)) . . . . .	38
A.1	運動模倣タスク (被験者 1) の SVM(線形カーネル) における混同行列 . . . . .	48
A.2	運動模倣タスク (被験者 1) の SVM(RBF カーネル) における混同行列 . . . . .	48
A.3	運動模倣タスク (被験者 1) の SVM(多項式カーネル) における混同行列 . . . . .	49
A.4	運動模倣タスク (被験者 1) の SVM(シグモイドカーネル) における混同行列 . . . . .	49
A.5	運動模倣タスク (被験者 1) の NN(3 層) における混同行列 (10 回分) . . . . .	49
A.6	運動模倣タスク (被験者 1) の NN(4 層) における混同行列 (10 回分) . . . . .	50
A.7	運動模倣タスク (被験者 1) の RF(ntree=500) における混同行列 . . . . .	50
A.8	運動模倣タスク (被験者 1) の RF(ntree=1000) における混同行列 . . . . .	50
A.9	運動模倣タスク (被験者 1) の SLR-VAR における混同行列 . . . . .	51
A.10	運動模倣タスク (被験者 1) の SLR-LAP における混同行列 . . . . .	51
A.11	運動模倣タスク (被験者 2) の SVM(線形カーネル) における混同行列 . . . . .	52
A.12	運動模倣タスク (被験者 2) の SVM(RBF カーネル) における混同行列 . . . . .	52
A.13	運動模倣タスク (被験者 2) の SVM(多項式カーネル) における混同行列 . . . . .	52
A.14	運動模倣タスク (被験者 2) の SVM(シグモイドカーネル) における混同行列 . . . . .	53
A.15	運動模倣タスク (被験者 2) の NN(3 層) における混同行列 (10 回分) . . . . .	53
A.16	運動模倣タスク (被験者 2) の NN(4 層) における混同行列 (10 回分) . . . . .	53
A.17	運動模倣タスク (被験者 2) の RF(ntree=500) における混同行列 . . . . .	54
A.18	運動模倣タスク (被験者 2) の RF(ntree=1000) における混同行列 . . . . .	54

## 表目次

A.19 運動模倣タスク (被験者 2) の SLR-VAR における混同行列 . . . . .	54
A.20 運動模倣タスク (被験者 2) の SLR-LAP における混同行列 . . . . .	55
A.21 RGB 刺激タスクの SVM(線形カーネル) における混同行列 . . . . .	56
A.22 RGB 刺激タスクの SVM(RBF カーネル) における混同行列 . . . . .	56
A.23 RGB 刺激タスクの SVM(多項式カーネル) における混同行列 . . . . .	56
A.24 RGB 刺激タスクの SVM(シグモイドカーネル) における混同行列 . . . . .	57
A.25 RGB 刺激タスクの NN(3 層) における混同行列 (10 回分) . . . . .	57
A.26 RGB 刺激タスクの NN(4 層) における混同行列 (10 回分) . . . . .	57
A.27 RGB 刺激タスクの RF(ntree=500) における混同行列 . . . . .	58
A.28 RGB 刺激タスクの RF(ntree=1000) における混同行列 . . . . .	58
A.29 RGB 刺激タスクの SLR-VAR における混同行列 . . . . .	58
A.30 RGB 刺激タスクの SLR-LAP における混同行列 . . . . .	58
A.31 感情誘発タスクの SVM(線形カーネル) における混同行列 . . . . .	59
A.32 感情誘発タスクの SVM(RBF カーネル) における混同行列 . . . . .	59
A.33 感情誘発タスクの SVM(多項式カーネル) における混同行列 . . . . .	59
A.34 感情誘発タスクの SVM(シグモイドカーネル) における混同行列 . . . . .	60
A.35 感情誘発タスクの NN(3 層) における混同行列 (10 回分) . . . . .	60
A.36 感情誘発タスクの NN(4 層) における混同行列 (10 回分) . . . . .	60
A.37 感情誘発タスクの RF(ntree=500) における混同行列 . . . . .	60
A.38 感情誘発タスクの RF(ntree=1000) における混同行列 . . . . .	61
A.39 感情誘発タスクの SLR-VAR における混同行列 . . . . .	61
A.40 感情誘発タスクの SLR-LAP における混同行列 . . . . .	61



# 第 1 章

## 序論

脳情報デコーディングとは，人間の活動や認知状態を，機器で計測した脳波や脳活動をもとに推定する手法である [1]．この技術を用いることで，想起によってコンピュータへの入力を行うことができる BCI(Brain Computer Interface) や，想起画像検索への応用が考えられる．これらは体の不自由な人でも操作できるコンピュータや，ノンバーバルな情報を取り扱えるユーザインタフェースに応用することで社会に役立てることができる．

脳情報デコーディングでは，MVPA(Multi-Voxel Pattern Analysis) を用いる方法が主流である．これは，人間の脳の状態を高い空間分解能で計測できる fMRI(functional Magnetic Resonance Imaging) 装置で計測した BOLD 信号から，機械学習の手法を用いて高精度に人間の状態を推定する手法である．現在 fMRI 実験で用いられているボクセルサイズは一般的に  $3\text{ mm} \times 3\text{ mm} \times 3\text{ mm}$  の立方体であり，これは脳神経細胞のサイズに比べて非常に大きいため，ボクセル一つ一つが持つ情報量は小さい．しかし，複数のボクセルの組み合わせをパターンとして扱うことで，高精度な推定が可能となっている．

脳の状態を撮像した fMRI 画像は非常に次元が高く複雑なデータであるため，機械学習手法で分析を行う前に，SPM(Statistical Parametric Mapping) による一般線形モデル (General Linear Model; GLM) を用いたボクセルごとの  $t$  検定や，ROI(Region of Interest; 関心領域) 解析などの前処理を行って次元を削減する必要がある．脳情報デコーディングでは特徴の次元削減は重要な要素となっている．

本研究では，運動模倣タスク，RGB 刺激提示タスク，画像刺激による感情誘発という 3 つのタスクで得られた脳画像データセットに対して，GLM を用いた統計的な前処理と，サポートベクターマシン (SVM)，ニューラルネットワーク (NN)，ランダムフォレスト (RF)，

スパースロジスティック回帰 (SLR) の 4 つの機械学習手法を用いた識別を行う。その結果から、高次元データに対する特徴抽出について検討し、前処理によって十分に次元削減ができていなければサポートベクターマシンが、事前の特徴選択が難しい高次脳機能課題においてはスパースロジスティック回帰が有効であることを示す。

まず第 2 章では、脳情報デコーディングの概要とその先行研究について書き、本研究で着目する機械学習と特徴選択について書く。第 3 章では、本研究で用いる 4 つの機械学習手法の基本的知識と特性について解説する。第 4 章では、比較に用いるデータセットを生成するために行った 3 つの被験者実験について書く。第 5 章では、データセットに対する前処理と比較するデコーダとそのパラメータについて書く。第 6 章では、各データセットにおける各デコーダの推定精度を示し、得られた結果に対する考察を行う。第 7 章で研究全体についてまとめる。

## 第 2 章

# 脳情報デコーディング

脳情報デコーディングとは、装置で計測した人間の脳状態の変化から、人間の活動や認知状態を推定する手法である。人間の脳には局在性があり、部位によってはたらきが異なっている。よって、脳波や部位ごとの脳血流量の変化を計測し、人間の状態と結びつけることで、脳情報のみから人間の認知や考えていることを読み取ることが可能になる。脳の大きさや形状には個人差があり、実際の脳の位置にはずれがあるため、機械学習の手法で個人に合わせて異なるボクセルを特徴量として選択する。

現在主流となっている手法は、空間分解能が高く 3 次元的に撮像することができる fMRI(functional Magnetic Resonance Imaging) 装置を用いた MVPA(Multi-Voxel Pattern Analysis) [17, 18] である。現在の fMRI 装置の解像度は  $3 \times 3 \times 3$  mm が主流である。これは脳の神経細胞よりはるかに大きく、異なる現象に反応するニューロンが一つの画素に含まれてしまう。しかし、関係のある複数のボクセルを組み合わせ、パターンとして扱うことで、解像度が低いまま高精度な推定ができる。代表的な研究として、2005 年に、Miyawaki らによって被験者が見ている線分の角度のデコードが行われている [1]。また、2008 年には被験者が見ている  $10 \times 10$  ピクセルの白黒画像の各画素を、異なる解像度の画像を推定して足し合わせるモジュラ・デコーディングの手法によってデコードしている [12]。2013 年には Horikawa らによって、眠っている人が見ている夢のデコードが実際に行われている [21]。

fMRI は高い空間分解能を持っているため、ボクセル情報は 10 万次元を超える高次元データとして得られる。そのままでは次元数が大きすぎるため、統計的に有意なボクセルのみを抽出したり、ROI(Region of Interest; 関心領域) を設定することで次元を削減する必要

がある．次元削減による特徴選択の考え方は，脳情報デコーディングにおいて重要な考え方であり，いくつかの先行研究が存在する．Miyawaki らは，SPM(Statistical Parametric Mapping) による，GLM を用いた回帰分析と統計処理，および機械学習アルゴリズムによる重みづけにより，信号の有意性が低すぎるボクセルを除去している [19]．Fujiwara らは，被験者が見ている画像とボクセルデータを結びつけるための基底を Bayesian CCA(Canonical Correlation Analysis; 正準相関分析) によって求めることで特徴選択を行っている [20]．

本研究では，回帰分析と統計処理による特徴選択に注目する．脳活動部位の異なる 3 種類のタスクを行うことでデータセットを生成し，前処理による次元削減ののち 4 種類の機械学習アルゴリズムを適用することで，タスクに合った特徴選択と機械学習手法について考察する．

## 第 3 章

# 機械学習手法

本章では、本論文で用いる 4 つの機械学習手法について説明する。

### 3.1 サポートベクターマシン (SVM)

サポートベクターマシン (Support Vector Machines; SVM) とは、マージン最大化による高い汎化性能を持つ、ノンパラメトリックな教師あり学習手法である。特徴空間における決定関数と特徴ベクトルのマージンを最大化することで未知のデータを効率よく識別できる。1995 年に Vapnik らによって提案された [3]。サポートベクターマシンという名前のとおり、学習結果となる分離超平面から最短距離にあるベクター (サポートベクター) を求める。サポートベクターだけを用いれば、他のベクターを使わなくても同じ超平面を見つけられるため、実質的な特徴削減が可能である。図 3.1 が、サポートベクターマシンの特徴空間上における決定関数のふるまいを簡潔に表したものである。

SVM の分離超平面を求める最適化問題は式 (3.1)、制約条件は式 (3.2) で定義される。 $K(\mathbf{x}, \mathbf{x}')$  はカーネル関数である。カーネル関数は、ベクトル  $\mathbf{x}$  と  $\mathbf{x}'$  をより高次元の特徴空間に写像することで、非線形な識別が可能となる。カーネル関数は学習データに適したものを適宜選択する。

$$\max Q(\alpha) = \sum_{i=1}^M \alpha_i - \frac{1}{2} \sum_{i,j=1}^M \alpha_i \alpha_j y_i y_j K(\mathbf{x}, \mathbf{x}') \quad (3.1)$$

$$\text{s.t. } \sum_{i=1}^M y_i \alpha_i = 0, \quad 0 \leq \alpha_i \leq C (i = 1, \dots, M) \quad (3.2)$$

### 3.2 ニューラルネットワーク (NN)

また，決定関数は式 (3.3) となる． $S$  はサポートベクターの添字集合である．

$$D(x) = \sum_{i \in S} \alpha_i y_i K(\mathbf{x}, \mathbf{x}') + b \quad (3.3)$$

最大の利点として，マージンを最大化することで，高い汎化性能を実現できること，解が一意に収束するため，多層ニューラルネットワークで発生しやすい局所解の問題を回避できること，線形分離しづらい高次元データでもサポートベクターを用いた次元削減とカーネルの利用によりデータ群の分割ができること，ノンパラメトリックな手法であるため，脳情報デコーディングのような，データ分布を求めることが出来ない問題にも適用できることが挙げられる．

脳情報デコーディングの研究においては，fMRI を用いたリアルタイム性の高いデコーディング [11] や，人間の視覚野の方位選択性のデコーディング [1] に用いられている．方位選択性のデコードでは，線形 SVM による複数の学習器が，視覚野のそれぞれ異なる複数のボクセルに対応付けられ，パターンの変化から被験者の見ている方位をデコードする集団学習に似た手法を用いている．

### 3.2 ニューラルネットワーク (NN)

ニューラルネットワーク (Neural Network; NN) とは，教師あり学習によって，人間の神経細胞を模した素子で学習器を構成する手法のひとつである．

人間の神経回路を構成するニューロン（神経細胞）の働きを模したニューロン素子を複数つなぎ合わせることで実現する．人間のニューロンは，複数のニューロンからの電気信号（インパルス）を受け取って総和をとり，一定の強さに達すると別のニューロンへの出力を行う働きをする．入力を受け取る各ニューロンからのインパルスは，シナプス結合の強さによって重み付けされる．出力先は複数存在するが，すべての出力先に同一の値を出力する．人工的にニューロンのはたらきを模したニューロン素子を並列に接続することで，特徴ベクトルの学習を行うのがニューラルネットワークである．人間のニューロンが全か無かの法則

### 3.2 ニューラルネットワーク (NN)




図 3.1 Support Vector Machine

に従って 1 もしくは 0 を出力するのに対し，人工的なニューラルネットワークは微分可能な伝達関数を用いる．

本研究で用いるのはフィードフォワード型階層型ニューラルネットワークで実現した，バックプロパゲーション（誤差逆伝播法）で学習する多層パーセプトロンである．この手法は Rumelhart らが 1986 年に提案した [13]．入力  $v$  に対する教師信号と出力  $y$  の誤差を元に，階層を逆に辿る形で，入力の重み  $w_{kij}$  を更新する． $k, j, i$  はそれぞれ層の番号，入力元ニューロンの番号，出力先ニューロンの番号を意味する．ニューラルネットワークは，教師信号との誤差が一定の値より小さくなるまで，重み  $w_{kij}$  の更新を繰り返すことで関数近似する． $k$  層  $j$  番目のニューロン単体の出力  $Q_{kj}$  は式 (3.4) となる． $b_{kj}$  は  $k$  層の  $j$  番目のニューロンのバイアス（定数項）， $f, g$  は伝達関数である．伝達関数には通常，式 (3.5) に示

### 3.2 ニューラルネットワーク (NN)

したシグモイド関数を用いる．終端に位置する出力層のニューロンの出力が，最終的な出力  $y$  となる．

$$Q_{kj} = f\left(\sum_{i=1}^N Q_{k-1i} w_{kij} + b_{kj}\right) \quad (3.4)$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.5)$$

特徴として，ノイズに強く，非線形の学習にも対応できることが挙げられる．その特徴からパターン認識に適し，手書き文字認識や音声認識に用いられている．

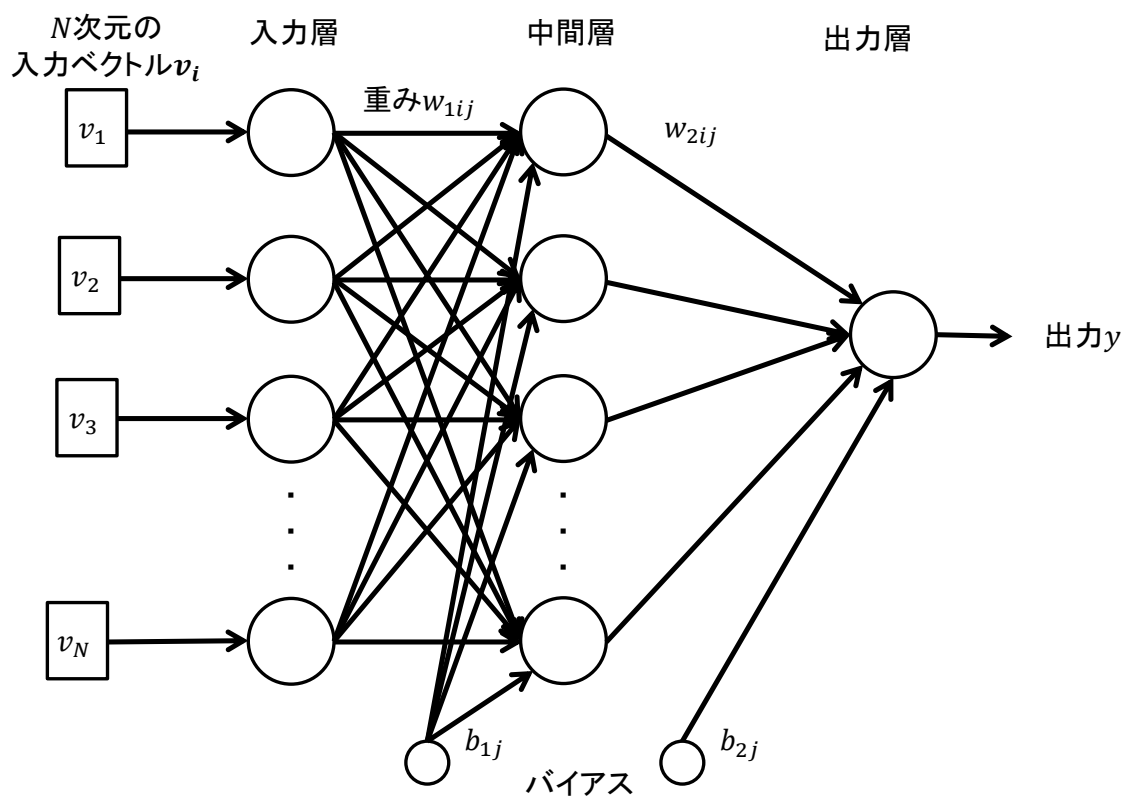


図 3.2 ニューラルネットワーク



### 3.3 ランダムフォレスト (RF)

## 3.3 ランダムフォレスト (RF)

ランダムフォレスト (Random Forests; RF) とは、複数の 2 分決定木を用いた集団学習アルゴリズムのひとつである。1996 年に Breiman によって提案された [14]。データ集合からランダムに抜き出したサブサンプルから二分決定木を複数本作ることで学習器を構成する。クラス推定にも回帰問題にも用いることができる [15]。

ランダムフォレストの学習アルゴリズムを以下に示す。教師データ  $t_i$  と特徴ベクトル  $\mathbf{v}_i$  が一組になった訓練データ集合が存在するとする。教師データ  $t_i$  はいずれかのクラスに属する。ただし  $i = 1, \dots, N$  とする。

1. サンプルデータ集合から、ランダムにデータを選択してサブサンプル集合とする。重複や使われないデータがあっても構わない。
2. 1 を繰り返してサブサンプル集合を  $n$  個作る。
3. それぞれのサブサンプル集合の変数から 2 分決定木の根ノードを  $n$  本作る。
4. 決定木の各ノードの分岐関数  $h_i(\mathbf{v}, \theta)$  を求めてサブサンプルを 2 つに分割し、2 つのノードを作成する。 $\theta$  はパラメータであり、候補からランダムに抽出される。
5. それぞれの木で、終了条件を満たすまで再帰的にノードを作り続ける。

2 分決定木の各ノードの分岐関数  $h_i(\mathbf{v}, \theta)$  は単純な線形関数で、2 クラス分類を行うため出力は 0 もしくは 1 である。パラメータ  $\theta$  はパラメータ候補の中から、分割後のエントロピーの差が最大になるような値が選択される。分割前の特徴空間は、それぞれのクラスに属するベクトルが、どちらのクラスも同じように存在すると考えられる。パラメータ  $\theta$  を調整することで、片方の領域にはあるクラスが、もう片方の領域には別のクラスが多く分布するように分割する。ただしすべての候補を試すと計算量がかかりすぎてしまうため、パラメータ候補はランダムに抽出したものを利用する。1 つのクラスとそれ以外への分割をくり返すことで、最終的な出力  $p_i(t|\mathbf{v})$  は、もっとも属する可能性が高いクラスラベルとなる。推定の際は、属する可能性の高いクラス  $p_i(t|\mathbf{v})$  を全ての決定木で求め、多数決で結果を出す。

利点として、ランダムにサブサンプルを選択するため、大量のサンプルデータを学習して

### 3.4 スパースロジスティック回帰 (SLR)

も計算量を抑えられること，ランダム性の導入により決定木同士の相関を下げ，高い汎化性能を実現できることが挙げられる．特徴抽出の面から見ると，ランダムに特徴選択を行うためノイズを抽出してしまう危険性があるものの，あらかじめ使用する特徴の数決めておくため，処理そのものが複雑にならないといえる．しかしランダムに選ぶ以上，有意な特徴よりもノイズははるかに多いデータの学習には向かないため，脳情報デコーディングに用いる場合は本研究のようにあらかじめ前処理を行い，ある程度次元削減をしておく必要がある．

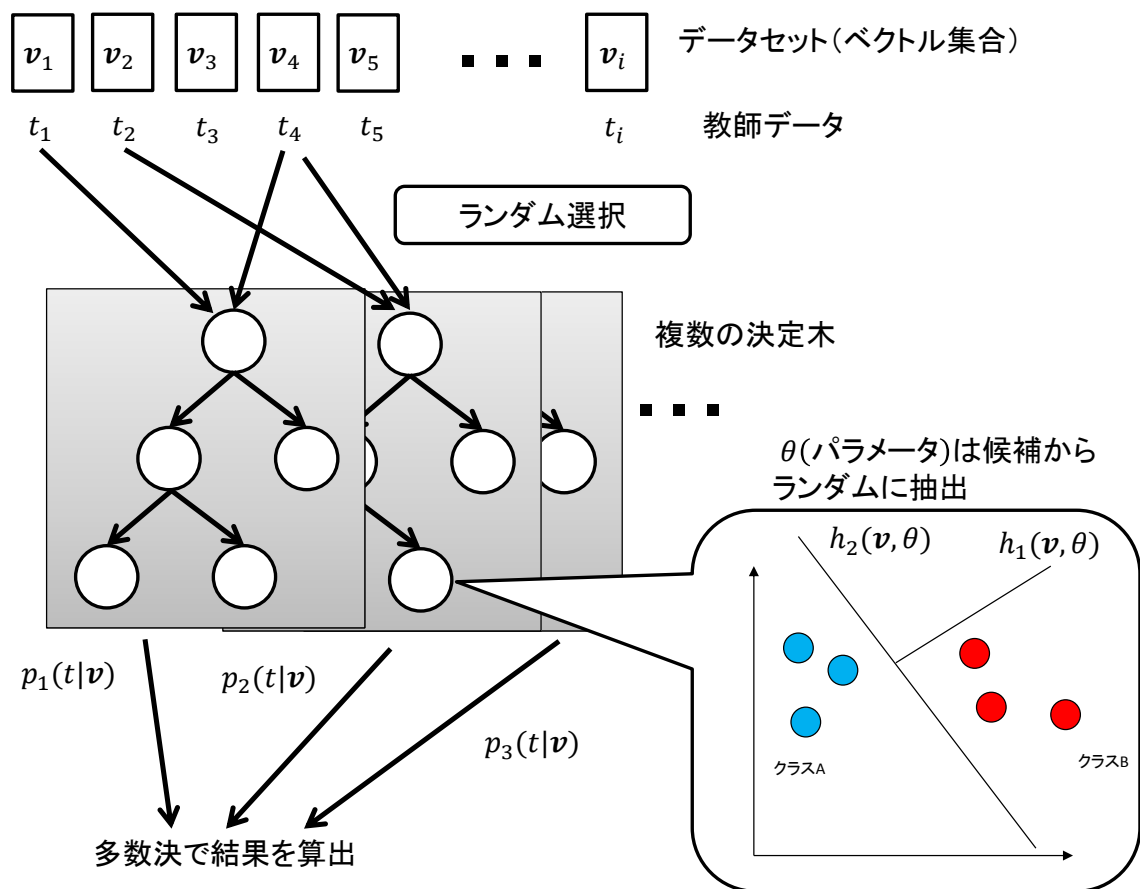


図 3.3 ランダムフォレスト

### 3.4 スパースロジスティック回帰 (SLR)

スパースロジスティック回帰 (Sparse Logistic Regression; SLR) とは，脳情報デコーディングへの活用を前提として提案された，ロジスティック回帰をベイズ推定の枠組みで拡張し

### 3.4 スパースロジスティック回帰 (SLR)

た手法である．2008 年に Yamashita らによって提案された [16] ．

SLR の特徴として，特徴量の重みの推定に，Automatic Relevance Determination (ARD) を用いることが挙げられる．ARD はベイズ推定の事前分布を用いた手法で，重み  $\theta$  を周辺化事後確率として推定するものである．推定の際には，学習した重み  $\theta^i$  からクラスに属する確率  $p^i$  をクラスごとに求め，最も属する可能性の高いクラスを出力  $y$  として返す．2 つのステップに分かれており，判別の前に不要な特徴量の重みをゼロする処理を行っている．

SLR には複数の方式があり，本研究ではラプラス近似を用いる方法 (LAP) と変分型近似を用いる方法 (VAR) の 2 種類を取り扱う．LAP はパラメータをラプラス近似で求める手法である [16] ．SLR はベイズ推定を用いるため，周辺化事後確率の分布はガウス分布とは限らなくなる．そこで多変量ガウス分布で近似を行う．VAR は LAP を改良したもので，ロジスティック関数をガウス分布で近似する手法である [24–26] ．VAR は LAP に比べ，メモリ消費と速度の面で改善されている [23] ．

SLR の特徴として，スパース性が高いことが挙げられる．結果との相関が低い不要な特徴量は，対応する重みがほとんどゼロになるため実質的に除外される．よって効率のよい次元圧縮が可能となっている．SLR は，視覚野の活動から画像を再構成するためのデコーダに用いられている [12] ．

### 3.4 スパースロジスティック回帰 (SLR)

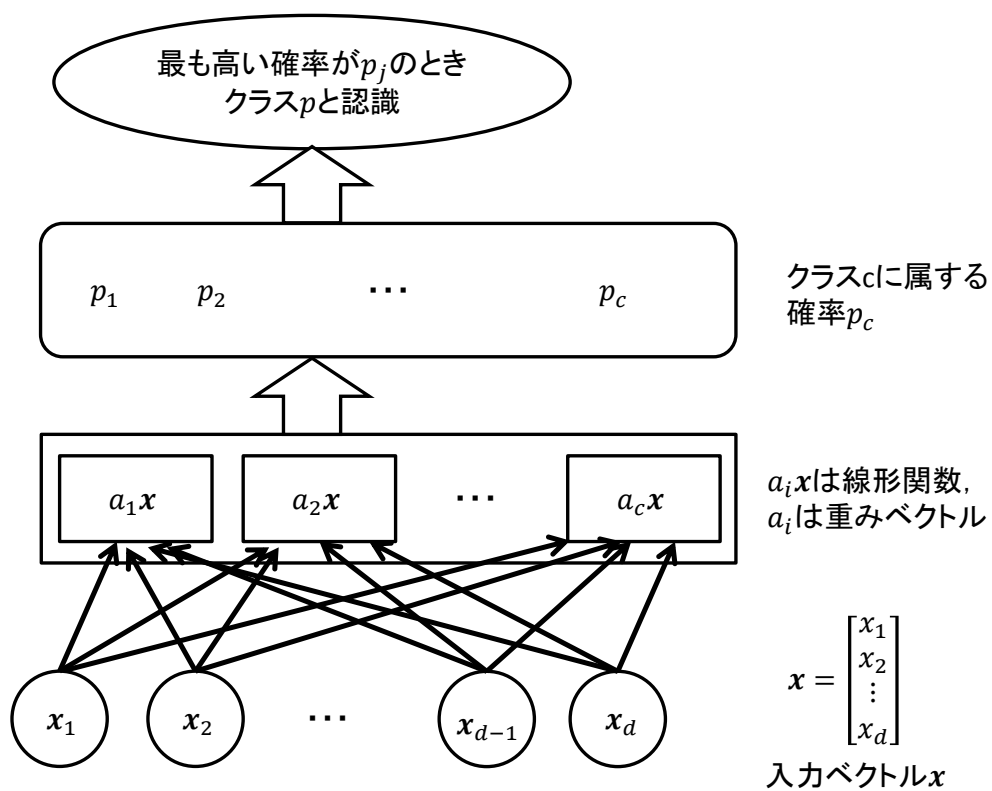


図 3.4 Sparse Logistic Regression

## 第 4 章

# 実験内容

本章では、デコーダ評価用のデータセットを作るために行った実験の内容について説明する。

本論文では、運動野、視覚野、高次脳機能の識別課題それぞれに対するデコーダの性能を明らかにするために、運動模倣タスク、RGB 刺激提示タスク、画像刺激による感情誘発という 3 種類の実験タスクによって得られた計 4 つのデータセットを用いてデコーダの評価を行う。運動模倣タスクは運動野からの運動指令の、RGB 刺激提示タスクは視覚野の認知状態の、画像による感情誘発タスクは高次脳機能のデコードを目的としたタスクである。各実験デザインはブロックデザインの考え方に基づいて行われる。いずれのタスクも、fMRI 装置内の被験者に対し、刺激画像を LCD プロジェクターで投影することで行う (図 4.1)。なお、本実験は高知工科大学倫理審査委員会 C3-2 にて承認されており、被験者には実験内容についての説明をした後、書面にて実験参加に同意の意思を確認している。各実験の被験者数は少数だが、これは脳情報デコーダが各個人にフィッティングされるため、多数の被験者を用いずとも特徴選択手法・機械学習手法の比較には十分であること、fMRI 実験自体が多数の被験者で実験しづらいことによる。

### 4.1 運動 (手の形) 模倣タスク

fMRI 装置内の被験者に、提示した手の形 (グー、チョキ、パー) を模倣させるタスクを行う (図 4.2)。

## 4.1 運動(手の形)模倣タスク




図 4.1 被験者実験の様子




図 4.2 運動模倣タスク (1 ラン分)

### 4.1.1 被験者

被験者は 20 代の男性 2 名である。被験者は fMRI 装置についての説明と実験の概要、安全性、個人情報保護についての説明を受け、書面にて同意の旨を提出した上で参加した。

### 4.1.2 fMRI 計測パラメータ

fMRI 装置として、本学脳コミュニケーション研究センターに設置された SIEMENS 社の MAGNETOM Verio(3T) を使用する。撮像パラメータは、FOV = 192[mm], 1 スライスあたりのボクセル数が  $64 \times 64$  [matrix], 1 ボクセルあたりのサイズが  $3 \times 3 \times 3$ [mm], スラ

#### 4.1 運動(手の形)模倣タスク

イス数が 50 枚, TE = 50[ms], フリップアングル 90°, TR = 5[s] である.

##### 4.1.3 タスク内容

表 4.1 は, 被験者に提示した刺激の提示順である. 刺激は画像刺激と音声刺激の 2 つを用いる. 被験者は画像が提示されている間, ペーシング音に合わせて, スクリーン上に提示された画像と同じ手を右手で繰り返し模倣する. 1 回の刺激画像提示で 4 スキャン分のデータを撮像する. 1 ラン中に 6 回の刺激画像提示を含み, 同一の試行を 10 ラン分行う.

表 4.1 運動模倣タスクにおける刺激の提示順

時間 [s]	0	20	40	60	80	100	120	140
ラン 1	レスト	チョキ	グー	パー	グー	パー	チョキ	レスト
ラン 2	レスト	チョキ	パー	グー	グー	チョキ	パー	レスト
ラン 3	レスト	グー	チョキ	パー	グー	パー	チョキ	レスト
ラン 4	レスト	パー	グー	チョキ	グー	チョキ	パー	レスト
ラン 5	レスト	チョキ	パー	グー	グー	チョキ	パー	レスト
ラン 6	レスト	パー	チョキ	グー	パー	グー	チョキ	レスト
ラン 7	レスト	パー	グー	チョキ	グー	パー	チョキ	レスト
ラン 8	レスト	チョキ	パー	グー	チョキ	グー	パー	レスト
ラン 9	レスト	チョキ	グー	パー	グー	パー	チョキ	レスト
ラン 10	レスト	グー	チョキ	パー	チョキ	パー	グー	レスト

##### 4.1.4 ROI 解析によるデータセットの生成

撮像された画像は, レスト (1 ランあたり 8 スキャン) を含めた 4 クラスのラベルを持つ, 一人あたり 320 サンプル  $64 \times 64 \times 50$  次元のデータセットとして扱う. こうして得られたデータセットに対して, SPM(Statistical Parametric Mapping) [4] を用いて, 体動による

#### 4.1 運動(手の形)模倣タスク

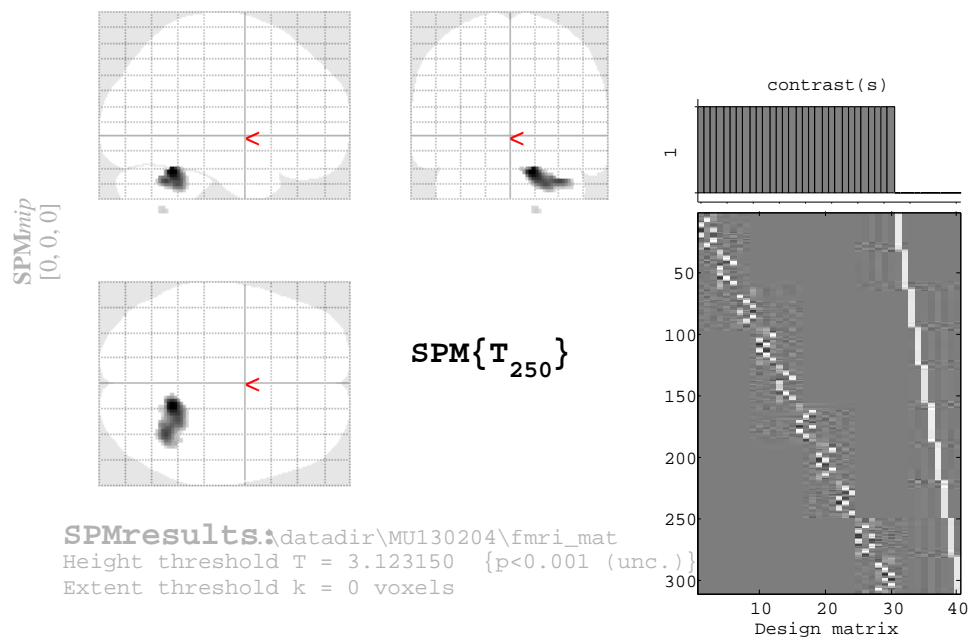
ブレの除去, 個人座標系から MNI 標準脳へのノーマライズ, ボクセルに対するスムージング, ROI の設定, 統計解析を行う. ROI は運動に関連する脳領域として, 右脳および左脳それぞれの第 4 ブロードマン領野 (brodmann area 4), 小脳 (Cerebellum), 補足運動野 (Supplementary Motor Area; SMA) とする [22]. 第 4 ブロードマン領野は, 脳部位が一次運動野 (Primary Motor Cortex; M1) に対応しているため設定した. 各 ROI ごとに統計解析を行い, 有意な活動が見られるクラスタのうち, 最も大きいクラスタを選択する. 統計値の有意水準は  $p < 0.001$  とする. この実験のみ, 二人分の脳画像から 2 つのデータセットを生成した.

##### 被験者 1

有意な活動が見られたのは右小脳 (図 4.3), 左第 4 ブロードマン領野 (図 4.4), 左補足運動野 (図 4.5) である. 右小脳からは 407 ボクセル, 左第 4 ブロードマン領野からは 100 ボクセル, 左補足運動野からは 24 ボクセル, 合計 531 ボクセルを選択した.



#### 4.1 運動 (手の形) 模倣タスク



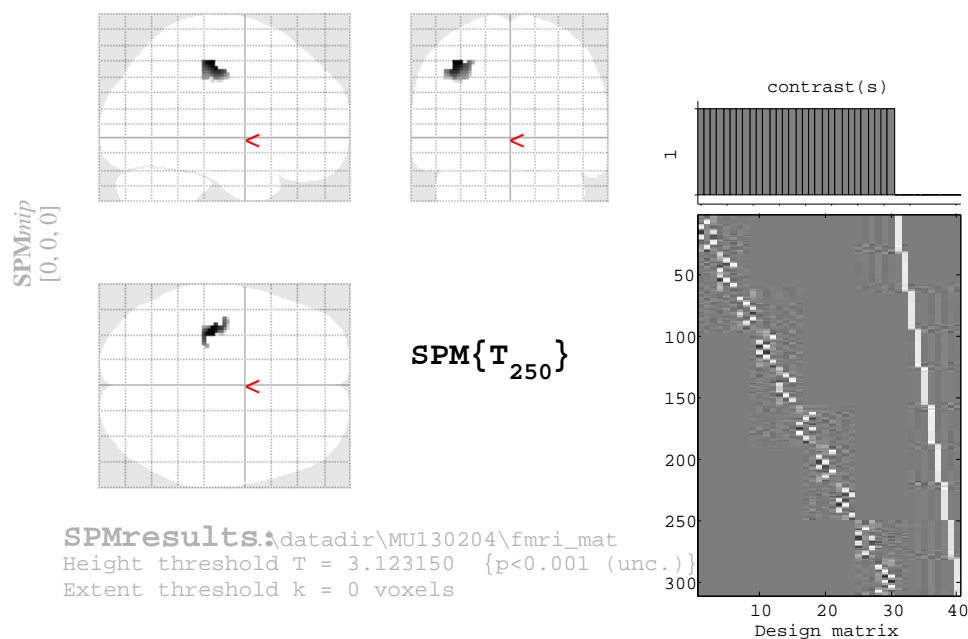
**Statistics: p-values adjusted for search volume**

set-level		cluster-level			voxel-level					x, y, z {mm}
p	c	p corrected	k <sub>E</sub>	p uncorrected	p FWE-corr <sup>F</sup>	p FDR-corr <sup>F</sup>	T	(Z <sub>≡</sub> )	p uncorrected	
0.102	2	0.000	407	0.000	0.000	0.000	6.93	6.62	0.000	14 -50 -24
					0.000	0.000	5.70	5.52	0.000	34 -54 -30
					0.000	0.000	5.54	5.38	0.000	24 -46 -32
		0.202	10	0.418	0.233	0.007	3.40	3.36	0.000	18 -56 -50

図 4.3 運動模倣タスク中の被験者 1 の右小脳における賦活領域

図 4.3 は、右小脳におけるレストとそれ以外 (3 種の運動) の条件間の賦活領域を示している。2 つのクラスタが存在し、より大きいクラスタが選択された。選択されたクラスタのサイズは 407 ボクセル、ピークの  $t$  値は 6.93 であり、被験者 1 から得られるテストデータの大部分を占める。

#### 4.1 運動 (手の形) 模倣タスク



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

set-level		cluster-level			voxel-level					x, y, z {mm}			
<i>p</i>	<i>c</i>	<i>p</i> corrected	<i>k</i>	<i>E</i>	<i>p</i> uncorrected	<i>p</i> FWE-corr	<i>p</i> FDR-corr	<i>T</i>	( <i>Z</i> )	<i>p</i> uncorrected			
0.002	2	0.001	100	0.017	0.000	0.000	10.03	Inf	0.000		-36	-22	50
		0.048	1	0.829	0.015	0.001	3.55	3.50	0.000		-34	-22	38

図 4.4 運動模倣タスク中の被験者 1 の左第 4 ブロードマン領野における賦活領域

図 4.4 は、左第 4 ブロードマン領野におけるレストとそれ以外の条件間の賦活領域を示している。2 つのクラスタがあり、最も大きいクラスタを選択した。選択したクラスタのサイズは 100 ボクセルで、ピークの  $t$  値は最も高く 10.03 である。

## 4.1 運動 (手の形) 模倣タスク

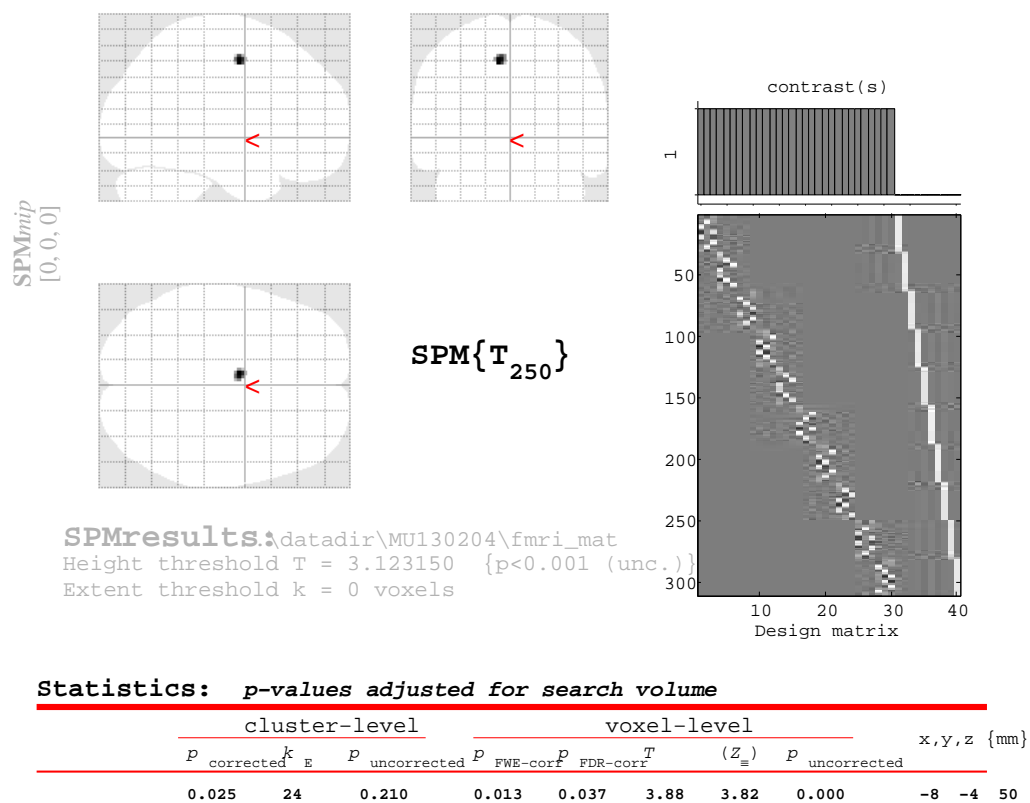


図 4.5 運動模倣タスク中の被験者 1 の左補足運動野における賦活領域

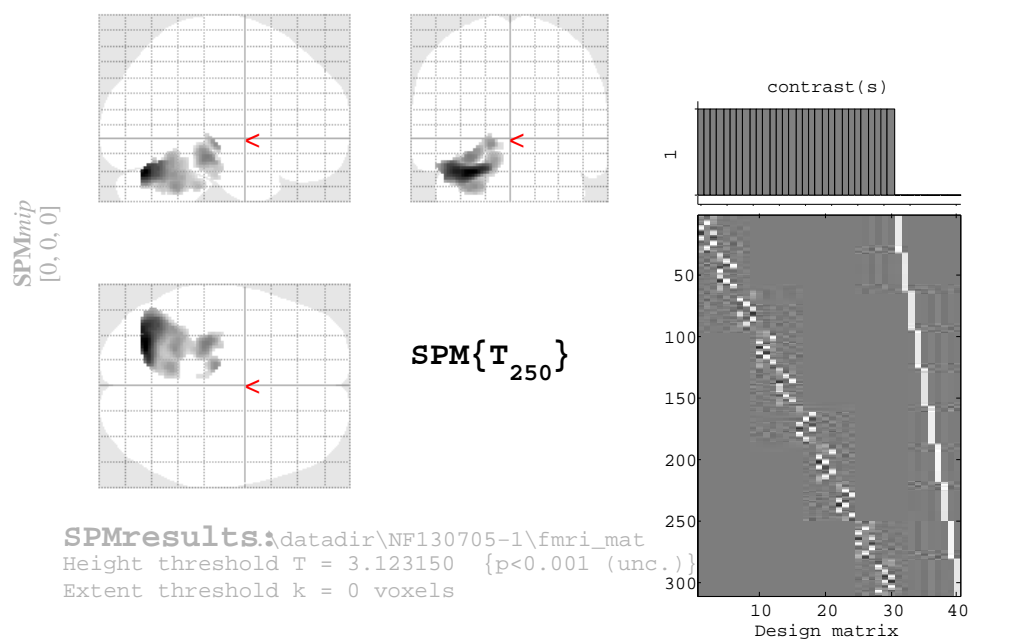
図 4.5 は、左補足運動野におけるレストとそれ以外の条件間の賦活領域である。クラスターが 1 つだけ存在し、サイズは 24 ボクセルと小さく、ピークの  $t$  値は 3.88 である。

## 4.1 運動 (手の形) 模倣タスク

### 被験者 2

有意な活動が見られたのは左小脳 (図 4.6), 右小脳 (図 4.7), 左第 4 ブロードマン領野 (図 4.8), 右第 4 ブロードマン領野 (図 4.9), 右補足運動野 (図 4.10) である。左小脳からは 1572 ボクセル, 右小脳からは 2451 ボクセル, 左第 4 ブロードマン領野からは 8 ボクセル, 右第 4 ブロードマン領野からは 21 ボクセル, 右補足運動野からは 21 ボクセル, 合計 4062 ボクセルを選択した。

被験者 1 と比べると, 選択されたボクセル数の合計が 8 倍近い大きさになっている。また, 有意な活動が見られた ROI が多く, 小脳の賦活領域のクラスタサイズが大きい。逆に, 小脳以外の賦活領域におけるクラスタサイズは小さいものとなっている。



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

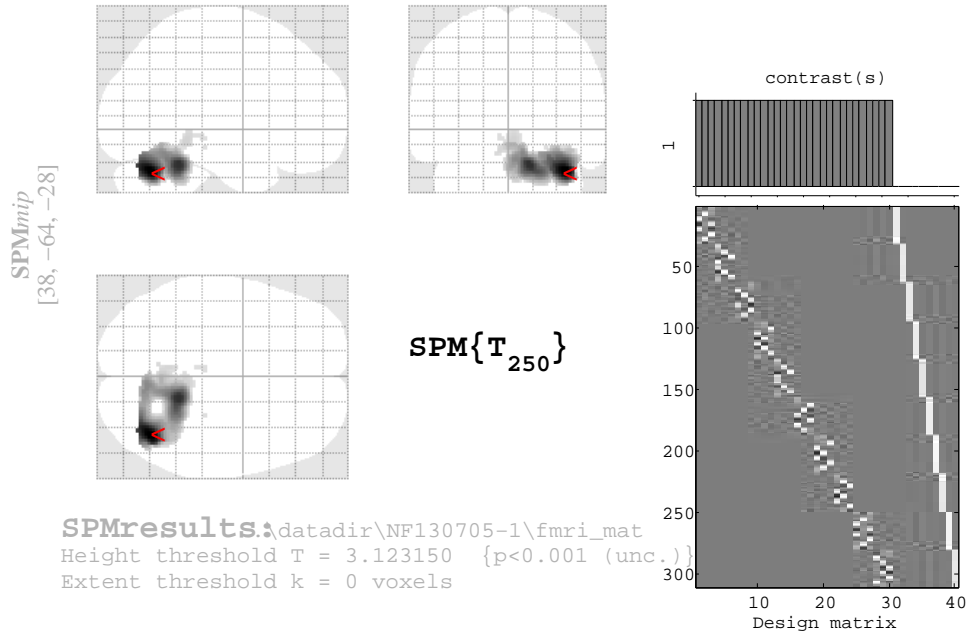
set-level		cluster-level			voxel-level					x, y, z {mm}
P	c	P corrected	k <sub>E</sub>	P uncorrected	P FWE-corr	P FDR-corr	T	(Z <sub>u</sub> )	P uncorrected	
0.116	2	0.000	1572	0.000	0.000	0.000	8.42	Inf	0.000	-28 -68 -22
					0.000	0.000	7.64	7.24	0.000	-36 -70 -22
					0.000	0.000	7.25	6.90	0.000	-20 -66 -20
		0.000	296	0.000	0.000	0.000	5.42	5.27	0.000	-28 -26 -12
		0.001	0.000	4.94	4.82	0.000	-12 -20 -4			
0.122	0.001	3.68	3.63	0.000	-26 -20 -20					

図 4.6 運動模倣タスク中の被験者 2 の左小脳における賦活領域

図 4.6 は, 左小脳におけるレストとそれ以外の条件間の賦活領域である。2 つのクラスタ

#### 4.1 運動 (手の形) 模倣タスク

が存在する．1572 ボクセルを持つクラスタを選択した．被験者 2 において選択されたクラスタの中では，右小脳に次いで大きいものである．ピークの  $t$  値は 8.42 である．



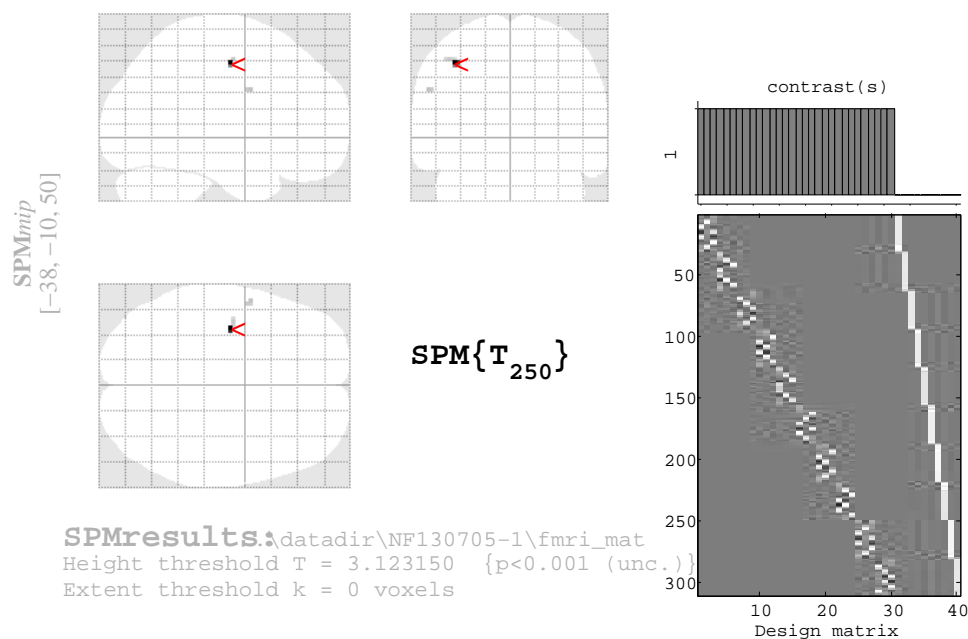
#### Statistics: *p-values adjusted for search volume*

set-level		cluster-level			voxel-level					x, y, z {mm}
<i>p</i>	<i>c</i>	<i>p</i> corrected	<i>k</i>	<i>E</i>	<i>p</i> uncorrected	<i>p</i> FWE-corr	<i>p</i> FDR-corr	<i>T</i>	( <i>Z</i> )	
0.003	4	0.000	2451	0.000	0.000	0.000	12.74	Inf	0.000	38 -64 -28
					0.000	0.000	10.53	Inf	0.000	14 -44 -22
					0.000	0.000	6.81	6.51	0.000	6 -66 -20
		0.379	1	0.839	0.247	0.001	3.39	3.35	0.000	-8 -58 -16
		0.379	1	0.839	0.332	0.002	3.26	3.22	0.001	26 -26 -12
		0.272	6	0.559	0.380	0.002	3.19	3.16	0.001	-6 -32 -4

図 4.7 運動模倣タスク中の被験者 2 の右小脳における賦活領域

図 4.7 は，右小脳におけるレストとそれ以外の条件間の賦活領域である．4 つのクラスタが存在し，2451 ボクセルを持つクラスタが選択された．被験者 2 において最も大きいクラスタである．ピークの  $t$  値は被験者 2 の中で最も大きく，12.74 となっている．

#### 4.1 運動 (手の形) 模倣タスク



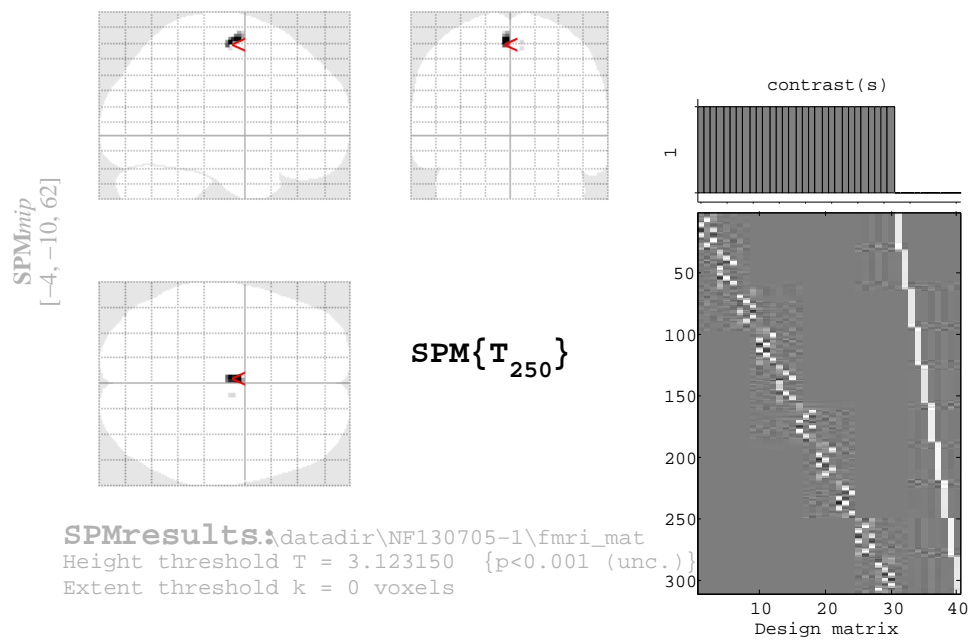
**Statistics: p-values adjusted for search volume**

set-level		cluster-level			voxel-level					x, y, z {mm}			
p	c	p corrected	k	E	p uncorrected	p FWE-corr	p FDR-corr	T	(Z)	p uncorrected			
0.002	2	0.033	8	0.494	0.001	0.002	4.43	4.34	0.000	-38	-10	50	
		0.045	3	0.693	0.021	0.010	3.48	3.44	0.000	-56	4	32	

図 4.8 運動模倣タスク中の被験者 2 の左第 4 ブロードマン領野における賦活領域

図 4.8 は、左第 4 ブロードマン領野におけるレストとそれ以外の条件間の賦活領域である。クラスタは 2 つ存在するが非常に小さい。8 ボクセルを持つクラスタが選択された。被験者 1 と比べると、選択されたクラスタサイズが 10 分の 1 以下となっている。また、ピークの  $t$  値が 4.34 と小さく、半分以下となっている。

#### 4.1 運動 (手の形) 模倣タスク



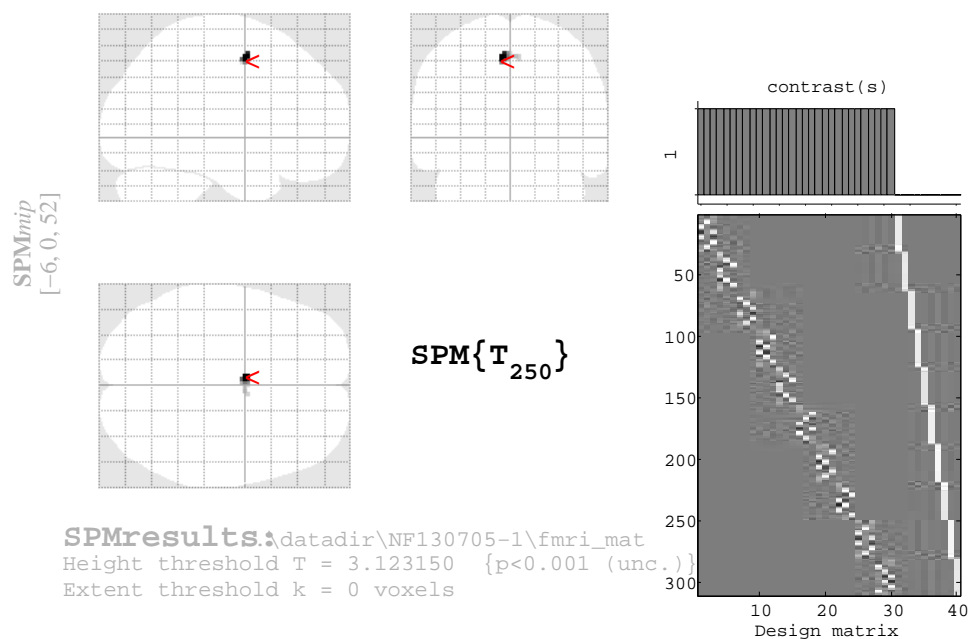
**Statistics: p-values adjusted for search volume**

set-level		cluster-level			voxel-level					x, y, z {mm}			
p	c	p corrected	k	E	p uncorrected	p FWE-corr	p FDR-corr	T	(Z)	p uncorrected			
0.000	3	0.016	21	0.262	0.001	0.001	4.27	4.19	0.000		-4	-10	62
		0.049	1	0.839	0.043	0.009	3.23	3.20	0.001		8	-8	62
		0.049	1	0.839	0.046	0.010	3.21	3.17	0.001		8	-10	58

図 4.9 運動模倣タスク中の被験者 2 の右第 4 ブロードマン領野における賦活領域

図 4.9 は、右第 4 ブロードマン領野におけるレストとそれ以外の条件間の賦活領域である。3 つのクラスタが存在し、サイズが 21 ボクセルのクラスタが選択された。ピークの  $t$  値は 4.27 である。

## 4.1 運動 (手の形) 模倣タスク



Statistics: *p-values adjusted for search volume*

cluster-level			voxel-level					x, y, z {mm}			
$P$ corrected	$k$	$E$	$P$ uncorrected	$P$ FWE-corr	$P$ FDR-corr	$T$	$(Z)$	$P$ uncorrected			
0.032	21	0.262	0.004	0.010	4.24	4.16	0.000	-6	0	52	
			0.074	0.066	3.31	3.27	0.001	4	0	54	

図 4.10 運動模倣タスク中の被験者 2 の右補足運動野における賦活領域

図 4.10 は、右補足運動野におけるレストとそれ以外の条件間の賦活領域である。クラスターは 1 つしか存在しない。ピークの  $t$  値は 4.24 である。補足運動野について、被験者 1 では左側のみに有意な活動がみられたが、被験者 2 では逆に右側のみに賦活領域が存在する。



## 4.2 RGB 刺激提示タスク

### 4.2 RGB 刺激提示タスク

被験者に 3 色の色画像刺激 (赤, 緑, 青) を提示し, 視覚的な色の認識をさせるタスクを行う (図 4.11) [2]. 被験者は 20 代の色覚正常の男性 1 名である.




図 4.11 RGB 刺激提示タスク (1 ラン分)

#### 4.2.1 被験者

被験者は 20 代の男性 1 名である. 被験者は fMRI 装置についての説明と実験の概要, 安全性, 個人情報保護についての説明を受け, 同意した上で参加した.

#### 4.2.2 fMRI 計測パラメータ

fMRI 装置として, 本学脳コミュニケーション研究センターに設置された SIEMENS 社の MAGNETOM Verio(3T) を使用する. 撮像パラメータは, FOV = 192[mm], 1 スライスあたりのボクセル数が  $64 \times 64$  [matrix], 1 ボクセルあたりのサイズが  $3 \times 3 \times 3$ [mm], スライス数が 50 枚, TE = 50[ms], フリップアングル  $90^\circ$ , TR = 5[s] である.

#### 4.2.3 タスク内容

fMRI 装置内の被験者に対し, プロジェクターによって赤, 青, 緑の 3 色の円のいずれかが提示される. 被験者は提示された画像を注視し, 脳の血流等の状態変化を fMRI 装置で撮像する. 表 4.2 は, 被験者に提示した刺激の提示順である. 脳の状態の変化を計測する. 項

## 4.2 RGB 刺激提示タスク

目 4.1 と同じく 1 回の刺激画像提示で 4 回のスキャンを行い，1 ラン中に 6 回の刺激画像提示を含み，10 ラン分の試行を行う．

表 4.2 RGB 刺激提示タスクにおける刺激の提示順

時間 [s]	0	20	40	60	80	100	120	140
ラン 1	レスト	緑	赤	青	赤	青	緑	レスト
ラン 2	レスト	緑	青	赤	赤	緑	青	レスト
ラン 3	レスト	赤	緑	青	赤	青	緑	レスト
ラン 4	レスト	青	赤	緑	赤	緑	青	レスト
ラン 5	レスト	緑	青	赤	赤	緑	青	レスト
ラン 6	レスト	青	緑	赤	青	赤	緑	レスト
ラン 7	レスト	青	赤	緑	赤	青	緑	レスト
ラン 8	レスト	緑	青	赤	緑	赤	青	レスト
ラン 9	レスト	緑	赤	青	赤	青	緑	レスト
ラン 10	レスト	赤	緑	青	緑	青	赤	レスト

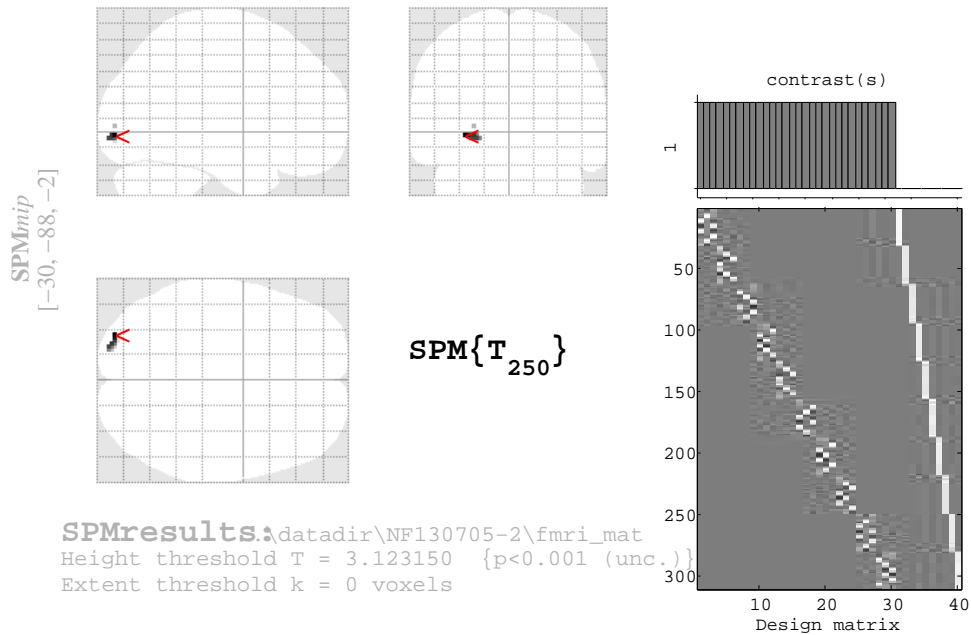
### 4.2.4 ROI 解析によるデータセットの生成

撮像された画像は，レストを含めた 4 クラスのラベルを持つ一人あたり 320 サンプル  $64 \times 64 \times 49$  次元のデータとして扱う．視覚野のデコードを行うために ROI を左脳および右脳の第 17, 18, 19 ブロードマン領野に設定する．第 17 ブロードマン領野は一次視覚野 (V1) に，第 18 ブロードマン領野は二次視覚野 (V2) に，第 19 ブロードマン領野は視覚連合野 (V3) に対応している [22]．これらはいずれも人間の視覚的認知に関わる領域である．SPM を用いて体動によるブレの除去，個人座標系から MNI 標準脳へのノーマライズ，ボクセルに対するスムージング，ROI の設定，統計解析を行い，有意な活動が見られた部位から最も大きいクラスタを選択する．左第 17 ブロードマン領野からは 16 ボクセル (図 4.12)，

## 4.2 RGB 刺激提示タスク

右第 17 ブロードマン領野からは 5 ボクセル (図 4.13), 左第 18 ブロードマン領野からは 62 ボクセル (図 4.14), 右第 18 ブロードマン領野からは 173 ボクセル (図 4.15), 右第 19 ブロードマン領野からは 5 ボクセル (図 4.16), 合計 261 ボクセルを選択した。

他の実験の賦活領域と比較すると, クラスタサイズの合計が最も小さい。



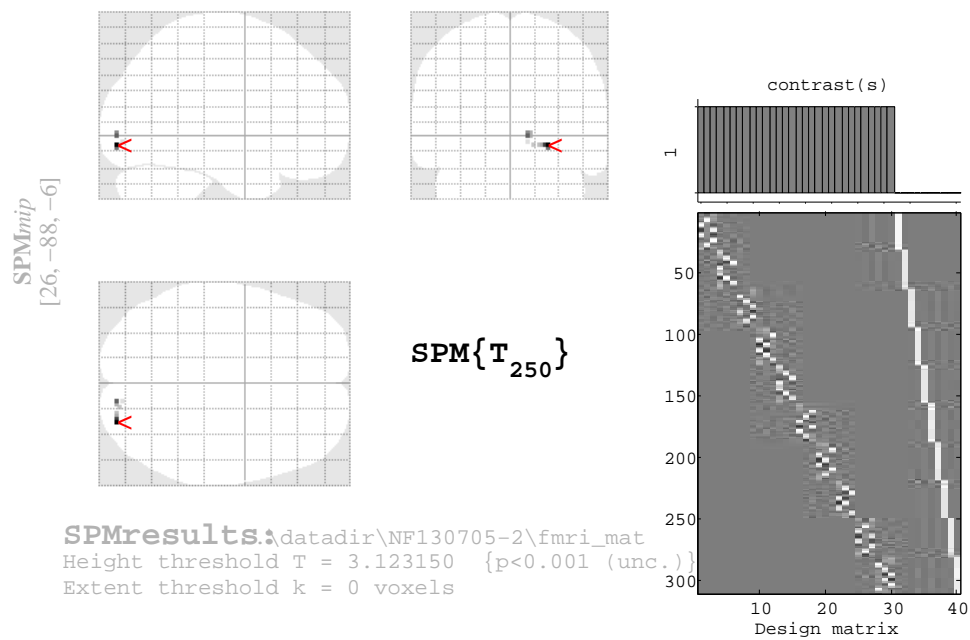
### Statistics: *p*-values adjusted for search volume

set-level		cluster-level			voxel-level					x, y, z {mm}
<i>p</i>	<i>c</i>	<i>p</i> corrected	<i>k</i>	<i>p</i> uncorrected	<i>p</i> FWE-corr <sup>T</sup>	<i>p</i> FDR-corr <sup>T</sup>	<i>T</i>	( <i>Z</i> <sub>≡</sub> )	<i>p</i> uncorrected	
0.001	2	0.011	16	0.313	0.000	0.000	4.84	4.73	0.000	-30 -88 -2
				0.001	0.000	4.25	4.18	0.000	-22 -92 -4	
		0.029	1	0.833	0.013	0.004	3.44	3.39	0.000	-24 -88 4

図 4.12 RGB 刺激提示タスク中の左第 17 ブロードマン領野における賦活領域

図 4.12 は, 左第 17 ブロードマン領野におけるレストとそれ以外の条件間の賦活領域である。クラスタは 2 つ存在し, サイズは小さいものとなっている。クラスタサイズが 16 のクラスタを選択した。ピークの *t* 値は 4.84 である。

## 4.2 RGB 刺激提示タスク



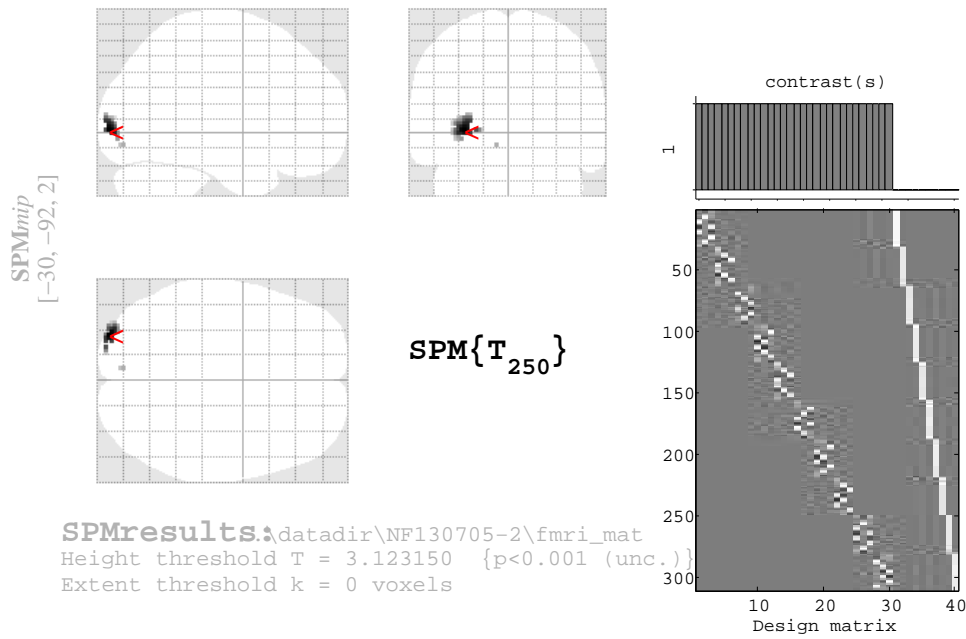
**Statistics: p-values adjusted for search volume**

set-level		cluster-level			voxel-level					x, y, z {mm}			
p	c	p corrected	k	E	p uncorrected	p FWE-corr	p FDR-corr	T	(Z)	p uncorrected			
0.000	4	0.019	5	0.585	0.010	0.009	3.50	3.46	0.000		26	-88	-6
		0.021	4	0.630	0.017	0.009	3.34	3.30	0.000		12	-88	0
		0.027	1	0.833	0.028	0.009	3.17	3.14	0.001		16	-86	-6
		0.027	1	0.833	0.032	0.009	3.14	3.10	0.001		12	-84	-4

図 4.13 RGB 刺激提示タスク中の右第 17 ブロードマン領野における賦活領域

図 4.13 は、右第 17 ブロードマン領野におけるレストとそれ以外の条件間の賦活領域である。4 つの小さなクラスタが存在し、クラスタサイズが 5 のものを選択した。ピークの  $t$  値は 3.50 である。

## 4.2 RGB 刺激提示タスク



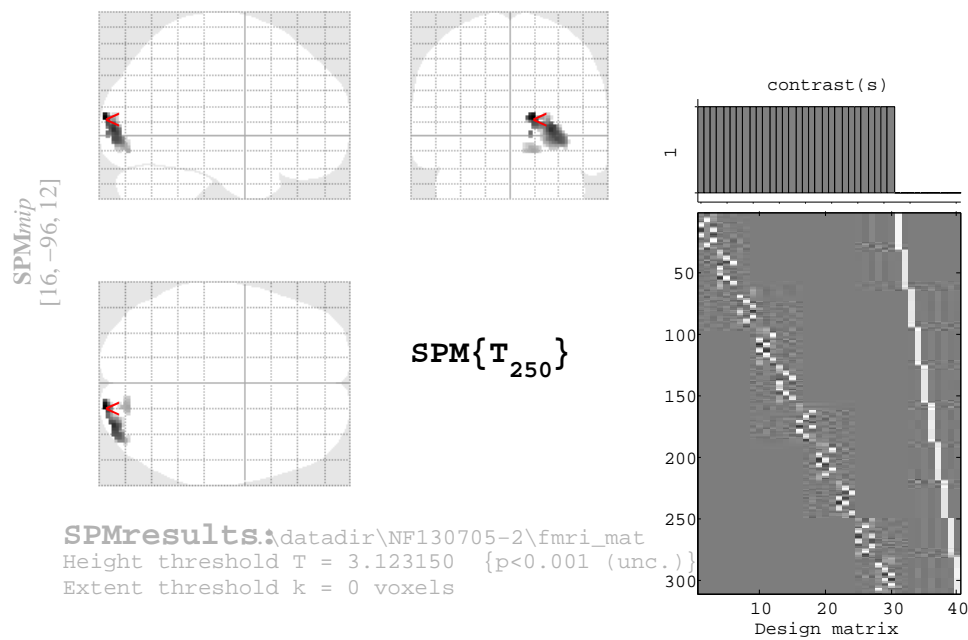
### Statistics: *p-values adjusted for search volume*

set-level		cluster-level			voxel-level					$x, y, z$ {mm}
$p$	$c$	$p$ corrected	$k$	$E$	$p$ uncorrected	$p$ FWE-corr $F$	$p$ FDR-corr $F$	$T$	$(Z)$	
0.001	3	0.009	62	0.057	0.000	0.000	5.69	5.51	0.000	-30 -92 2
		0.101	3	0.683	0.001	0.000	4.70	4.60	0.000	-22 -94 2
		0.109	2	0.748	0.028	0.002	3.67	3.62	0.000	-8 -82 -8

図 4.14 RGB 刺激提示タスク中の左第 18 ブロードマン領野における賦活領域

図 4.14 は、左第 18 ブロードマン領野におけるレストとそれ以外の条件間の賦活領域である。3つのクラスタが存在し、サイズが 62 のクラスタが選択された。このクラスタは画像提示タスクの被験者において最も大きいものである。ピークの  $t$  値は 5.69 である。

## 4.2 RGB 刺激提示タスク



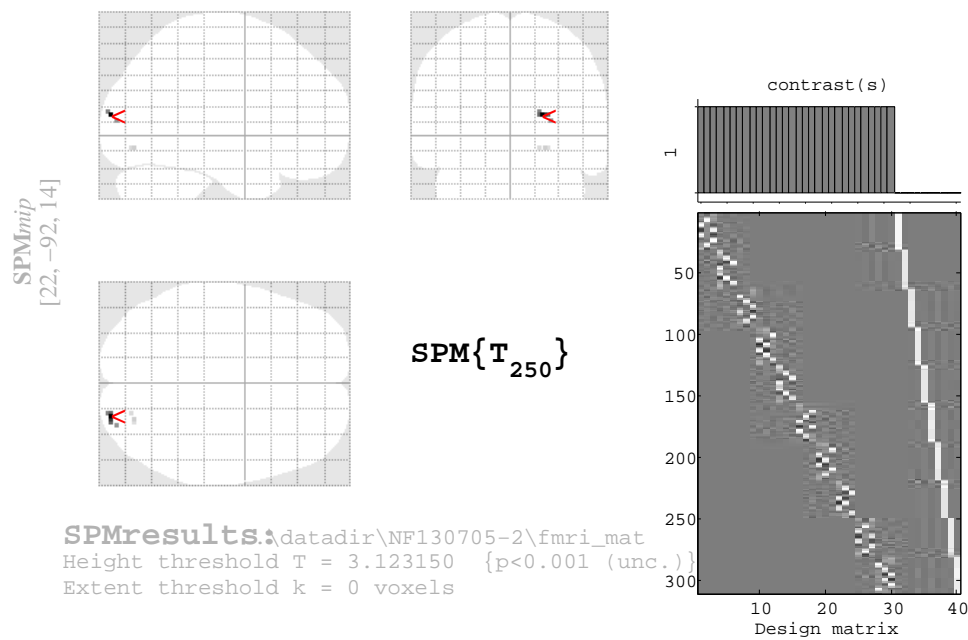
**Statistics: p-values adjusted for search volume**

set-level		cluster-level			voxel-level					x, y, z {mm}
p	c	p corrected	k <sub>E</sub>	p uncorrected	p FWE-corr <sup>F</sup>	p FDR-corr <sup>F</sup>	T	(Z <sub>≡</sub> )	p uncorrected	
0.001	3	0.001	173	0.003	0.000	0.000	5.53	5.36	0.000	16 -96 12
		0.120	2	0.748	0.000	0.000	4.94	4.82	0.000	28 -90 4
		0.040	22	0.237	0.025	0.001	3.73	3.67	0.000	14 -94 2
										16 -80 -10

図 4.15 RGB 刺激提示タスク中の右第 18 ブロードマン領野における賦活領域

図 4.15 は、右第 18 ブロードマン領野におけるレストとそれ以外の条件間の賦活領域である。3つのクラスタが存在し、サイズが 173 のものが選択された。ピークの  $t$  値は 5.53 である。

## 4.2 RGB 刺激提示タスク



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

set-level		cluster-level			voxel-level					<i>x, y, z</i> {mm}
<i>p</i>	<i>c</i>	<i>p</i> corrected	<i>k</i>	<i>E</i>	<i>p</i> uncorrected	<i>p</i> FWE-corr	<i>p</i> FDR-corr	<i>T</i>	<i>Z</i> (≡)	
0.000	4	0.093	5	0.585	0.057	0.080	3.47	3.42	0.000	22 -92 14
		0.130	1	0.833	0.101	0.080	3.28	3.24	0.001	28 -88 10
		0.118	2	0.748	0.123	0.080	3.21	3.17	0.001	24 -76 -8
		0.130	1	0.833	0.128	0.080	3.19	3.16	0.001	20 -78 -8

図 4.16 RGB 刺激提示タスク中の右第 19 ブロードマン領野における賦活領域

図 4.16 は、右第 19 ブロードマン領野におけるレストとそれ以外の条件間の賦活領域である。4 つの小さなクラスタが存在し、サイズが 5 のものが選択された。ピークの *t* 値は 3.47 である。

## 4.3 画像による感情誘発タスク

### 4.3 画像による感情誘発タスク

被験者に快もしくは不快の感情を誘発する画像刺激を提示するタスクを行い，被験者の感情の変化を測定する (図 4.17) .




図 4.17 画像による感情誘発タスク (1 ラン分)

#### 4.3.1 被験者

被験者は 20 代の男性 1 名である．被験者は fMRI 装置についての説明と実験の概要，安全性，個人情報保護についての説明を受け，同意した上で参加した．

#### 4.3.2 fMRI 計測パラメータ

fMRI 装置として，本学脳コミュニケーション研究センターに設置された SIEMENS 社の MAGNETOM Verio(3T) を使用する．撮像パラメータは，FOV = 192[mm]，1 スライスあたりのボクセル数が  $64 \times 64$  [matrix]，1 ボクセルあたりのサイズが  $3 \times 3 \times 3$ [mm]，スライス数が 47 枚，TE = 50[ms]，フリップアングル  $90^\circ$ ，TR = 3[s] である．

#### 4.3.3 タスク内容

fMRI 装置内の被験者は，LCD プロジェクターに投影された刺激画像を注視する．被験者の誘発された感情による脳の状態の変化を fMRI 装置で撮像する．表 4.3 は，被験者に提示した刺激の提示順である．画像刺激は心理実験用画像セットである IAPS(International



### 4.3 画像による感情誘発タスク

Affective Picture System) [5] から, “Arousal”(覚醒度)のパラメータが 5.0 のそれぞれ異なる画像を 21 枚選び出し, “Valence Mean”(快・不快度)の値が 7.0 以上のものを快画像に, 3.0 以下のものを不快画像として選び出した. 1 回の刺激画像提示で 5 スキャン分の撮像を行い, 1 ランは 7 枚の刺激画像提示を含む. 合計 3 ラン分の試行を行う.

表 4.3 画像による感情誘発タスクにおける刺激の提示順 (r: レスト)

時間 [s]	0	15	30	39	54	63	78	87	102	111	126	135	150	159	174
ラン 1	r	快	r	不快	r	快	r	快	r	不快	r	快	r	不快	r
ラン 2	r	快	r	不快	r	快	r	快	r	不快	r	快	r	快	r
ラン 3	r	快	r	不快	r	快	r	快	r	不快	r	快	r	不快	r

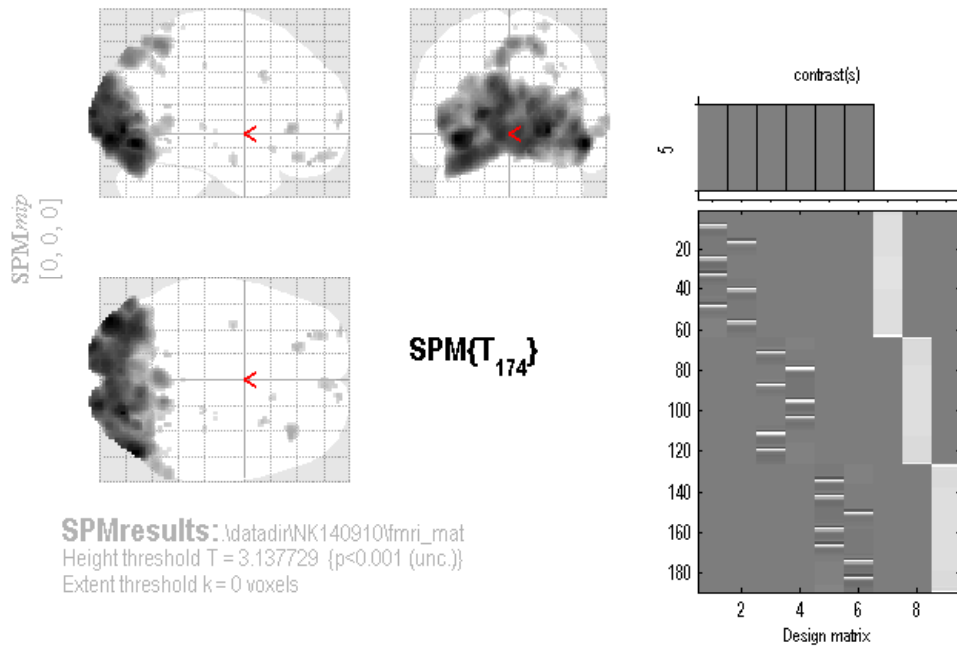
#### 4.3.4 ROI 解析によるデータセットの生成

画像から最終的にレストを含めた 3 クラスのラベルを持つ  $64 \times 64 \times 47$  次元 189 サンプルのデータセットが得られる. これを SPM で統計解析し, 全脳から有意な賦活領域 (図 4.19, 図 4.18) を得る. ここからクラスタサイズが大きい順に 3 つのクラスタ選択して組み合わせることで, 13931 ボクセルのデータとした. 1 つ目のクラスタのサイズは 13172 ボクセル, 2 つ目は 717 ボクセル, 3 つ目は 42 ボクセルである.

他の実験タスクの被験者と比較すると, クラスタサイズの合計が最も大きい. これは, 解剖学的な ROI を設定していないためだと考えられる.

図 4.19 および図 4.18 は, 全脳におけるレストとそれ以外の賦活領域である. クラスタは 24 つ存在し, サイズの大きい順に 3 つ選択した. これらのクラスタは,  $t$  値に関しても高い値を示している. それぞれのピークの  $t$  値は, 1 つ目が 6.27, 2 つ目が 4.53, 3 つ目が 3.90 である. 1 つ目のクラスタは, 本研究の全ての被験者において最も大きなクラスタサイズをもつ.

### 4.3 画像による感情誘発タスク



Statistics: *p-values adjusted for search volume*

set-level		cluster-level				peak-level					mm mm mm		
<i>p</i>	<i>c</i>	<i>p</i> <sub>FWE-cor</sub>	<i>q</i> <sub>FDR-cor</sub>	<i>k</i> <sub>E</sub>	<i>p</i> <sub>uncor</sub>	<i>p</i> <sub>FWE-cor</sub>	<i>q</i> <sub>FDR-cor</sub>	<i>T</i>	( <i>Z</i> <sub>z</sub> )	<i>p</i> <sub>uncor</sub>			
0.005	24	0.000	0.000	13172	0.000	0.000	0.001	6.27	5.95	0.000	-38	-94	-6
						0.000	0.001	6.22	5.90	0.000	50	-78	-8
						0.000	0.001	6.15	5.84	0.000	24	-86	0
		0.000	0.000	717	0.000	0.185	0.032	4.53	4.40	0.000	16	-58	56
						0.188	0.032	4.53	4.40	0.000	2	-60	58
						0.189	0.032	4.53	4.40	0.000	-8	-82	48
		0.828	0.846	42	0.133	0.817	0.203	3.90	3.81	0.000	38	30	2
		1.000	0.846	1	0.846	0.950	0.326	3.71	3.63	0.000	-28	42	-22
		0.958	0.846	25	0.240	0.975	0.397	3.63	3.56	0.000	-18	34	-18
		0.990	0.846	16	0.346	0.984	0.425	3.60	3.53	0.000	-28	50	-18
		0.996	0.846	12	0.417	0.985	0.425	3.59	3.52	0.000	30	10	36
		0.998	0.846	10	0.460	0.988	0.437	3.57	3.50	0.000	12	62	4
		0.996	0.846	12	0.417	0.989	0.441	3.56	3.49	0.000	-30	64	8
		0.976	0.846	21	0.280	0.991	0.457	3.54	3.48	0.000	6	54	-18
		0.996	0.846	12	0.417	0.992	0.463	3.53	3.47	0.000	-34	-10	-22
		1.000	0.846	2	0.767	0.996	0.503	3.48	3.42	0.000	32	-56	-6
		0.947	0.846	27	0.222	0.997	0.513	3.47	3.41	0.000	28	-60	42
		1.000	0.846	3	0.706	0.997	0.519	3.46	3.40	0.000	-14	-56	16
		0.968	0.846	23	0.259	0.999	0.579	3.41	3.35	0.000	22	-54	68
		1.000	0.846	1	0.846	1.000	0.655	3.35	3.29	0.001	24	-32	4
		1.000	0.846	2	0.767	1.000	0.655	3.34	3.29	0.001	34	-60	-6

図 4.18 感情誘発タスク中の全脳における感情誘発タスク中の賦活領域 (1)

set-level		cluster-level				peak-level					mm mm mm		
<i>p</i>	<i>c</i>	<i>p</i> <sub>FWE-cor</sub>	<i>q</i> <sub>FDR-cor</sub>	<i>k</i> <sub>E</sub>	<i>p</i> <sub>uncor</sub>	<i>p</i> <sub>FWE-cor</sub>	<i>q</i> <sub>FDR-cor</sub>	<i>T</i>	( <i>Z</i> <sub>z</sub> )	<i>p</i> <sub>uncor</sub>			
		1.000	0.846	4	0.656	1.000	0.655	3.34	3.29	0.001	14	16	-12
		1.000	0.846	2	0.767	1.000	0.671	3.33	3.27	0.001	34	-30	44
		0.998	0.846	10	0.460	1.000	0.695	3.31	3.26	0.001	28	-80	26
		1.000	0.846	2	0.767	1.000	0.742	3.28	3.23	0.001	22	-30	2
		1.000	0.846	1	0.846	1.000	0.987	3.15	3.10	0.001	28	-22	0
		1.000	0.846	1	0.846	1.000	0.997	3.14	3.09	0.001	24	-22	-10
		1.000	0.846	1	0.846	1.000	0.997	3.14	3.09	0.001	2	-44	68

図 4.19 感情誘発タスク中の全脳における感情誘発タスク中の賦活領域 (2)

## 第 5 章

# データ解析

本項では、実験で得たデータセットに対して適用する前処理の方法と、実際に比較検討するデコーダの構成とパラメータについて述べる。

### 5.1 前処理

fMRI データはそのままで次元が高いため、機械学習に適する次元数に下げる必要がある。ROI に基づいて特徴抽出が行われたデータから、さらに  $t$  値が大きい順から 200 次元の特徴を選択し、これを最終的に機械学習にかけるデータの次元数とする。サンプルのばらつきを低減するためブロック内での平均化を行う。また、機械学習に都合がいいように、外れ値の除去とトレンド除去（区間ごとに線形関数によるフィッティングを行い差分を取ることで、時系列的な傾向のある増減を除去する）、ベースラインでの正規化、 $Z$  ノルムへの変換を行う。

### 5.2 デコーダの構成と評価

本実験においては、4 種類の機械学習手法に基づいた 10 種類のデコーダを構築し比較に用いる。

- SVM(線形カーネル)
- SVM(RBF カーネル)
- SVM(多項式カーネル)

## 5.2 デコーダの構成と評価

- SVM(シグモイドカーネル)
- 3層ニューラルネットワーク
- 4層ニューラルネットワーク
- ランダムフォレスト (ntree=500, mtry=14)
- ランダムフォレスト (ntree=1000, mtry=14)
- スパースロジスティック回帰 (VAR-1vsR)
- スパースロジスティック回帰 (LAP-1vsR)

各デコーダそれぞれについて，ラン単位で分割したクロスバリデーションを行い判別率を比較する．NNの初期重みはランダムに決定されるため，10回試行を繰り返し，識別率の平均を用いる．データ構造体のフォーマットにはATRの公開するBrain Decoder Toolbox 1.2.2 [6](以下BDTB)を利用する．

### 5.2.1 SVM デコーダ

SVMデコーダには，libsvm-3.16 [7]を学習器として用いる．写像を行わない線形カーネル(式5.1)，RBFカーネル(式5.2)，多項式カーネル(式5.3)，シグモイドカーネル(式5.4)を使用する． $\gamma$ は $1/k$ ( $k$ は特徴数)， $coef0$ は0， $degree$ は3とする．

$$K(\mathbf{x}, \mathbf{x}') = \mathbf{x}^T \mathbf{x}' \quad (5.1)$$

$$K(\mathbf{x}, \mathbf{x}') = \exp(-\gamma \|\mathbf{x} - \mathbf{x}'\|^2) \quad (5.2)$$

$$K(\mathbf{x}, \mathbf{x}') = (\gamma \mathbf{x}^T \mathbf{x}' + coef0)^{degree} \quad (5.3)$$

$$K(\mathbf{x}, \mathbf{x}') = \tanh(\gamma \mathbf{x} \cdot \mathbf{x}' + coef0) \quad (5.4)$$

## 5.2 デコーダの構成と評価

### 5.2.2 ニューラルネットワークデコーダ

ニューラルネットワークデコーダは, Neural Network Toolbox 2.0 [9] を学習器として用いる. 実装するニューラルネットは入力層, 中間層, 出力層からなる 3 層のものと, 隠れ層を 1 層追加した 4 層のものとする. 本研究では, 通常のスグモイド関数 (式 3.5) よりも高い精度を確認できたため, 中間層および隠れ層のニューロンには双曲線正接スグモイド関数 (式 5.5) を, 出力層のニューロンには線形関数を用いる. 出力層のニューロンの数は 1 つ, 中間層のニューロンの数は入力データの次元数の  $1/10$  に 1 を足した 21 つ, 最大反復回数は 3000 回, 学習率は 0.1, 終了条件は誤差が  $10^{-6}$  未満になった場合とする.

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (5.5)$$

### 5.2.3 ランダムフォレストデコーダ

ランダムフォレストデコーダには, R のパッケージである randomForest package 4.6-7 [10] を用いる. 決定木の数 (ntree) が 500 と 1000 の 2 つの場合で, デコーダを比較する. 決定木の分岐に用いる変数の数 (mtry) は, 特徴次元の二乗根が一般的に用いられているため, それに倣い  $\sqrt{200} = 14$  を用いる.

### 5.2.4 スパースロジスティック回帰デコーダ

スパースロジスティック回帰デコーダには, Sparse Logistic Regression toolbox 1.2.1alpha [8] を用いる. 変分型近似 (VAR) の手法を取り入れたものとラプラス近似 (LAP) を用いた 2 つのデコーダを比較する. 学習の最大反復回数はどちらも 150 回とする.

## 第 6 章

# 結果と考察

表 6.1 実験結果 (Precision±S.D.(%))

		運動模倣 1	運動模倣 2	RGB 刺激	感情誘発
SVM	linear	93±9	47±17	68±16	67±32
	RBF	87±11	43±24	57±18	48±27
	多項式	87±11	53±23	60±21	48±30
	シグモイド	88±14	50±24	50±15	33±17
NN	3-layer	72±15	36±18	53±18	77±32
	4-layer	76±13	32±18	53±18	72±37
RF	ntree=500	82±13	42±18	57±25	81±40
	ntree=1000	82±12	37±13	60±30	81±37
SLR	VAR	92±14	50±23	68±17	81±26
	LAP	90±9	53±15	72±21	52±39

表 6.1 に、各データセットにおけるデコーダの推定精度 (%) と標準偏差 (S.D.) を示す。標準偏差はクロスバリデーションにおける各 fold ごとの推定精度のばらつきである。

運動模倣実験においては、1 人目の被験者の状態は線形サポートベクターマシンで 93% と高精度な推定ができているのに対し、2 人目の被験者のデータセットにおける最高精度はスパースロジスティック回帰および RBF カーネルを用いたサポートベクターマシンの 53% にとどまっている。これは、2 人目の被験者実験で撮像した画像にノイズが多く含まれていた

ため、統計値による特徴選択の際に必要なクラスを絞り込めず線形分離が難しくなったことが原因と考えられる。実際、統計処理によって求められた被験者 2 の賦活領域のクラスサイズは被験者 1 のそれに比べて大きく、前処理で行った統計値によるボクセル選択で、相関の低いボクセルが含まれたことは考えられる。また、被験者 1 の推定精度の標準偏差は全体的に小さく、いずれの機械学習アルゴリズムでも、他のデータセットに比べ安定した学習ができている。

RGB 刺激実験においては、ラプラス近似を用いたスパースロジスティック回帰が 72%、変分型スパースロジスティック回帰と線形サポートベクターマシンが 68%と高い推定精度を示している。サポートベクターマシンとスパースロジスティック回帰の性能が良いという傾向は、運動模倣実験における被験者 1 と類似している。また、ROI 解析で選択したボクセル数は、運動模倣実験は 531 ボクセル、RGB 刺激実験は 261 ボクセルと 1000 ボクセル未満に収まっている。

感情誘発実験においては、ランダムフォレストとスパースロジスティック回帰が 80%と、サポートベクターマシンやニューラルネットワークより高い精度を示している。これは他の 3 つのデータセットではみられない傾向である。また、同じスパースロジスティック回帰でも、ラプラス近似を用いた手法よりも変分型近似を用いた手法のほうが高い精度を示した。実際、スパースロジスティック回帰デコーダの訓練において、ラプラス近似を用いたデコーダは用いる特徴量が 200 から減らない一方、変分型近似を用いるデコーダは 8 から 15 程度まで次元削減ができており、スパースなモデルを生成できている。これは、感情誘発実験では解剖学的な ROI 解析を行っていないこと、BOLD 信号の検出が難しい高次元な感情をデコードする課題であることが原因と考えられる。ただし、感情誘発実験における標準偏差は他の実験に比べて大きいいため、この結果だけで高精度と断定することは難しい。また、使用したデータセットの中でも、感情誘発実験だけは 2 クラス判別問題となっているためチャンスレベルが高いことも考慮すべきである。

各データセットにおけるランダムフォレストの結果に着目すると、運動模倣タスクの被験者 1 では 82%の精度を出しているが、RGB 刺激提示タスクでは 60%かそれ以下に下がって

いる。これは、統計値によるボクセル選択で多くのボクセルが選択されるほど、相関の低いボクセルを選択する確立が上がっていくためではないかと考えられる。感情誘発タスクにおける精度は 81% と高いが、他のタスクと異なり 2 クラス分類であることが、二分決定木を用いるランダムフォレストに有利に働いたのだと考えられる。

特徴として選択したクラスタにおけるピークボクセルの  $t$  値の観点から比較すると、ピークの  $t$  値が高く、かつ選択したボクセル数が少ないデータセットは線形判別の精度が高まっていることがわかる。

以上のことから、前処理による次元削減が十分にできているならば線形サポートベクターマシンが、事前の特徴選択が難しい高次脳機能課題においてはスパースロジスティック回帰が有効であるといえる。

ただし、研究の過程において、 $t$  値によるボクセルの選択数を増やし、 $t$  値の低いボクセルを含めた解析を行ったところ、精度が向上したデータがみられた。よって、レストとそれ以外の活動における賦活領域を選択する手法では、種類を問わずどのような活動をしていても賦活する部位まで選択してしまっている可能性があるため今後の考察が必要になると考えられる。



## 第 7 章

# 結論

本稿では、脳情報デコーディングの核となる技術である機械学習アルゴリズムのうち、サポートベクターマシン、ニューラルネットワーク、ランダムフォレスト、スパースロジスティック回帰の 4 つについて、内部で行われている特徴選択の観点から比較を行った。脳情報データセットを得るために、運動模倣タスク、RGB 刺激提示タスク、画像による感情誘発タスクという、それぞれ異なる脳機能に着目した 3 種類の実験タスクを行った。得られたデータの特性がそれぞれ異なる計 4 つのデータセットに対して機械学習アルゴリズムを適用した。

その結果、運動模倣タスクにおいては被験者によって傾向が異なり、SPM 解析で有意なボクセルの抽出がうまくできていた被験者 1 の場合は SVM が 93% と最も精度が高く、被験者 1 に比べて有意なボクセルの絞り込みができていない被験者 2 の場合はニューラルネットワークの 54% と SLR の 53%、RBF カーネルを用いた SVM の 53% が最高精度だった。RGB 刺激提示タスクの場合はラプラス近似を用いた SLR が最も高精度だった。画像による感情誘発タスクの場合は変分型近似を用いた SLR が最も高精度で、SLR によるスパース化が有効に機能していることがわかった。以上のことから、統計的前処理によるボクセル選択による次元削減が有効なデータに対しては SVM、事前の特徴選択が難しい高次脳機能課題においては SLR が有効であることがわかった。

本研究の成果は、Brain Computer Interface を実装する際、人間の脳のどのような働きをデコードし入力に変えるのか、前処理にどの程度計算リソースを割り当てられるのかといった情報をもとに、課題に適した構成を考えるために応用できると考えられる。今後の展望として、未知のデータに対応する特徴選択法の考案が挙げられる。本研究では、あらかじ

め撮像したデータからテストデータを生成する関係上，全てのデータを用いて統計値による特徴選択や前処理を行っている．実際のリアルタイム BCI では，その都度撮像した未知のデータを判別するため，既知のデータだけを用いて，未知のデータに対応できるボクセルを選択する手法を取り入れる必要があるといえる，また，本研究では刺激画像の輝度については調整を行っていないが，視覚画像の再構成のような複数条件のデコードにおいて，モジュラ・デコーディングの手法を取り入れる場合は画像刺激の輝度を統一して視覚野の影響を取り除く必要があると考えられる．

# 謝辞

本研究を進めるにあたり，修士論文指導教員の吉田真一准教授から，学部時代に引き続き，非常に丁寧かつ熱心なご指導を頂きました．ここに多大なる感謝の意を表します．私が脳情報デコーディングという研究分野に取り組むきっかけを頂いただけでなく，fMRI 実験のノウハウの構築，3 回の国際学会発表，国内での研究会においても大変お世話になりました．深く感謝いたします．

また，副査を担当して頂いた繁柵博昭准教授，篠森敬三教授からは，脳科学や認知科学の知見から多くのアドバイスを頂きました．両先生に感謝いたします．

そして，負担の大きい fMRI 実験の被験者を引き受けてくださったほか，研究を引き継いで貴重な実験データを提供してくださった吉田研究室の同期・後輩の皆様に感謝いたします．ありがとうございました．

## 参考文献

- [1] Kamitani, Y., and Tong, F., “Decoding the visual and subjective contents of the human brain,” *Nature Neuroscience*, Vol.8, No.5, pp.679-685, 2005.
- [2] Koike, N., Hatakeyama, Y., and Yoshida, S., “Decoding color of stimuli given to a human subject from functional magnetic resonance imaging voxel patterns using machine learning algorithm,” *World Automation Congress (WAC), IFMIP, Hawaii*, pp.681-686, IEEE, 2014.
- [3] Cortes, C., and Vapnik, V.N., “Support-Vector Networks”, *Machine Learning*, Vol.20, Issue 3, pp.273-297, 1995.
- [4] SPM - Statistical Parametric Mapping, <http://www.fil.ion.ucl.ac.uk/spm/>.
- [5] Lang, P.J., Bradley, M.M., and Cuthbert, B.N. “International affective picture system (IAPS): Affective ratings of pictures and instruction manual,” *Technical Report A-8*. University of Florida, Gainesville, FL., 2008.
- [6] Brain Decoder Toolbox — ATR - DNI,  
<http://www.cns.atr.jp/dni/download/brain-decoder-toolbox/>.
- [7] Chih-Chung Chang and Chih-Jen Lin, LIBSVM : a library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, 2:27:1–27:27, 2011. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- [8] SLR toolbox Web Page, <http://www.cns.atr.jp/~oyamashi/SLR\-WEB.html>.
- [9] Neural Network Toolbox - MATLAB,  
<http://www.mathworks.com/products/neural-network/index.html>.
- [10] CRAN - Package randomForest,  
<http://cran.r-project.org/web/packages/randomForest/index.html>.
- [11] 木村真弘 他, 「オンライン fMRI デコーディング」, 電子情報通信学会 第 2 回ブレイン

## 参考文献

- コミュニケーション研究会講演予稿集, 29/32, 2006.
- [12] Miyawaki, Y; Uchida, H; Yamashita, O; Sato, M; Morito, Y; Tanabe, H C.; Sadato, N; Kamitani, Y, “Visual Image Reconstruction from Human Brain Activity using a Combination of Multiscale Local Image Decoders,” *Neuron*, Vol.60, Issue 5, pp.915-929, 2008.
- [13] Rumelhart, David E.; Hinton, Geoffrey E., Williams, Ronald J., “Learning representations by back-propagating errors”, *Nature* 323 (6088), 533-536, 1986.
- [14] Breiman, L.: “Random Forests, *Machine Learning*,” Vol.45 No.1, pp.5-32, 2001.
- [15] 波部 齊 : ランダムフォレスト , 情報処理学会研究報告 コンピュータビジョンとイメージメディア ( CVIM ) , Vol.2012-CVIM-182 , No.31 , pp. 1-8 , 2012.
- [16] Yamashita O, Sato MA, Yoshioka T, Tong F, Kamitani Y, “Sparse estimation automatically selects voxels relevant for the decoding of fMRI activity patterns,” *Neuroimage*, Vol.42(4), pp.1414-1429, 2008.
- [17] J.V. Haxby, M.I. Gobbini, M.L Furey, A. Ishai, J.L. Schouten and P. Pietrini, “Distributed and Overlapping Representations of Faces and Objects in Ventral Temporal Cortex”, *Science* Vol.293, 2425-2430, 2001.
- [18] James V. Haxby, “Multivariate pattern analysis of fMRI: The early beginnings”, *NeuroImage* 62(2), 852-855, 2012.
- [19] Yoichi Miyawaki, Hajime Uchida, Okito Yamashita, Masa-aki Sato, Yusuke Morito, Hiroki C Tanabe, Norihiro Sadato, Yukiyasu Kamitani, “Visual image reconstruction from human brain activity: A modular decoding approach,” *Journal of Physics: Conference Series*, Vol.197(1), pp.1742-6596, 2009.
- [20] Yusuke Fujiwara, Yoichi Miyawaki, Yukiyasu Kamitani, “Estimating image basis for visual image reconstruction from human brain,” *NIPS2009*, 2009.
- [21] T. Horikawa, M. Tamaki, Y. Miyawaki, and Y. Kamitani, ”Neural Decoding of Visual Imagery During Sleep, *Science* 340(6132), 639-642, 2013.

## 参考文献

- [22] M.F. ベアー, B.W. コノーズ, and M.A. パラディーソ, “カラー版 ベアー コノーズパラディーソ神経科学: 脳の探求,” 西村書店, 2007.
- [23] O. Yamashita, “Quick Manual for Sparse Logistic Regression ToolBox ver1.2.1,” [http://www.cns.atr.jp/~oyamashi/SLR\\_WEB.html](http://www.cns.atr.jp/~oyamashi/SLR_WEB.html).
- [24] Jaakkola TS, Jordan MI, “Bayesian parameter estimation via variational methods,” *Statistics and Computing*, 10, pp25-37, 2000.
- [25] Bishop C, Tipping ME, “Variational relevance vector machines,” *Proceedings of the 16th Conference in Uncertainty Artificial Intelligence*, pp.46-53, 2000.
- [26] Bishop C, “*Pattern recognition and machine learning*,” Springer, New York, 2006.

# 発表一覧

1. Koike, N., Hatakeyama, Y., and Yoshida, S., “Machine Learning of functional Magnetic Resonance Imaging Data for Brain Decoding,” The 3rd International Workshop on Advanced Computational Intelligence and Intelligent Informatics (IWACIII), Shanghai, 2013.
2. Koike, N., Hatakeyama, Y., and Yoshida, S., “Supervised Learning of functional Magnetic Resonance Imaging Data for Brain Decoding”, the 14th International Symposium on Advanced Intelligent Systems (ISIS), Korea, 2013.
3. Koike, N., Hatakeyama, Y., and Yoshida, S., “Decoding color of stimuli given to a human subject from functional magnetic resonance imaging voxel patterns using machine learning algorithm,” World Automation Congress (WAC), IFMIP, Hawaii, pp.681-686, IEEE, 2014.
4. Koike, N., Hatakeyama, Y., and Yoshida, S., “Decoding Emotion by Deep Brain Voxel Selection using fMRI,” International Symposium on Interaction Design and Human Factors (IDHF), Kochi, 2014.

## 付録 A

# 各データセットの識別における混同行列

本項では、各データセットにおけるデコーダの識別結果の混同行列を示す。

### A.1 運動模倣タスク (被験者 1) における混同行列

表 A.1 運動模倣タスク (被験者 1) の SVM(線形カーネル) における混同行列

-predict \ actual	グー	チョキ	パー
グー	19	0	1
チョキ	1	19	0
パー	1	1	18

表 A.2 運動模倣タスク (被験者 1) の SVM(RBF カーネル) における混同行列

-predict \ actual	グー	チョキ	パー
グー	19	0	1
チョキ	0	17	3
パー	2	2	16



## A.1 運動模倣タスク (被験者 1) における混同行列

表 A.3 運動模倣タスク (被験者 1) の SVM(多項式カーネル) における混同行列

-predict \ actual	グー	チョキ	パー
グー	19	0	1
チョキ	0	17	3
パー	2	2	16

表 A.4 運動模倣タスク (被験者 1) の SVM(シグモイドカーネル) における混同行列

-predict \ actual	グー	チョキ	パー
グー	18	0	2
チョキ	0	17	3
パー	2	0	18

表 A.5 運動模倣タスク (被験者 1) の NN(3層) における混同行列 (10 回分)

-predict \ actual	グー	チョキ	パー
グー	166	32	2
チョキ	2	153	27
パー	5	71	124

## A.1 運動模倣タスク (被験者 1) における混同行列

表 A.6 運動模倣タスク (被験者 1) の NN(4 層) における混同行列 (10 回分)

-predict \ actual	グー	チョキ	パー
グー	174	24	2
チョキ	12	146	42
パー	12	56	132

表 A.7 運動模倣タスク (被験者 1) の RF(ntree=500) における混同行列

-predict \ actual	グー	チョキ	パー
グー	19	0	1
チョキ	2	16	2
パー	2	4	14

表 A.8 運動模倣タスク (被験者 1) の RF(ntree=1000) における混同行列

-predict \ actual	グー	チョキ	パー
グー	19	0	1
チョキ	2	16	2
パー	2	4	14

A.1 運動模倣タスク (被験者 1) における混同行列

表 A.9 運動模倣タスク (被験者 1) の SLR-VAR における混同行列

-predict \ actual	ゲー	チョキ	パー
ゲー	19	0	1
チョキ	2	16	2
パー	2	4	14

表 A.10 運動模倣タスク (被験者 1) の SLR-LAP における混同行列

-predict \ actual	ゲー	チョキ	パー
ゲー	20	0	0
チョキ	1	17	2
パー	2	1	17

A.2 運動模倣タスク (被験者 2) における混同行列

## A.2 運動模倣タスク (被験者 2) における混同行列

表 A.11 運動模倣タスク (被験者 2) の SVM(線形カーネル) における混同行列

-predict \ actual	ゲー	チョキ	パー
ゲー	4	5	11
チョキ	3	12	5
パー	5	3	12

表 A.12 運動模倣タスク (被験者 2) の SVM(RBF カーネル) における混同行列

-predict \ actual	ゲー	チョキ	パー
ゲー	10	3	7
チョキ	11	4	5
パー	3	5	12

表 A.13 運動模倣タスク (被験者 2) の SVM(多項式カーネル) における混同行列

-predict \ actual	ゲー	チョキ	パー
ゲー	10	3	7
チョキ	6	7	7
パー	3	2	15

## A.2 運動模倣タスク (被験者 2) における混同行列

表 A.14 運動模倣タスク (被験者 2) の SVM(シグモイドカーネル) における混同行列

-predict actual	グー	チョキ	パー
グー	9	4	7
チョキ	7	11	2
パー	6	4	10

表 A.15 運動模倣タスク (被験者 2) の NN(3 層) における混同行列 (10 回分)

-predict actual	グー	チョキ	パー
グー	38	84	78
チョキ	49	102	49
パー	55	93	52

表 A.16 運動模倣タスク (被験者 2) の NN(4 層) における混同行列 (10 回分)

-predict actual	グー	チョキ	パー
グー	50	60	90
チョキ	54	99	47
パー	48	84	68

## A.2 運動模倣タスク (被験者 2) における混同行列

表 A.17 運動模倣タスク (被験者 2) の RF(ntree=500) における混同行列

-predict \ actual	グー	チョキ	パー
グー	3	4	13
チョキ	2	15	3
パー	11	2	7

表 A.18 運動模倣タスク (被験者 2) の RF(ntree=1000) における混同行列

-predict \ actual	グー	チョキ	パー
グー	3	4	13
チョキ	4	13	3
パー	12	2	6

表 A.19 運動模倣タスク (被験者 2) の SLR-VAR における混同行列

-predict \ actual	グー	チョキ	パー
グー	8	3	9
チョキ	2	14	4
パー	9	3	8

## A.2 運動模倣タスク (被験者 2) における混同行列

表 A.20 運動模倣タスク (被験者 2) の SLR-LAP における混同行列

-predict actual	ゲー	チョキ	パー
ゲー	7	2	11
チョキ	2	16	2
パー	9	2	9

### A.3 RGB 刺激提示タスクにおける混同行列

表 A.21 RGB 刺激タスクの SVM(線形カーネル) における混同行列

-predict \ actual	赤	緑	青
赤	15	4	1
緑	5	13	2
青	3	4	13

表 A.22 RGB 刺激タスクの SVM(RBF カーネル) における混同行列

-predict \ actual	赤	緑	青
赤	8	7	5
緑	5	12	3
青	3	3	14

表 A.23 RGB 刺激タスクの SVM(多項式カーネル) における混同行列

-predict \ actual	赤	緑	青
赤	12	6	2
緑	7	11	2
青	2	5	13



### A.3 RGB 刺激提示タスクにおける混同行列

表 A.24 RGB 刺激タスクの SVM(シグモイドカーネル) における混同行列

-predict \ actual	赤	緑	青
赤	8	7	5
緑	4	13	3
青	6	5	9

表 A.25 RGB 刺激タスクの NN(3 層) における混同行列 (10 回分)

-predict \ actual	赤	緑	青
赤	101	93	6
緑	49	107	44
青	11	79	11

表 A.26 RGB 刺激タスクの NN(4 層) における混同行列 (10 回分)

-predict \ actual	赤	緑	青
赤	97	97	6
緑	39	122	39
青	1	91	99

### A.3 RGB 刺激提示タスクにおける混同行列

表 A.27 RGB 刺激タスクの RF(ntree=500) における混同行列

-predict \ actual	赤	緑	青
赤	11	7	2
緑	5	11	4
青	5	3	13

表 A.28 RGB 刺激タスクの RF(ntree=1000) における混同行列

-predict \ actual	赤	緑	青
赤	11	7	2
緑	4	13	3
青	5	3	12

表 A.29 RGB 刺激タスクの SLR-VAR における混同行列

-predict \ actual	赤	緑	青
赤	15	5	0
緑	8	10	2
青	1	3	16

表 A.30 RGB 刺激タスクの SLR-LAP における混同行列

-predict \ actual	赤	緑	青
赤	15	4	1
緑	4	14	2
青	3	3	14

## A.4 画像による感情誘発タスクにおける混同行列

表 A.31 感情誘発タスクの SVM(線形カーネル) における混同行列

-predict \ actual	快	不快
快	11	1
不快	6	3

表 A.32 感情誘発タスクの SVM(RBF カーネル) における混同行列

-predict \ actual	快	不快
快	8	4
不快	7	2

表 A.33 感情誘発タスクの SVM(多項式カーネル) における混同行列

-predict \ actual	快	不快
快	7	5
不快	6	3

#### A.4 画像による感情誘発タスクにおける混同行列

表 A.34 感情誘発タスクのSVM(シグモイドカーネル)における混同行列

-predict \ actual	快	不快
快	7	5
不快	6	3

表 A.35 感情誘発タスクのNN(3層)における混同行列(10回分)

-predict \ actual	快	不快
快	95	28
不快	29	61

表 A.36 感情誘発タスクのNN(4層)における混同行列(10回分)

-predict \ actual	快	不快
快	95	25
不快	32	58

表 A.37 感情誘発タスクのRF(ntree=500)における混同行列

-predict \ actual	快	不快
快	11	1
不快	3	6

#### A.4 画像による感情誘発タスクにおける混同行列

表 A.38 感情誘発タスクの RF(ntree=1000) における混同行列

		-predict	
		快	不快
actual	快	11	1
	不快	3	6

表 A.39 感情誘発タスクの SLR-VAR における混同行列

		-predict	
		快	不快
actual	快	9	3
	不快	1	8

表 A.40 感情誘発タスクの SLR-LAP における混同行列

		-predict	
		快	不快
actual	快	2	10
	不快	0	9