

平成 24 年度

学士学位論文

fMRI を用いた脳情報デコーディングに 適した機械学習

Comparison of Machine Learning Algorithms
for Brain-Decoding from fMRI Signals

1130334 小池 規伎

指導教員 吉田 真一

2013 年 3 月 9 日

高知工科大学 情報学群

要 旨

fMRI を用いた脳情報デコーディングに適した機械学習

小池 規伎

脳機能計測により得られるデータと人の認知の状態や行動とを機械学習により学習させ、脳計測のみから認知状態や行動を推定する脳情報デコーディング技術があるが、その重要な要素となるのがデコーダである。Brain Machine Interface あるいは Brain Computer Interface として実用化するにあたって、デコーダに使われる機械学習アルゴリズムの識別精度と学習速度の向上は重要な課題である。本研究では、現在、多くの研究分野で用いられている機械学習アルゴリズムである Support Vector Machine, ニューラルネットワーク, ランダムフォレスト, Sparse Logistic Regression の 4 つの機械学習アルゴリズムを用いてデコーダを構成し、これらのデコーダの識別精度や学習速度を比較する。デコードする課題として、先行研究との比較・考察を行うことも考えて、被験者が出しているじゃんけんの手（グー, チョキ, パー）を推定する問題を扱う。1 名の被験者に対し、被験者の運動野の状態のデコードを通して、じゃんけんの手を推定精度と学習にかかる時間コストを算出する。その結果として、線形カーネルを使用した SVM が精度 93.3%, データ数 31 の学習にかかる速度 0.004[s] と最も高い性能となり、ニューラルネットワークが最も低い 72.1%, 9.665[s] となっている。

キーワード fMRI, 脳情報デコーディング, 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

Comparison of Machine Learning Algorithms for Brain-Decoding from fMRI Signals

Noriki Koike

Brain decoding is a technology that reads the human state or behavior from the human brain activity obtained from functional magnetic imaging or other devices measuring brain activity. Core technology of brain decoding is a decoder. A decoder is a machine learning algorithm such as support vector machines. Improvement of machine learning precision and speed of convergence of learning is important issues and then the purpose of this research is comparison of machine learning algorithms for the brain decoding application.

In this study, we construct the brain decoder using four machine learning algorithms, that are support vector machines, neural networks, random forests, sparse logistic regression. We conduct a brain decoding experiment of the game of "paper," "scissors," and "stones." The decoder decodes a subject's hand from fMRI measurement. The result shows that the highest performance in both accuracy and speed are achieved by SVM using the linear kernel, and those of the lowest by neural network.

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

目次

| | | |
|-------|--------------------------------------|----|
| 第 1 章 | 序論 | 1 |
| 第 2 章 | 機械学習アルゴリズム | 4 |
| 2.1 | Support Vector Machine | 4 |
| 2.2 | ニューラルネットワーク | 5 |
| 2.3 | ランダムフォレスト | 7 |
| 2.4 | Sparse Logistic Regression | 9 |
| 第 3 章 | 実験内容 | 12 |
| 3.1 | 実験 | 12 |
| 3.1.1 | 被験者 | 12 |
| 3.1.2 | 計測パラメータ | 12 |
| 3.1.3 | 試行の内容 | 13 |
| 3.2 | SPM を用いた ROI セッション解析 | 14 |
| 3.3 | デコーダの構成と評価 | 15 |
| 3.3.1 | SVM デコーダ | 17 |
| 3.3.2 | ニューラルネットワークデコーダ | 17 |
| 3.3.3 | ランダムフォレストデコーダ | 18 |
| 3.3.4 | SLR デコーダ | 18 |
| 3.3.5 | 性能評価 | 18 |
| 第 4 章 | 結果と考察 | 19 |
| 第 5 章 | 結論 | 23 |
| | 謝辞 | 24 |

目次

| | |
|-----------------------|----|
| 参考文献 | 25 |
| 付録 A 各条件における SPM 解析結果 | 27 |

目次

| | | |
|-----|--------------------------------------|----|
| 1.1 | 脳情報デコーディングの概観 | 3 |
| 2.1 | Support Vector Machine | 6 |
| 2.2 | ニューラルネットワーク | 8 |
| 2.3 | ランダムフォレスト | 10 |
| 2.4 | Sparse Logistic Regression | 11 |
| 3.1 | 被験者の試行内容 | 14 |
| 3.2 | ROI セッション解析の流れ | 16 |
| 4.1 | 識別率の比較 | 21 |
| 4.2 | 実行速度の比較 | 22 |
| A.1 | 全条件における賦活領域 | 28 |
| A.2 | rock 条件における賦活領域 | 29 |
| A.3 | scissors 条件における賦活領域 | 30 |
| A.4 | paper 条件における賦活領域 | 31 |

表目次

| | | |
|-----|--------------------------|----|
| 3.1 | 被験者に行わせた試行のリスト | 13 |
| 4.1 | 識別率 | 20 |
| 4.2 | 実行速度 | 20 |

第 1 章

序論

近年，fMRI (functional Magnetic Resonance Imaging, 核磁気共鳴画像法) を用いた脳情報デコーディング技術の研究が行われている．脳情報デコーディングとは，脳機能計測によって測定された脳活動から，その時に脳が受け取っている刺激や脳が指令している行動，認知の状態を読み取る技術である (図 1.1)．脳情報デコーディングは脳活動の局在性に基いて，計測した活動部位の信号をパターンデータとして識別器に学習させることで，読み取った脳情報から人の状態を識別できるようにする技術である．

fMRI は，脳表面の活動を計測する fNIRS や EEG に比べ，磁気を用いて脳の深部まで高い解像度で脳活動を画像化することができるため，精度の高いデコーディングを行うことができる．Kamitani らの研究 [1] では，ニューラルネットワークを用いたデコーダによって，視覚野ニューロンの方位選択制をデコードしている．Miyawaki らの研究 [2] では，ベイズ推定の手法を取り入れたデコーダで，被験者の見ている白黒二次元画像を視覚野ニューロンから再構成している．Nishimoto らの研究 [3] では，被験者に動画を見せ，視覚野の状態を fMRI で読み取り，これまでより高い精度で動画として再構成することに成功している．ATR と Honda は，被験者がじゃんけんの手を出している時の運動野の状態を機械学習することで，ほぼリアルタイム [5] でロボットアームに同じ手を出させるデコーダを構成した [4]．特に ATR と Honda の研究は，Brain Computer Interface の実用化に向けた研究として大きな一歩となった．

脳情報デコーディング技術の実用化にあたって重要な要素となるのがデコーダの機械学習アルゴリズムである．本研究では，デコード精度の向上を目的として，既存の研究 [4] で示されている運動野のデコーダを構成する．デコードを通して，SVM，ニューラルネットワー

ク、ランダムフォレスト、SLR という 4 つの学習アルゴリズムについて、学習精度と計算コストの観点から比較を行い、線形カーネルを使用した SVM が精度・速度ともに最も高い性能を発揮し、ニューラルネットワークが最も低速かつ低精度であることを示す。

まず第 2 章では、本研究で比較する Support Vector Machine、ニューラルネットワーク、ランダムフォレスト、Sparse Logistic Regression の 4 つの機械学習アルゴリズムの基本的知識について解説する。第 3 章では、運動野の脳活動データを得るために行う実験について、被験者にじゃんけんの手を出させる試行の手順と、得られたデータに関心領域 (ROI) に基づいた解析を行い学習用データセットを得る手順、実装するデコーダの一覧とそのパラメータ、性能評価の方法について書く。第 4 章では、実際の推定精度と学習にかかる時間を示し、得られた結果に対する考察を行う。第 5 章で研究全体についてまとめる。

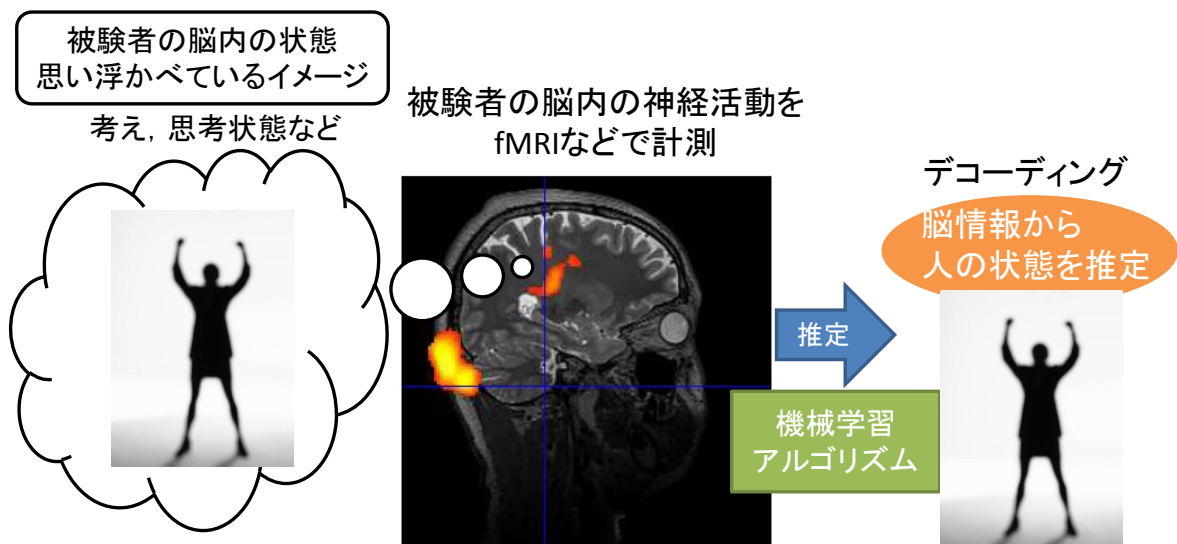


図 1.1 脳情報デコーディングの概観

第 2 章

機械学習アルゴリズム

本項では、本研究で用いる 4 つの機械学習アルゴリズムについて、基礎的な知識を解説する。

2.1 Support Vector Machine

SVM (Support Vector Machine) は、教師あり学習によって学習器を構成するノンパラメトリックな手法のひとつである。1995 年に Vapnik らによって提案された [6]。SVM は最適化問題を解くことで、マージンが最大になるような分離超平面 (最適超平面) を求める手法である。図 2.1 が、SVM の原理を完結に示した図である。2 次元の特徴空間上に複数のベクトルが存在し、各ベクトルはクラス A、クラス B のうちいずれかのクラスに属するとする。図ではクラス A は赤色、クラス B は青色で表す。2 つのクラスを直線で分離する場合、直線 A、直線 B のように、複数の解が考えられる。直線 A は 2 つのクラスを分離できているが、境界付近のベクトルと直線の距離が近く、未知のデータを正しく識別できないことが考えられる。このとき、直線 B のように、2 つのクラスの境界に最も近いベクトルとの距離 (マージン) を最大にすることで、一意の解に収束する。マージンを最大化することで汎化性能を高めることができ、未知の入力データに対しても高い識別精度を維持することができる。特徴空間上のベクトルには、取り除いても解が変わらないベクトルが存在する。取り除くと解に影響するベクトルをサポートベクトルと呼ぶ。決定関数でクラス判別を行う際は、サポートベクトルのみが使われるため、実質的な次元削減な次元削減が可能となっている。

SVM の分離超平面を求める最適化問題は式 2.1、制約条件は式 2.2 で定義される。

2.2 ニューラルネットワーク

$K(\mathbf{x}, \mathbf{x}')$ 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．

$$\max Q(\alpha) = \sum_{i=1}^M \alpha_i - \frac{1}{2} \sum_{i,j=1}^M \alpha_i \alpha_j y_i y_j K(\mathbf{x}, \mathbf{x}') \quad (2.1)$$

$$\text{s.t. } \sum_{i=1}^M y_i \alpha_i = 0, 0 \leq \alpha_i \leq C (i = 1, \dots, M) \quad (2.2)$$

また，決定関数は式 2.3 となる． S はサポートベクトルの添字集合である．

$$D(x) = \sum_{i \in S} \alpha_i y_i K(\mathbf{x}, \mathbf{x}') + b \quad (2.3)$$

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が挙げられる．また，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．

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 [4] に用いられている．

2.2 ニューラルネットワーク

ニューラルネットワークは，教師あり学習によって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はたらきをする．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

2.2 ニューラルネットワーク




図 2.1 Support Vector Machine

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 [7]。入力 v に対する教師信号と出力 y の誤差を元

2.3 ランダムフォレスト

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 2.4 となる． b_{kj} は k 層の j 番目のニューロンのバイアス， f, g は伝達関数である．伝達関数には通常シグモイド関数（式 2.5）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．

$$Q_{kj} = f\left(\sum_{i=1}^N Q_{k-1i} w_{kij} + b_{kj}\right) \quad (2.4)$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.5)$$

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．脳情報デコーディングの分野においては，人間の視覚野の方位選択制をデコードするために用いられている [1]．

2.3 ランダムフォレスト

ランダムフォレストは，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 [8]．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．

ランダムフォレストの学習アルゴリズムを以下に示す [9]．教師データ t_i と特徴ベクトル \mathbf{v}_i が一組になったサンプル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．

2.3 ランダムフォレスト

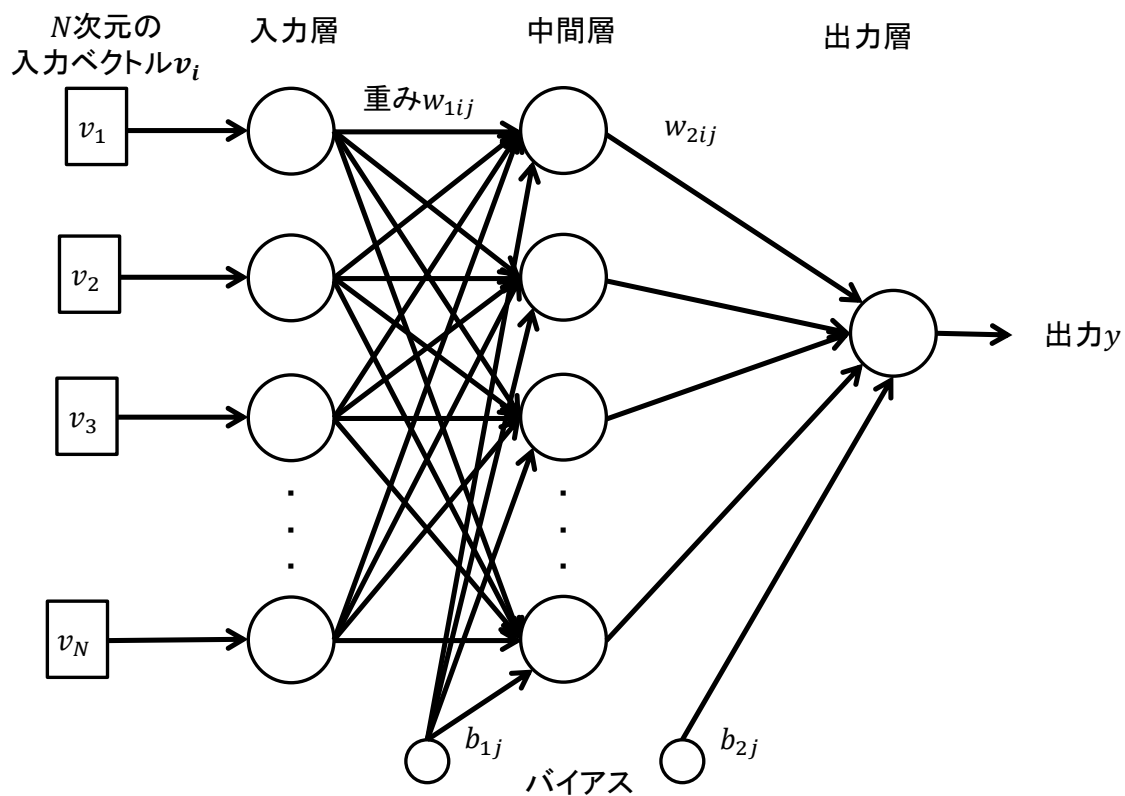


図 2.2 ニューラルネットワーク

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. θ 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 θ 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

2.4 Sparse Logistic Regression

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 θ 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。

2.4 Sparse Logistic Regression

SLR (Sparse Logistic Regression) は、ロジスティック回帰をベイズ推定の枠組みで拡張した手法である。2008年に Yamashita らによって提案された [10]。特徴量の重みの推定に、Automatic Relevance Determination (以下 ARD) を用いる。ARD はベイズ推定の事前分布を用いた手法で、重み θ は周辺化事後確率として推定される。推定の際には、学習した重み θ^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。

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手法であり、実際に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 [2]。

2.4 Sparse Logistic Regression

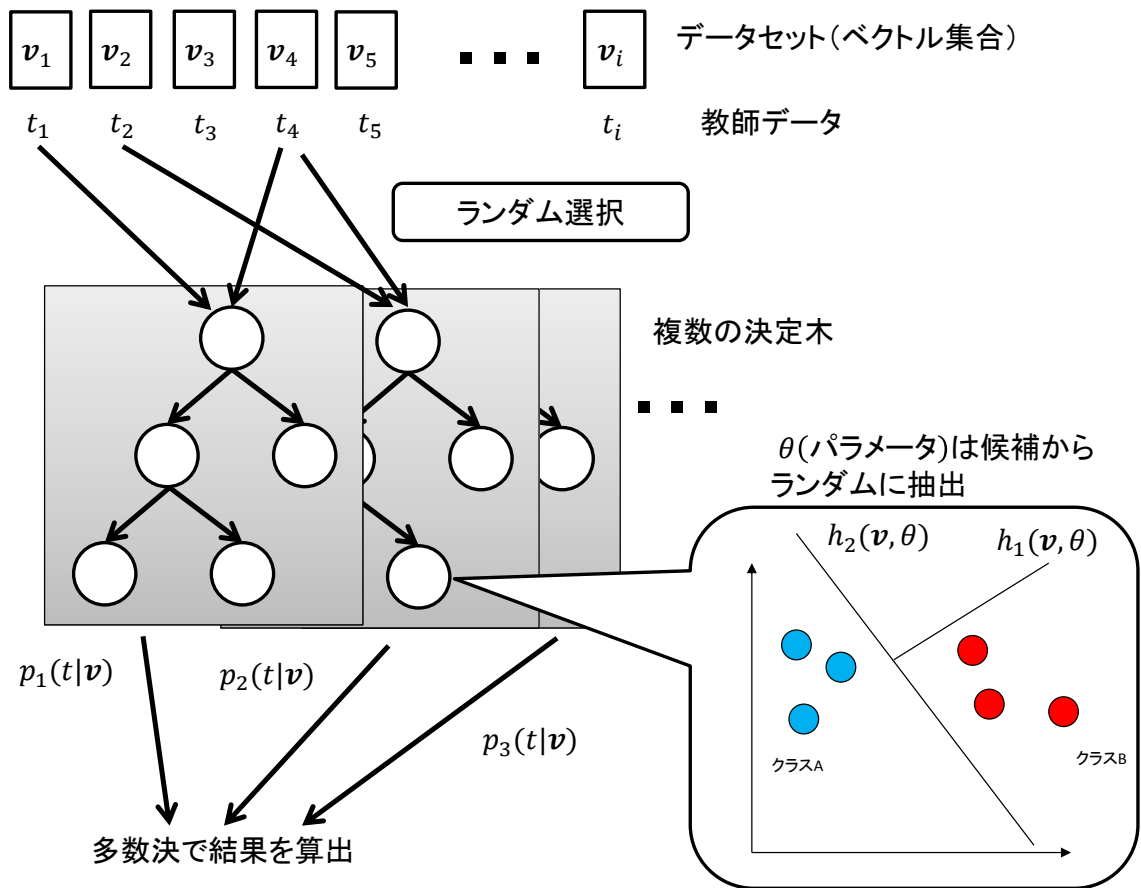


図 2.3 ランダムフォレスト

2.4 Sparse Logistic Regression

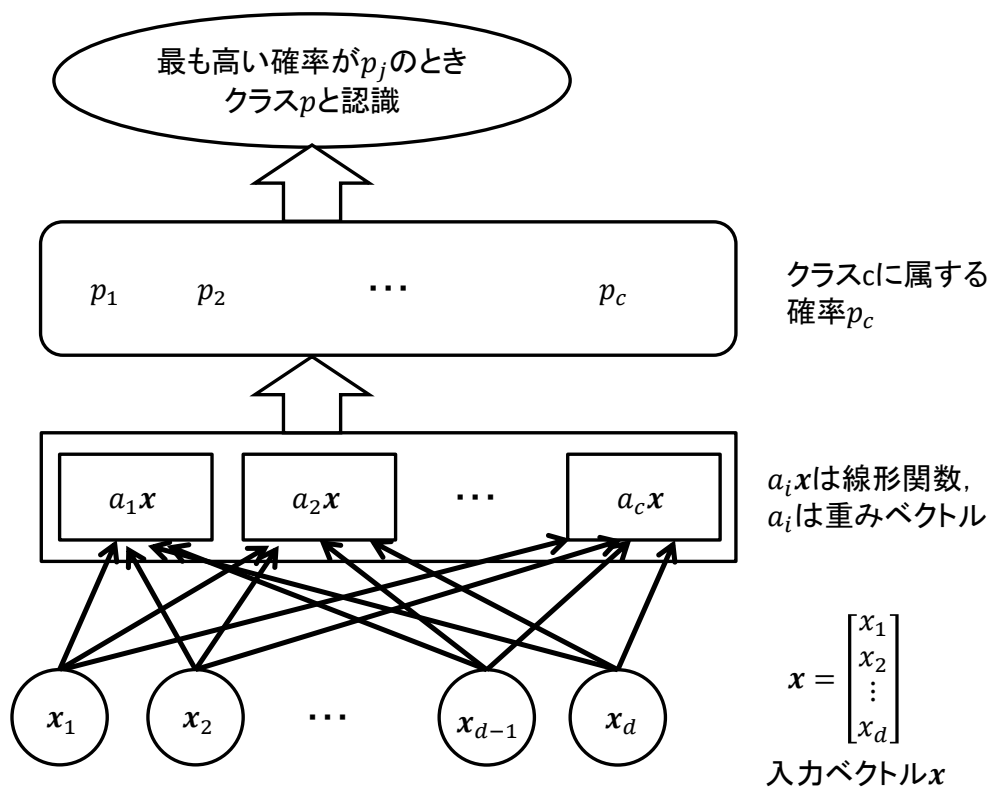


図 2.4 Sparse Logistic Regression

第 3 章

実験内容

本項では、データセット作成のために行う実験と、解析の方法、デコーダのパラメータについて書く。まず、被験者の情報、fMRI の計測パラメータ、被験者にじゃんけんの手を模倣させる試行の詳細な手順を示す。次に、SPM を用いた関心領域 (ROI) の設定手順と解析手順およびパラメータを示す。最後に、デコーダに使用するアルゴリズムの一覧と評価方法について示す。

3.1 実験

データセット作成のために、被験者にじゃんけんの手を模倣させる試行を行う。

3.1.1 被験者

正常な視覚をもつ 1 名の男子学生 (22 歳) が被験者として参加した。被験者は fMRI 装置についての説明、実験の内容と要する時間、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。

3.1.2 計測パラメータ

本研究では、fMRI 装置として SIEMENS 社の MAGNETOM Verio (3T) を使用する。撮像パラメータは、FOV=192mm, 64 × 64 matrix, 1 ボクセルあたりのサイズが 3 × 3 × 3 mm, スライス数 50 slice, TE 50 ms, フリップアングル 90°, TR 5000ms とする。

3.1 実験

3.1.3 試行の内容

図 3.1 が試行内容である。fMRI 内の被験者に、ヘッドホンからの音声刺激と、プロジェクタで投影した画像刺激を同時に与える。刺激提示には Presentation を用いる。提示する画像刺激は、模倣させたいじゃんけんの手（グー、チョキ、パー）のいずれか、もしくは Rest 表示である。提示するじゃんけんの手画像には、実際に出した手を撮影した写真を用いる。手の画像は黒い背景の中心に配置される。音声刺激は 1 秒間隔のサイン波である。被験者は 1 秒間隔の音声指示に従い、脱力状態から指示されたじゃんけんの手を模倣を繰り返す。

被験者に模倣させた手のリストを表 3.1 に示す。1 ブロックの長さを 20 秒とする。実験開始から 20 秒間の Rest(脱力) 期間の後、20 秒ごとに模倣させる手の指示を変更する。最後に再び 20 秒間の Rest 期間をもって 1Run とする。これを、提示する手の順番を変えながら、合計 10Run 分行う。

表 3.1 被験者に行わせた試行のリスト

| 開始秒数(秒) | 0 | 20 | 40 | 60 | 80 | 100 | 120 | 140 |
|---------|------|-----|-----|-----|-----|-----|-----|------|
| Run1 | rest | チョキ | グー | パー | グー | パー | チョキ | rest |
| Run2 | rest | チョキ | パー | グー | グー | チョキ | パー | rest |
| Run3 | rest | グー | チョキ | パー | グー | パー | チョキ | rest |
| Run4 | rest | パー | グー | チョキ | グー | チョキ | パー | rest |
| Run5 | rest | チョキ | パー | グー | グー | チョキ | パー | rest |
| Run6 | rest | パー | チョキ | グー | パー | グー | チョキ | rest |
| Run7 | rest | パー | グー | チョキ | グー | パー | チョキ | rest |
| Run8 | rest | チョキ | パー | グー | チョキ | グー | パー | rest |
| Run9 | rest | チョキ | グー | パー | グー | パー | チョキ | rest |
| Run10 | rest | グー | チョキ | パー | チョキ | パー | グー | rest |

3.2 SPM を用いた ROI セッション解析

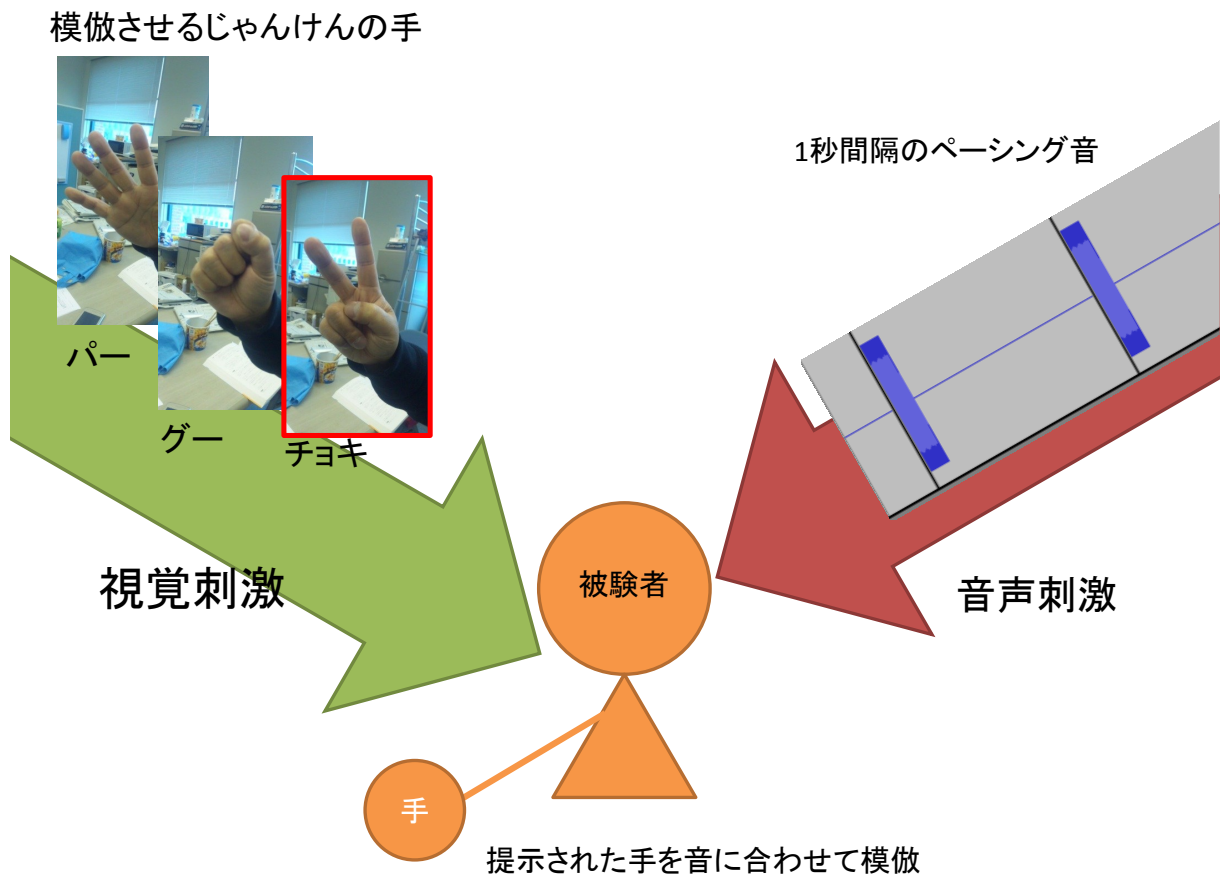


図 3.1 被験者の試行内容

3.2 SPM を用いた ROI セッション解析

fMRI で撮像した画像には試行に関係のない信号も含まれるため、統計的な解析で有意な活動のみを取り出す必要がある。解析には SPM5 [11] を用いる。解析の流れを 3.2 に示す。

fMRI が撮像した脳画像は DICOM 形式で保存されるため、SPM で処理するために Analyze 形式に変換する。DICOM 形式から Analyze 7.5 形式への変換には MRIConvert [12] を利用する。

3.3 デコーダの構成と評価

統計解析の前処理は Realign , Normalize , Smooth の順に行う . Normalize は T1 構造画像ではなく , Realign の際に生成される全 EPI 画像の平均画像に合わせて正規化する . また , セッションにおける各 Run について , 先頭 5 秒分の画像 (1 ファイル) はノイズを多く含むため , 前処理の段階で除去する .

さらに本実験では , 手の動作に伴う脳活動をデコーディングするため , 関心領域 (ROI) を設定する . 一次運動野 (M1) , 補足運動野 (Supplementary Motor Area , SMA) , 小脳全体 (Cerebellum , CB) の領域の左右それぞれについて合計 6 通りの ROI マスクを生成する . ROI マスクの作成には WFU pickAtlas [13] を用いる . M1 の ROI マスクについては , "TD Brodmann's areas" の "brodmann area 4" (ブロードマン 4 野) を選択する . それぞれの ROI マスクは , Realign 時に生成される EPI の平均画像に合わせて , 個人座標系に変換してから解析に用いる .

全ての条件において有意な活動の見られる脳領域について , ROI セッション解析を行い , 検出された最も大きなクラスタの各ボクセルの座標と輝度を統計量ファイルに保存する . 統計的解析には t 検定を用い , p 値の有意水準は 0.001 に設定する . 実際の解析では , 一次運動野左脳側からは 100 ボクセル , 補足運動野左脳側からは 24 ボクセル , 小脳右脳側からは 407 ボクセルが検出された . 一次運動野右脳側 , 補足運動野右脳側 , 小脳左脳側についてはクラスタが検出されなかったため , これらを除く合計 531 ボクセルを機械学習で扱う特徴量とする . よって , データセットの大きさは 310 , 特徴量の次元は 531 次元となる .

さらにデータセット全体に対し , 1 秒分の時間方向シフト , 外れ値の除去 , 時間方向でのトレンド除去 , ブロック単位での平均化 , 時間方向のベースラインによる正規化を行う .

3.3 デコーダの構成と評価

本研究で比較検討する学習手法は次の通りである .

- SVM (線形カーネル)
- SVM (RBF カーネル)

3.3 デコーダの構成と評価

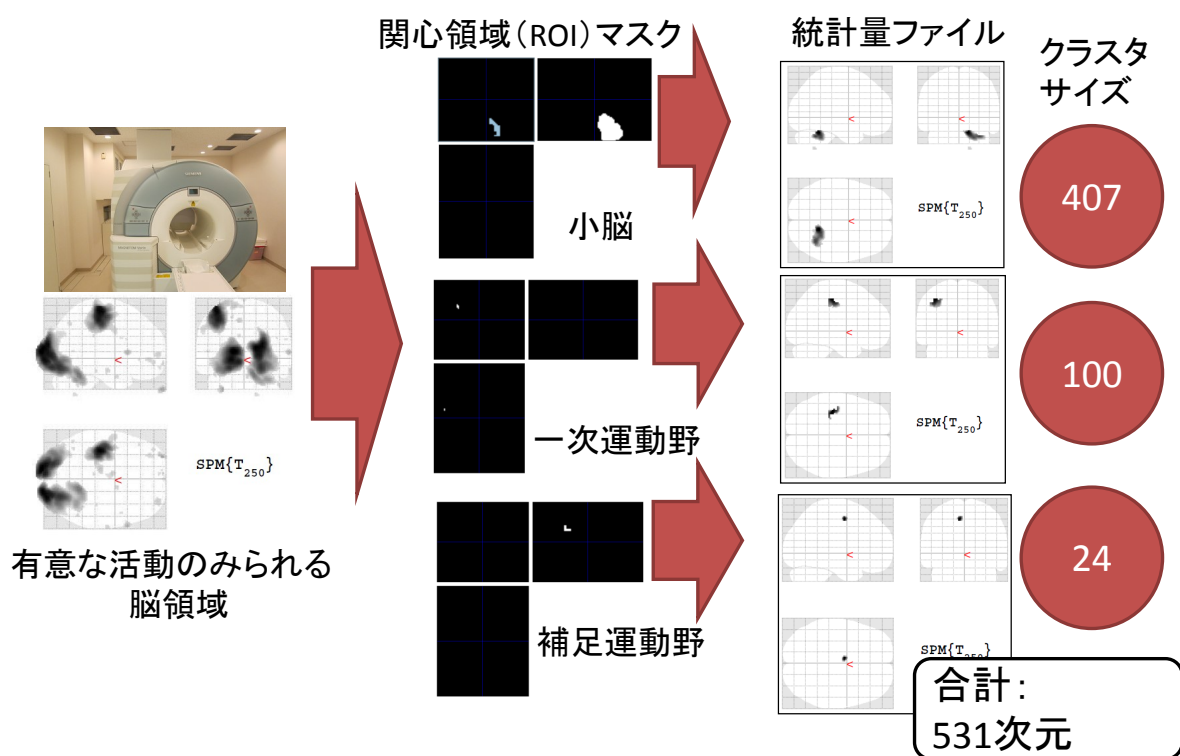


図 3.2 ROI セッション解析の流れ

- SVM (多項式カーネル)
- 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)

3.3 デコーダの構成と評価

- SLR-var-1vsR
- SLR-lap-1vsR

デコーダには ATR の公開する Brain Decoder Toolbox 1.2.2 [14] (以下 BDTB) を利用する .

3.3.1 SVM デコーダ

SVM デコーダには , BDTB にあらかじめ実装されている , libsvm-3.16 [15] によるデコーダを用いる . 写像を行わない線形カーネル (式 3.1) , RBF カーネル (式 3.2) , 多項式カーネル (式 3.3) , シグモイドカーネル (式 3.4) を使用する .

$$K(\mathbf{x}, \mathbf{x}') = \mathbf{x}^T \mathbf{x}' \quad (3.1)$$

$$K(\mathbf{x}, \mathbf{x}') = \exp(-\gamma \|\mathbf{x} - \mathbf{x}'\|^2) \quad (3.2)$$

$$K(\mathbf{x}, \mathbf{x}') = (\mathbf{x}^T \mathbf{x}' + 1)^d \quad (3.3)$$

$$K(\mathbf{x}, \mathbf{x}') = \tanh(\alpha \mathbf{x} \cdot \mathbf{x}' + \theta) \quad (3.4)$$

3.3.2 ニューラルネットワークデコーダ

Neural Network Toolbox 2.0 [17] によるニューラルネットワークデコーダを実装する . 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 層のものである . 中間層および隠れ層のニューロンには双曲線対数シグモイド関数 (式 3.5) 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次元数の 1/10 に 1 を足した 54 つ , 最大反復回数は 3000 回 , 終了条件は誤差が 10^{-6} 未満になった場合とする .

3.3 デコーダの構成と評価

$$f(x) = \frac{2}{1 + e^{-2x} - 1} \quad (3.5)$$

3.3.3 ランダムフォレストデコーダ

randomForest package 4.6-7 [19, 18] によるランダムフォレストデコーダを実装する．決定木の数が 500 と 1000，木の木数が異なる 2 つのデコーダを比較する．決定木の分岐に用いる変数の数はどちらも変数の総数の二乗根である 14 を用いる．

3.3.4 SLR デコーダ

Sparse Logistic Regression toolbox 1.2.1alpha [16] による SLR デコーダを用いる．ラプラス近似 (LAP) の手法を取り入れたものと変分型近似 (VAR) 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 150 回とする．

3.3.5 性能評価

性能評価のために，データセットを Run 単位で分割した 10 - 分割交差検定 (クロスバリデーション) を行う．分割したサブセットに対して，Z スコアへの正規化，rest 条件のデータの除去を行う．前処理を行ったテストデータを用いて，学習精度を算出する．計算コストについては MATLAB の profile 関数を用いて学習関数の実行時間を算出し，学習関数を 1 回実行するのにかかった時間を求める．計算機には，Intel Xeon X5675 と 147 ギガバイトのメモリを搭載した Windows マシンを使用する．

ニューラルネットの重みの初期値はランダムに決定されるため，ニューラルネットデコーダのみ 10 回デコードを行い，その平均を結果とする．

第 4 章

結果と考察

各アルゴリズムの精度を表 4.1 と図 4.1 にまとめた。線形カーネルを使用した SVM が最も精度が高く、次いで SLR、ランダムフォレストが続き、最も精度が低かったのがニューラルネットワークだった。線形カーネルを使用した SVM が高速であった理由として、テストデータが線形分離可能なデータだったのではないかと理由が考えられる。ランダムフォレストについては、脳情報デコーディングに用いるデータは被験者にかかる計測の負担が大きいなどの理由からどうしてもサンプル数が少なくなってしまうことから、大量データに強いランダムフォレストの特性がうまく生かされなかったのだと思われる。

各アルゴリズムの学習関数の実行時間を表 4.2 と図 4.2 にまとめた。こちらも線形カーネルを使用した SVM が最も高速で、ランダムフォレスト、SLR が続き、ニューラルネットワークが最も計算時間を要した。線形カーネルを使用した SVM が最も高速だった理由も、高精度だった要因と同じく、データの特徴が線形 SVM に適していたことが考えられる。ニューラルネットワークが低速だった理由については、重みの更新のために反復回数を 3000 回近く取らねばならず、近似に時間がかかってしまったのではないかと考えられる。

今回の実験では線形 SVM が最も高性能で、ニューラルネットワークが低性能だという結果になったが、今後ハードウェアの性能が向上し、大規模なマルチコア CPU による並列処理が普及した場合、アルゴリズムの並列化によってこの結果は覆る可能性がある。並列化するために SVM は二次最適化問題を解く必要がある。しかしランダムフォレストは各決定木の処理が独立しており、ニューラルネットも各層のニューロン同士は独立性が高いため、並列化による性能向上が見込めると考えられる。

表 4.1 識別率

| 機械学習アルゴリズム | 識別率 (%) |
|---------------------------------|---------|
| SVM (線形カーネル) | 93.3% |
| SVM (RBF カーネル) | 86.7% |
| SVM (多項式カーネル) | 86.7% |
| SVM (シグモイドカーネル) | 88.3% |
| ニューラルネット (3 層) | 72.1% |
| ニューラルネット (4 層) | 75.8% |
| ランダムフォレスト (ntree=500, mtry=14) | 81.7% |
| ランダムフォレスト (ntree=1000, mtry=14) | 81.7% |
| SLR-var-1vsR | 91.7% |
| SLR-lap-1vsR | 90.0% |

表 4.2 実行速度

| 機械学習アルゴリズム | 実行速度 (s) |
|---------------------------------|----------|
| SVM (線形カーネル) | 0.004 |
| SVM (多項式カーネル) | 0.007 |
| SVM (RBF カーネル) | 0.007 |
| SVM (シグモイドカーネル) | 0.017 |
| ニューラルネット (3 層) | 9.665 |
| ニューラルネット (4 層) | 13.381 |
| ランダムフォレスト (ntree=500, mtry=14) | 0.026 |
| ランダムフォレスト (ntree=1000, mtry=14) | 0.052 |
| SLR-var-1vsR | 0.155 |
| SLR-lap-1vsR | 4.687 |




図 4.1 識別率の比較

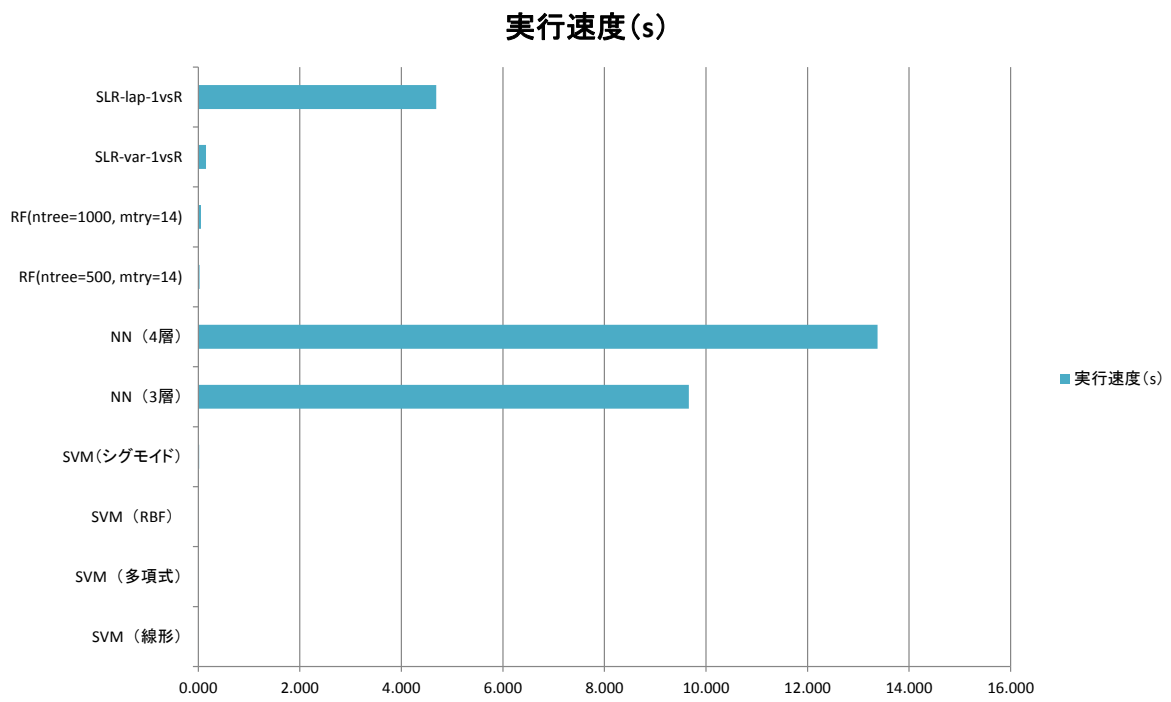


図 4.2 実行速度の比較

第 5 章

結論

本稿では、脳情報デコーディング技術の核となる機械学習アルゴリズムのうち、SVM、ニューラルネットワーク、ランダムフォレスト、SLR という 4 つの手法について有効性を検討した。デコーディングする問題として、被験者にじゃんけんの手を出させる試行を扱い、一次運動野、補足運動野、小脳の活動に着目して学習データを作成した。各機械学習アルゴリズムを用いた脳情報デコーダを実装して MATLAB 上でクロスバリデーションを行い、推定精度と学習関数の実行時間について比較した。その結果、識別精度については、線形カーネルを使用した SVM が最も高く、ニューラルネットワークが最も低いことがわかった。学習速度については、線形カーネルを使用した SVM が最も高速で、ニューラルネットワークが最も低速であることがわかった。

本研究の範囲では線形 SVM が最も優れた結果を示し、ニューラルネットワークの性能が低いという結果が出たが、今後ハードウェアの性能向上にともなって実行環境が変化すれば、並列化に不向きな SVM よりも、弱識別器の独立性が高いランダムフォレストとニューラルネットワークが高い性能を発揮する可能性がある。

本研究の成果は、今後 Brain Computer Interface もしくは Brain Machine Interface がシステムとして実用化されるにあたって、ソフトウェア実行環境の計算リソースに適した機械学習アルゴリズムの選択に応用できるだろう。

謝辞

本研究を進めるにあたり，卒業論文指導教員の情報学群 吉田研究室 吉田真一 講師から脳情報デコーディングという研究ジャンルへ取り組むきっかけを頂いたほか，fMRI 装置の運用をはじめ，様々なご指導を頂きました．ここに深く感謝いたします．

そして学習アルゴリズムの選定のほか，研究活動に様々な形で協力していただいた吉田研究室の皆様，fMRI 実験は被験者への負担が大きいのにもかかわらず，予備実験を含めた多くの実験に参加していただいた被験者の方々へ感謝いたします．協力していただいた数多くの方々へ心から感謝を申し上げたく，謝辞にかえさせていただきます．

参考文献

- [1] Yukiyasu Kamitani & Frank Tong, "Decoding the visual and subjective contents of the human brain", *Nature Neuroscience*, 400-410, 2005
- [2] Miyawaki, Yoichi; Uchida, Hajime; Yamashita, Okito; Sato, Masa-aki; Morito, Yusuke; Tanabe, Hiroki C.; Sadato, Norihiro; Kamitani, Yukiyasu, "Visual Image Reconstruction from Human Brain Activity using a Combination of Multiscale Local Image Decoders", *Neuron*, 915-929, 2008
- [3] Shinji Nishimoto, et al, "Reconstructing Visual Experiences from Brain Activity Evoked by Natural Movies", *Curr. Biol.*, 21(19), 1641-1646, 2011
- [4] 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 回ブレインコミュニケーション研究会講演予稿集, 29/32, 2006
- [5] ATR と Honda、脳でロボットを操作する基礎技術の開発に成功 ,
<http://www.honda.co.jp/news/2006/c060524a.html>
- [6] Cortes, Corinna; and Vapnik, Vladimir N.; "Support-Vector Networks", *Machine Learning*, 20, 1995.
- [7] Rumelhart, David E.; Hinton, Geoffrey E., Williams, Ronald J., "Learning representations by back-propagating errors", *Nature* 323 (6088), 533-536, 1986
- [8] Breiman, L.: Random Forests, *Machine Learning Vol.45 No.1*, pp.5-32, 2001
- [9] 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 , 2012.5 .
- [10] Yamashita O, Sato MA, Yoshioka T, Tong F, Kamitani Y, "Sparse estimation automatically selects voxels relevant for the decoding of fMRI activity patterns." *Neuroimage* 42(4), 2008, 1414-1429
- [11] SPM5 - Statistical Parametric Mapping, <http://www.fil.ion.ucl.ac.uk/spm/software/spm5/>

参考文献

- [12] MRIConvert: a nifty DICOM file converter,
<http://lcn1.uoregon.edu/~jolinda/MRIConvert/>
- [13] ANSIR Laboratory :: PickAtlas, <http://fmri.wfubmc.edu/software/PickAtlas>
- [14] Brain Decoder Toolbox — ATR - DNi,
<http://www.cns.atr.jp/dni/download/brain-decoder-toolbox/>
- [15] 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>
- [16] SLR toolbox Web Page, http://www.cns.atr.jp/~oyamashi/SLR_WEB.html
- [17] Neural Network Toolbox - MATLAB - MathWorks 日本,
<http://www.mathworks.co.jp/products/neural-network/>
- [18] randomforest-matlab - Random Forest (Regression, Classification and Clustering) implementation for MATLAB (and Standalone) - Google Project Hosting,
<http://code.google.com/p/randomforest-matlab/>
- [19] CRAN - Package randomForest,
<http://cran.r-project.org/web/packages/randomForest/index.html>

付録 A

各条件における SPM 解析結果

本項では、第 3 章で撮像した脳画像を SPM で統計処理した結果と、その見方について説明する。fMRI SPM の解析結果は、fMRI で撮像した画像を 3 次元座標に変換した各ボクセルについて、ベースラインに対して有意な差が見られるかどうかで示される（図 A.1）。ベースラインとは、いわゆる「何もしていない」状態の脳活動を計測したものである。本実験では、各 Run の最初と最後に設けられた 20 秒の Rest 期間をベースラインとする。

図 A.1 の左側に配置されている 3 面図がいわゆるグラスブレインである。グラスブレインとは、標準脳を完全に透けて見える状態にしたものである。SPM は 3 次元座標に変換した脳活動をグラスブレインに重ねあわせて表示する。活動はグレースケールで描画され、活動が強ければ強いほど色が濃い。図 A.1 からは、主に視覚野と小脳、一次運動野に有意な脳活動がみられる。

グラスブレインの右側に配置されているのがデザインマトリクスである。下側の図は時間と条件を表しており、縦方向が時間、横方向が条件である。時間は上から下方向に進む。条件は（試行数 × 条件数）列分存在し、左端から「1Run 目のゲー」、「1Run 目のチョコキ」、「1Run 目のパー」、「2Run 目のゲー」... と 10Run 分続き、右端が 1~10Run 目について各 Run 全体を表す部分で終了する。上側の棒グラフは解析に用いた条件を表し、条件の各列と対応している。t 検定の場合は条件同士の有意な活動の差分を求めるため、1 から -1 の範囲でコントラストを設定する。本研究では、デコーディングに用いるボクセルを選択するため、すべての条件に対して 1 を設定する。

図 A.2 が、被験者がゲーを出している時に活動する脳部位、図 A.3 がチョコキを出している時の活動部位、図 A.4 がパーを出している時の活動部位である。パー条件のグラスブレ

インにはノイズが目立つのに対して、チョコキ、ゲーの順でノイズは減少していく。これは、rest 状態から目的の手を出すために握りこむ指の本数が、パーは0本、チョコキは3本、ゲーは5本全てであるからだと考えられる。

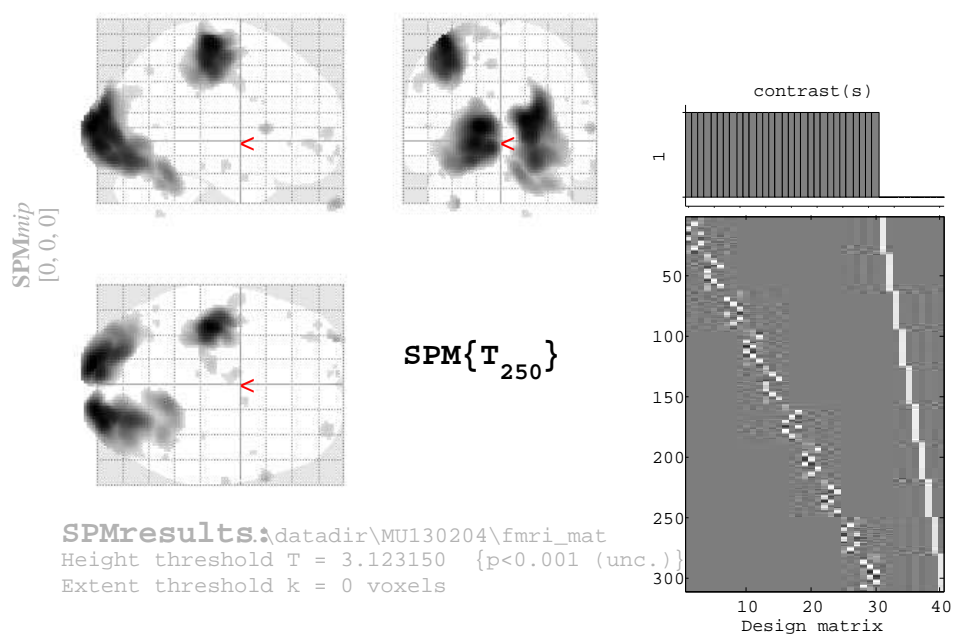


図 A.1 全条件における賦活領域

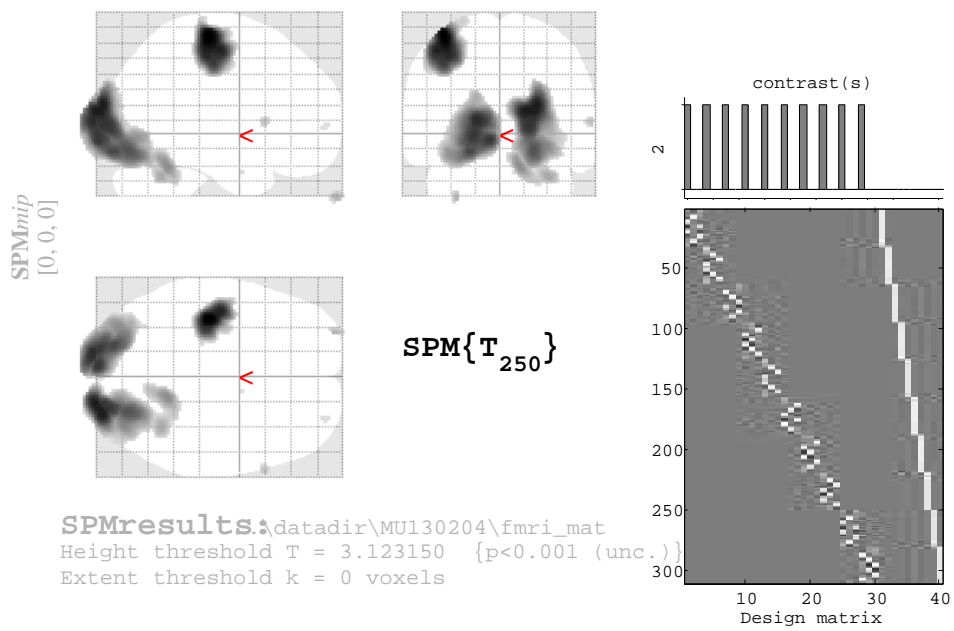


図 A.2 rock 条件における賦活領域

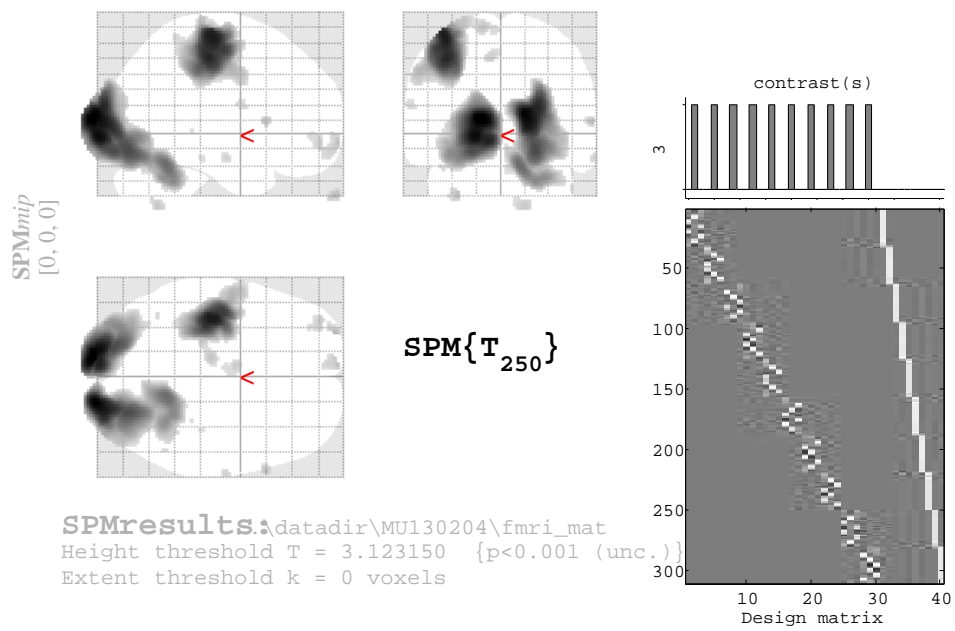


図 A.3 scissors 条件における賦活領域

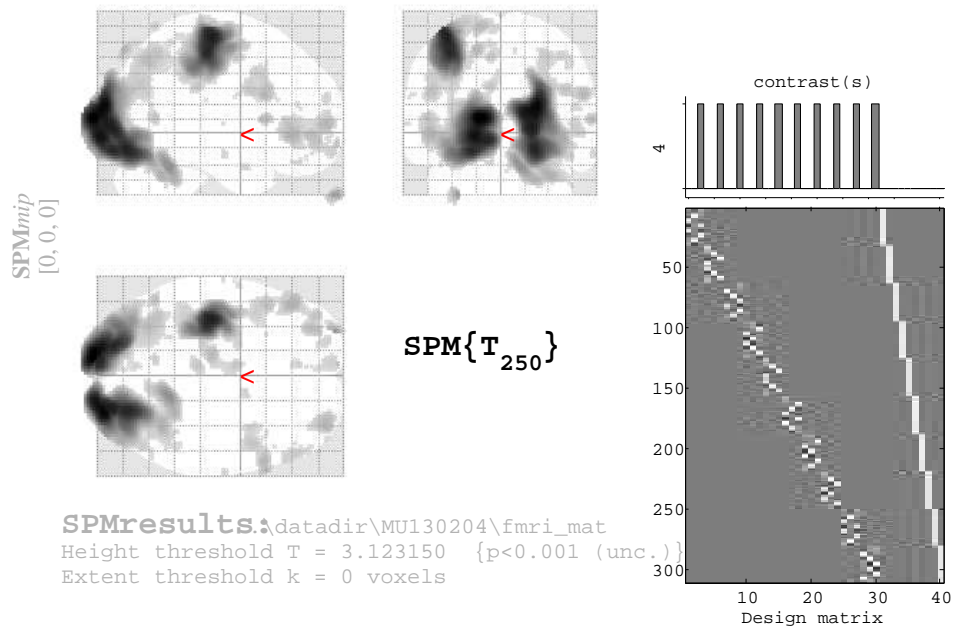


図 A.4 paper 条件における賦活領域