

平成 28 年度

学士学位論文

# 進化計算法による表情理解を推定する 脳情報復号器の性能向上

Performance Improvement by Evolutionary  
Computation for Brain Decoding of Facial  
Expression Recognition

1170319 佐々木泰一

指導教員 吉田真一

2017 年 2 月 28 日

高知工科大学 情報学群

# 要旨

## 進化計算法による表情理解を推定する 脳情報復号器の性能向上

佐々木 泰一

fMRI を用いた脳情報デコーディングはこれまで視覚を中心に成功報告がいくつか存在する。脳情報デコーディングで機械学習を行う際のハイパーパラメータの決定は、多くの場合、指定した範囲を総当りで探索する、Gridサーチで行うが、広範囲でハイパーパラメータを探索する際に、膨大な計算時間を要する場合がある。そこで本研究では、進化計算法の一種である、粒子群最適化 (Particle Swarm Optimization: PSO) を用いてハイパーパラメータを定めることで、短時間での識別精度の確保を実現する。PSO は多次元のパラメータ空間において、位置と速度を持つ粒子群によりモデル化され、粒子がそれぞれ空間内を移動し、最適値を探す。

評価実験では、被験者 8 名に対して、人の喜び、怒りの表情画像を見せた際の脳活動データを用い、SPM による個人解析、ガウシアンカーネル (RBF カーネル) を用いた SVM による機械学習を行う。この際の SVM のハイパーパラメータを PSO を用いて定めている。結果として、多くの被験者において、PSO を用いた場合の方が短い時間で高い識別率を得ることができることが分かった。したがって、PSO は脳情報デコーディングの機械学習のハイパーパラメータを定める手法として有効であると言える。

**キーワード** 粒子群最適化, 脳情報デコーディング, カーネル法, サポートベクトルマシン

# Abstract

## Performance Improvement by Evolutionary Computation for Brain Decoding of Facial Expression Recognition

There are several studies of brain decoding using fMRI and they are mainly focused on vision. Brain decoding employs machine learning and hyper-parameters should be determined for the algorithm. Previous studies use grid search to optimize the parameters. Generally, the search space of hyper-parameters are wide and sometimes it takes a long time to optimize the parameters. Therefore, in this study we use particle swarm optimization (PSO), which is a variation of evolutionally computation, to search optimal parameters. This study aims at the improvement of accuracy of brain decoding, while it spends a shorter time for the optimization of hyper-parameters. In PSO, particles have position and velocity, and each particle moves in the search space to find optimum values of hyper-parameters.

In order to evaluate the proposed technique, we use the fMRI data retrieved for a brain decoding study of facial expressions. We perform SPM analysis for the data for preprocessing and obtain brain activity data for 8 subjects seeing smile and anger faces. Grid search and PSO are used to optimize the hyper-parameters and compared each other. Support vector machine with Gaussian kernel is used as machine learning. As a result, we found that the higher accuracy can be obtained in a shorter time by PSO.

**key words**    Perticle Swarm Optimization, Brain Decoding, Kernel Methods, Support Vector Machine

# 目次

<b>第 1 章</b>	<b>序論</b>	<b>1</b>
<b>第 2 章</b>	<b>関連技術</b>	<b>3</b>
2.1	Functional Magnetic Resonance Imaging(fMRI) . . . . .	3
2.2	脳情報デコーディング . . . . .	3
2.3	Support Vector Machine(SVM) . . . . .	4
2.4	カーネル法 . . . . .	4
2.5	Grid サーチ . . . . .	5
2.6	Particle Swarm Optimization(PSO) . . . . .	5
<b>第 3 章</b>	<b>実験</b>	<b>8</b>
3.1	表情画像提示実験 . . . . .	8
3.1.1	実験概要 . . . . .	8
3.1.2	実験デザイン . . . . .	8
3.2	脳活動データ解析 . . . . .	9
3.2.1	画像変換 . . . . .	9
3.2.2	前処理 . . . . .	9
3.2.3	個人解析 . . . . .	10
3.3	評価実験 . . . . .	10
3.3.1	賦活ボクセルの時系列データ抽出 . . . . .	10
3.3.2	PSO を用いた機械学習 . . . . .	11
<b>第 4 章</b>	<b>結果</b>	<b>13</b>
4.1	被験者 A の識別率 . . . . .	13
4.2	被験者 B の識別率 . . . . .	14

## 目次

4.3	被験者 C の識別率 . . . . .	15
4.4	被験者 D の識別率 . . . . .	16
4.5	被験者 E の識別率 . . . . .	17
4.6	被験者 F の識別率 . . . . .	18
4.7	被験者 G の識別率 . . . . .	19
4.8	被験者 H の識別率 . . . . .	20
<b>第 5 章</b>	<b>考察</b>	<b>22</b>
<b>第 6 章</b>	<b>結論</b>	<b>24</b>
	<b>謝辞</b>	<b>25</b>
	<b>参考文献</b>	<b>27</b>

# 目次

2.1	PSO の処理の流れ . . . . .	6
2.2	粒子の位置 $x$ と, 速度 $v$ 更新の様子 . . . . .	7
3.1	前原の実験デザイン [1] . . . . .	9
3.2	賦活ボクセル一覧 . . . . .	11

# 表目次

4.1	被験者 A の PSO と Grid サーチの識別率 . . . . .	14
4.2	被験者 B の PSO と Grid サーチの識別率 . . . . .	15
4.3	被験者 C の PSO と Grid サーチの識別率 . . . . .	16
4.4	被験者 D の PSO と Grid サーチの識別率 . . . . .	17
4.5	被験者 E の PSO と Grid サーチの識別率 . . . . .	18
4.6	被験者 F の PSO と Grid サーチの識別率 . . . . .	19
4.7	被験者 G の PSO と Grid サーチの識別率 . . . . .	20
4.8	被験者 H の PSO と Grid サーチの識別率 . . . . .	21

# 第 1 章

## 序論

近年高齢化に伴い、老化によって自分の身体を思ったように動かすことができない人が増えている。そこで、医療や介護の分野においてブレイン・マシン・インタフェース (BMI) や、ブレイン・コンピュータ・インタフェース (BCI) などの技術が期待されている。これらの技術は、頭で考えただけでモノを動かすことができるようになるもので、車いすや義手の操作などに用いられる。現在は脳波を用いた制御が主であるが、ノイズが多く含まれるという欠点が存在し、研究の障害となっている。しかし、fMRI を用いた脳情報デコーディングでは快・不快感情の識別や [2], 顔画像の識別 [3] など、成功報告がいくつか存在する。fMRI は、脳波よりも詳細に脳活動を測定することができるメリットがある。更に、部分的な脳活動だけでなく、脳全体のパターンを見ることができると考えられる。

脳情報デコーディングで機械学習を行う際のハイパーパラメータの決定は、多くの場合、指定した範囲を総当りで探索する、Grid サーチで行うが、広範囲でハイパーパラメータを探索する際に、膨大な計算時間を要する場合がある。そこで本研究では、進化計算法の一種である、粒子群最適化を用いてハイパーパラメータを定めることで、Grid サーチを用いた場合よりも短時間での識別精度の確保を実現する。

本論文の構成について、第 2 章では、本研究で使用した関連技術である fMRI, 脳情報デコーディング, SVM, カーネル法, PSO についてそれぞれ示す。第 3 章では表情画像提示実験, SPM を用いた統計解析, PSO を用いて SVM のハイパーパラメータを決めた際の識別率と Grid サーチを用いてハイパーパラメータを決めた際の識別率の比較評価について示す。第 4 章では、各被験者の脳活動データを解析し、機械学習した際の識別率を示し、それ



に関する考察を示す。第 5 章では、本研究の結論を示す。

## 第 2 章

# 関連技術

### 2.1 Functional Magnetic Resonance Imaging(fMRI)

Functional Magnetic Resonance Imaging(fMRI) は、人の脳活動によって引き起こされる血流の変化を、MR 装置 (核磁気共鳴装置) を用いて、可視化する方法である。これにより、脳の機能の画像化を行う。MR 装置は、強力な磁石の中で原子核の共鳴周波数電磁波を用い、体内の水素原子の原子核の分布を測定することにより、体内の組織の形状や動きを測定する。

### 2.2 脳情報デコーディング

脳情報デコーディングとは、見ているものや体の動きの状態などを、脳によってコード化された情報と見なし、それを脳活動信号から解読することを指す。この技術を用い、コンピュータなどを動かす BCI(Brain Computer Interface) の研究が、医療や介護の分野で期待されている。脳情報デコーディングは大きく分けて以下の 3 つのステップから成る [6]。

1. 脳活動信号を計測し、ラベルをつける
2. 脳活動信号からラベルを予測する統計モデル (デコーダ) を構築する。
3. 新たな脳活動信号を与えた時、デコーダが「ラベル」を正確に予測できるかを評価する。

まずステップ 1 で、撮像した脳活動データに、そのときに見ているものや、体を動かしている状態などを「ラベル」として付加する。本研究では、笑っている状態であるか、怒っている状態であるかを「ラベル」として付加する。ステップ 2 では、機械学習を用いて、付加

## 2.3 Support Vector Machine(SVM)

したラベルごとに学習させ、デコーダを構築する。ステップ3では、ステップ2で学習していない脳活動信号を与えた場合に、構築したデコーダで「ラベル」を正確に予測できるかを評価する。

本実験では、まず脳活動データに、笑っている状態であるか、怒っている状態であるかを「ラベル」として付加し、Support Vector Machine(SVM)を用いて学習を行い、デコーダを構築する。そして、構築したデコーダを用いて予測を行う。

## 2.3 Support Vector Machine(SVM)

Support Vector Machine(SVM)は、教師あり学習による、パターン認識学習アルゴリズムの1つで、最大マージンを実現する2クラス問題の線形識別関数構成法である [8]。線形分離不可能な場合には後述のカーネル法によって非線形特徴写像により高次元非線形特徴空間に写像し、線形分離可能にする。

## 2.4 カーネル法

SVMは、識別境界が線形の識別超平面となる。識別境界が学習データの線形関数では表せない場合には、非線形特徴写像を用いて非線形特徴空間に写像し、その空間内で線形識別関数を用いる方法がある。これをカーネル法と呼ぶ。カーネル法には、多項式カーネルなどもあるが、本実験ではRBFカーネル(Radial Bases Function kernel)を用いる。RBFカーネルは式(2.1)によって定義される [8]。

$\gamma$ はカーネル関数の広がり制御するパラメータである。 $\gamma$ が小さい場合は識別境界が単純になり、 $\gamma$ が大きい場合は識別境界が複雑になっていく。本実験では、後述するPSOを用いてこの $\gamma$ の値を定める。

$$K(x, x') = \exp(-\gamma [\|x - x'\|^2]) \quad (2.1)$$

## 2.5 Gridサーチ

Gridサーチは機械学習のハイパーパラメータのチューニングに一般的に用いられる手法である。Gridサーチのアルゴリズムは、チューニングしたいパラメータを、定めた範囲の中で総当りに組み合わせ、識別器を作成していく。その中で、最も良い結果が出た識別器のハイパーパラメータを、最適なハイパーパラメータとする。

## 2.6 Particle Swarm Optimization(PSO)

Particle Swarm Optimization(PSO)は、群知能の一種である。例えば、集団行動をとる社会性昆虫の群れにおいて、個体の簡単な振る舞いが全体として統一されたある種の知的活動を示すことがある。これを群知能と呼ぶ。近年、この群知能に着想を得た様々なアルゴリズムが提案されている。これらのアルゴリズムは、クラスタリング問題や、データマイニング問題など、これまで様々な場面に適用されている。その中でもPSOは現在、群知能分野において最もよく知られたアルゴリズムである。

PSOは集団に基づく探索アルゴリズムである。最初に、集団を構成する個々の粒子(particle)にそれぞれランダムな解をセットすることで初期化を行う。各粒子はそれぞれ探索空間内を動き回り、より良い探索領域へ向かう。PSOは以下の式によって表される。

$$x_{\text{next}} = x + v_{\text{next}} \quad (2.2)$$

$$v_{\text{next}} = \omega v + c_1 r_1 (\hat{x} - x) + c_2 r_2 (\hat{x}_g - x) \quad (2.3)$$

ここで  $x$  は粒子の位置、 $v$  は粒子の速度、 $\omega$  は慣性定数、 $c$  は加速度定数、 $r$  は  $0 \sim 1$  の間の乱数をそれぞれ表す。PSOの処理の流れを図2.1に示す。まず各粒子について、 $x$  と  $v$  をランダムに初期化する。 $\hat{x}$  は各粒子の過去を含めた位置の履歴での最適パラメータを表し、 $\hat{x}_g$  は群全体でそれまで見つかっている最適パラメータを表す。その後、事前に設定しておいた最大世代数に達するまで、 $x$  と  $v$  を式(2.2)、(2.3)によって更新する。式(2.3)における $\omega$ は慣性定数である。 $c_1, c_2$ は、それぞれ $\hat{x}, \hat{x}_g$ に向かう速度の調整を表し、 $r_1, r_2$ は、 $0 \sim 1$ の範囲

## 2.6 Particle Swarm Optimization(PSO)

の乱数である。図 2.2 は粒子の位置  $x$  と速度  $v$  が更新される様子である。

本研究では、SVM のハイパーパラメータである  $c$  と  $\gamma$  を PSO 定めることで、従来の Grid サーチよりも短い時間での識別精度の確保を目指す。

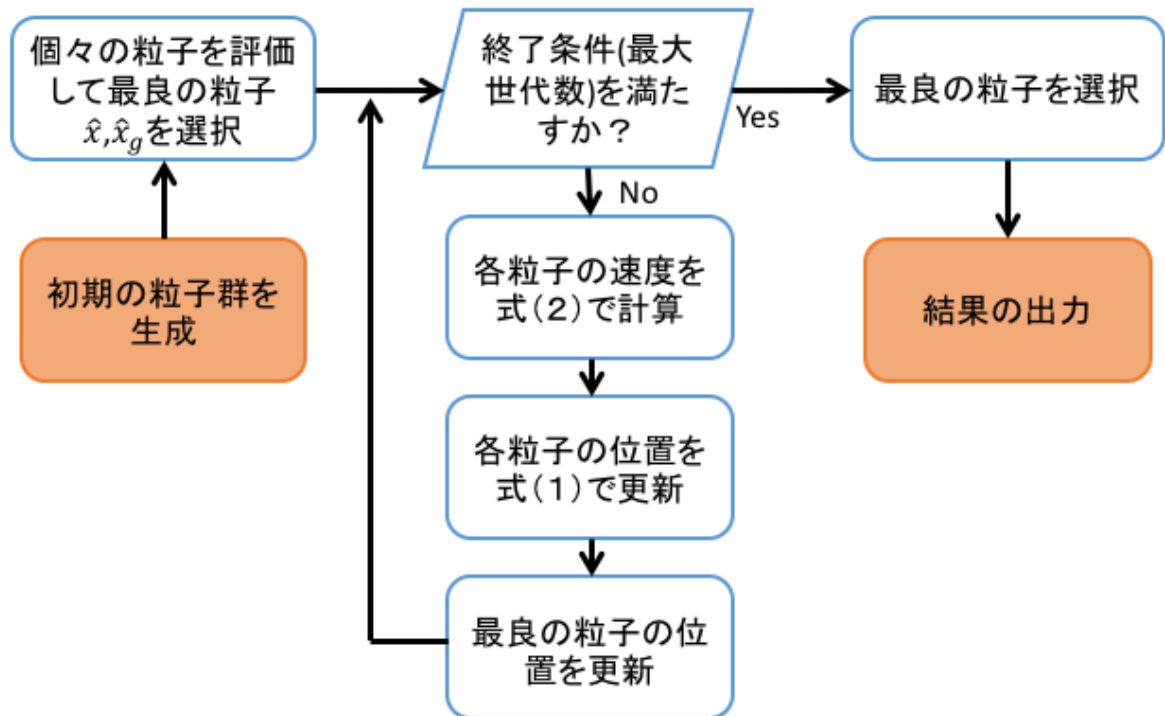


図 2.1 PSO の処理の流れ

## 2.6 Particle Swarm Optimization(PSO)




図 2.2 粒子の位置  $x$  と、速度  $v$  更新の様子

# 第 3 章

## 実験

### 3.1 表情画像提示実験

#### 3.1.1 実験概要

本研究では、前原が文献 [1] での顔表情認識の研究で用いた、人の喜び、怒りの表情画像を被験者に見せた際の脳活動データを用いる。表情画像には、高知工科大学情報学群の学生の喜び表情と怒りの表情の 2 種類の顔画像を用いる。2 種類の画像を被験者に提示し、fMRI を用い撮像する。被験者は提示されている画像が喜びであるか怒りであるかを、判定ボタンを押し、判定する。

被験者は、心身ともに健康である 21 歳と 22 歳の男性 5 名、女性 3 名の計 8 名であり、高知工科大学の脳コミュニケーションセンターにある MRI 装置 (3T) で撮像されたものである。

#### 3.1.2 実験デザイン

被験者に提示する実験デザインを図 3.1 に示す。まず、はじめに脳の安定化を図るため、レスト画像を 5 スキャン提示している。その後刺激画像を 5 スキャン提示している。刺激画像間には、BOLD 信号を下げるために、レスト画像を 3 スキャン提示している。刺激画像は被験者一人に対して、喜びの表情画像 32 枚、怒りの表情画像 32 枚の合計 64 枚をランダムに提示している。被験者は見ている表情を判定ボタンでリアルタイムで答える。ボタンは、刺激画像提示後に表示されるレスト画像が提示されている際に押す。また、ボタンは喜

## 3.2 脳活動データ解析

び、怒り、判定不能の3種類である。

以上を1ランとし、これを8ラン繰り返し行う。1ランにつき72枚の脳活動データを撮像し、合計576枚の脳活動データを撮像する。

## 3.2 脳活動データ解析

表情画像提示実験で得た脳活動データから、脳の賦活ボクセルを特定するため、SPM12を用いて解析を行う。SPM(Statistical Parametric Mapping)は、主に機能的画像データに関する仮説をテストするために用いられる[9]。本実験では、脳活動データを解析するための前処理と、個人解析に用いる。

### 3.2.1 画像変換

MRI装置で得られる脳活動データはDICOM形式で保存される。しかし、SPMで解析処理を行うためには、NifTi形式に変換する必要がある。そこで本実験では、MRIConvert[10]を用い、画像の変換を行う。

### 3.2.2 前処理

脳活動データは解析するために前処理を施す必要がある。本実験ではSPM12を用いる。前処理には、Realignment, Normalisation, Smoothingの3段階がある。

fMRIの実験はたとえ短い時間であっても、体動や心拍などによって被験者の頭も動いてしまうことが多い、また、本実験のようにボタンを押すような運動を伴う場合もある。




図 3.1 前原の実験デザイン [1]



### 3.3 評価実験

Realignment では、2 枚目以降の脳活動データを、1 枚目の脳活動データに合わせることで、頭部の動きに伴う脳活動データの変動を補正する。

Normalisation では、Realignment で処理した脳活動データを MNI(Montreal Neurological Institute) 標準脳に合わせる。

Smoothing では、これまでの前処理によって生じたノイズを取り除く。

#### 3.2.3 個人解析

個人解析では、表情画像定時実験で得た脳活動データから、脳の賦活ボクセルを特定する。特定には SPM12 を用いる。個人解析の手順は以下の通りに行う [4]。

1. デザインマトリクスを作成し、前処理が完了した脳活動データを一般線形モデル (General Linear Model:GLM) に組み込む。
2. GLM の説明変数の偏回帰係数を計算する。
3. 比較したい条件間のコントラストを作成し、その検定結果を表示する。

本実験では、喜びの表情画像提示時に対する、怒りの表情画像提示時に有意な差と、怒りの表情画像提示時に対しての喜びの表情画像提示時に有意な差の、2 種類をコントラストとして作成する。また、コントラストを立てる際の有意水準は  $p < 0.001$  とする。なお、有意水準  $p < 0.001$  にて賦活ボクセルが特定できなかった場合には、 $p < 0.01$  とする。

### 3.3 評価実験

#### 3.3.1 賦活ボクセルの時系列データ抽出

個人解析で得た脳の賦活ボクセルを用いて、機械学習を行う。個人解析を行うと、図 3.2 のように賦活ボクセル一覧が得られる。賦活ボクセルそれぞれの時系列データを取り出し、このデータを学習データとし、機械学習する。

### 3.3 評価実験

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-corr</sub>	<i>q</i> <sub>FDR-corr</sub>	<i>k</i> <sub>E</sub>	<i>p</i> <sub>uncorr</sub>	<i>p</i> <sub>FWE-corr</sub>	<i>q</i> <sub>FDR-corr</sub>	<i>T</i>	( <i>Z</i> <sub>≡</sub> )	<i>p</i> <sub>uncorr</sub>	mm	mm	mm
0.000	104	0.443	0.396	325	0.009	0.124	0.338	4.59	4.54	0.000	64	24	-2
						0.861	0.996	3.84	3.81	0.000	66	20	10
						1.000	0.996	3.19	3.18	0.001	58	16	16
		0.054	0.085	593	0.001	0.620	0.846	4.05	4.02	0.000	66	-42	-12
						0.979	0.996	3.62	3.60	0.000	66	-52	0
						1.000	0.996	3.18	3.16	0.001	50	-36	-20
		0.997	0.812	122	0.084	0.977	0.996	3.63	3.60	0.000	42	-78	22
		1.000	0.904	59	0.217	0.994	0.996	3.53	3.50	0.000	64	-12	-4
		1.000	0.904	31	0.370	0.996	0.996	3.50	3.48	0.000	6	-38	10
		1.000	0.904	71	0.178	0.996	0.996	3.49	3.47	0.000	50	38	-20
						1.000	0.996	2.52	2.51	0.006	38	44	-20
		0.911	0.737	191	0.035	0.998	0.996	3.45	3.43	0.000	-6	-14	10
						1.000	0.996	2.65	2.64	0.004	8	-16	10
						1.000	0.996	2.56	2.56	0.005	-14	-8	14
		1.000	0.904	51	0.250	0.998	0.996	3.45	3.43	0.000	-50	32	-10
		0.948	0.751	174	0.043	0.999	0.996	3.44	3.42	0.000	56	-46	56
						1.000	0.996	2.66	2.65	0.004	40	-48	68
		1.000	0.904	75	0.167	1.000	0.996	3.30	3.29	0.001	16	30	-20
		0.998	0.812	114	0.094	1.000	0.996	3.24	3.22	0.001	22	-14	-14
		1.000	0.904	72	0.175	1.000	0.996	3.23	3.22	0.001	-26	-18	-10

図 3.2 賦活ボクセル一覧

#### 3.3.2 PSO を用いた機械学習

機械学習には SVM(Support Vector Machine) の RBF カーネルを用いる。RBF カーネルにはコストパラメータ  $c$  と、RBF カーネル固有の  $\gamma$  の 2 種類のハイパーパラメータを定める必要がある。 $c$  は、誤分類をどの程度許容するかを決めるパラメータで、値を小さくすると、誤分類を許容するようになり、大きくすると、誤分類を許容しなくなる。

本実験では、このハイパーパラメータを PSO(Perticle Swarm Optimization) で定める。PSO は粒子数  $n_p$  と、最大世代数  $n_g$ 、慣性定数  $\omega$ 、加速度定数  $c_1, c_2$  を事前に決めておく必要がある。本実験では、粒子数と最大世代数をそれぞれ 10 個の場合と 100 個の場合を組み合わせ合わせた 4 パターンで機械学習を行い、識別率を算出する。いずれのパターンの場合も、慣性定数  $\omega = 0.5$ 、加速度定数  $c_1 = 0.5, c_2 = 0.5$  とする。コストパラメータ  $c$  と、RBF カーネル固有の  $\gamma$  の探索の範囲はそれぞれ、 $1 \sim 1000, 10^{-12} \sim 1$  とする。

また、比較対象として、Grid サーチを用いてハイパーパラメータを定め、機械学習を行う。Grid サーチは、指定した範囲を総当りで探索するアルゴリズムで、機械学習のハイパーパラメータを定める際に、広く使われている。こちらは PSO と同じ範囲内を、random 関

### 3.3 評価実験

数を用いてランダムで生成した値で探索する。本実験では、PSO と機械学習を繰り返す回数を同じにするために、探索する  $C$  の個数と、 $\gamma$  の個数をそれぞれ 10 個と 100 個の 2 パターンを組み合わせた 4 パターンで算出する。

# 第 4 章

## 結果

表情画像を提示した際の被験者の脳活動を解析，機械学習した際の識別率をそれぞれ表 4.1 ～ 表 4.8 に示す.

### 4.1 被験者 A の識別率

被験者 A の脳活動データを解析し，機械学習した結果を表 4.1 に示す. 表から，PSO を用いた全ての場合において，0.479 と最も高い識別率を得ることが分かる. また，Gridサーチを用いた場合において， $n_c$  を 100,  $n_\gamma$  を 10 にした場合と， $n_c$  を 100,  $n_\gamma$  を 100 にした場合で，0.479 と PSO と同様の識別率を得ることが分かる.

Gridサーチを用いた場合においても，PSO の場合と同じ識別率を得ているが，Gridサーチは 1000 回の機械学習を繰り返す必要があるのに対して，PSO の場合では，最大で 100 回の機械学習で同様の結果が得られている.

## 4.2 被験者 B の識別率

表 4.1 被験者 A の PSO と Grid サーチの識別率

	$n_p, n_g$	C	$\gamma$	識別率	計算時間 (s)
Grid サーチ	10, 10	455	0.574	0.477	37.3
	10, 100	46.3	0.69	0.476	420
	100, 10	321	0.589	<b>0.479</b>	373
	100, 100	980	0.589	<b>0.479</b>	4150
	$n_c, n_\gamma$				
PSO	10, 10	165	0.679	<b>0.479</b>	27.1
	10, 100	271	0.676	<b>0.479</b>	274
	100, 10	651	0.599	<b>0.479</b>	294
	100, 100	943	0.591	<b>0.479</b>	2755

$n_p$  : 粒子数,  $n_g$  : 世代数

$n_c$  : C のグリッド数,  $n_\gamma$  :  $\gamma$  のグリッド数

## 4.2 被験者 B の識別率

被験者 B の脳活動データを解析し、機械学習した結果を表 4.2 に示す。表から、PSO を用いた場合において、 $n_p$  を 100,  $n_g$  を 100 にした場合に、0.479 と最も高い識別率を得ることが分かる。また、Grid サーチを用いた場合において、 $n_c$  を 100,  $n_\gamma$  を 10 にした場合に、0.479 と PSO と同様の識別率を得ることが分かる。

Grid サーチを用いた場合では、373 秒で計算が終わるのに対して、PSO を用いた場合では 2755 秒と多くの時間がかかった。識別率が 0.444 となっているものは、 $\gamma$  の値が全て 0.0001 となっている。このことから、局所解に陥っていると考えられる。

### 4.3 被験者 C の識別率

表 4.2 被験者 B の PSO と Grid サーチの識別率

	$n_p, n_g$	C	$\gamma$	識別率	計算時間 (s)
Grid サーチ	10, 10	950	0.281	0.417	152
	10, 100	46.3	0.689	0.476	420
	100, 10	321	0.589	<b>0.479</b>	373
	100, 100	80.5	0.0001	0.444	11074
	$n_c, n_\gamma$				
PSO	10, 10	708	0.0001	0.444	141
	10, 100	451	0.0001	0.444	517
	100, 10	425	0.0001	0.444	1239
	100, 100	943	0.590	<b>0.479</b>	2755

$n_p$  : 粒子数,  $n_g$  : 世代数

$n_c$  : C のグリッド数,  $n_\gamma$  :  $\gamma$  のグリッド数

### 4.3 被験者 C の識別率

被験者 C の脳活動データを解析し、機械学習した結果を表 4.3 に示す。表から、PSO を用いた場合において、 $n_p$  を 100,  $n_g$  を 100 にした場合に、0.455 と最も高い識別率を得ることが分かる。また、Grid サーチを用いた場合において、 $n_c$  を 100,  $n_\gamma$  を 100 にした場合に、0.455 と PSO と同様の識別率を得ることが分かる。

Grid サーチを用いた場合においても、PSO の場合と同じ識別率を得ているが、Grid サーチは計算に 15617 秒必要であるのに対して、PSO の場合では、8257 秒で同様の結果が得られている。

#### 4.4 被験者 D の識別率

表 4.3 被験者 C の PSO と Grid サーチの識別率

	$n_p, n_g$	C	$\gamma$	識別率	計算時間 (s)
Grid サーチ	10, 10	45.1	0.141	0.438	166
	10, 100	588	0.012	0.448	1585
	100, 10	863	0.025	0.448	1530
	100, 100	782	0.028	<b>0.455</b>	15617
	$n_c, n_\gamma$				
PSO	10, 10	396	0.034	0.451	92.1
	10, 100	1	0.290	0.446	260
	100, 10	308	0.044	0.451	741
	100, 100	710	0.029	<b>0.455</b>	8257

$n_p$  : 粒子数,  $n_g$  : 世代数

$n_c$  : C のグリッド数,  $n_\gamma$  :  $\gamma$  のグリッド数

#### 4.4 被験者 D の識別率

被験者 D の脳活動データを解析し、機械学習した結果を表 4.4 に示す。表から、PSO を用いた全ての場合において、0.444 と最も高い識別率を得ることが分かる。

#### 4.5 被験者 E の識別率

表 4.4 被験者 D の PSO と Grid サーチの識別率

	$n_p, n_g$	C	$\gamma$	識別率	計算時間 (s)
Grid サーチ	10, 10	822	0.778	0.425	61.4
	10, 100	920	0.981	0.424	482
	100, 10	188	0.790	0.425	488
	100, 100	9.34	0.010	0.435	5318
	$n_c, n_\gamma$				
PSO	10, 10	1	0.0001	<b>0.444</b>	36.2
	10, 100	217	0.0001	<b>0.444</b>	409
	100, 10	51.8	0.0001	<b>0.444</b>	386
	100, 100	205	0.0001	<b>0.444</b>	4048

$n_p$  : 粒子数,  $n_g$  : 世代数

$n_c$  : C のグリッド数,  $n_\gamma$  :  $\gamma$  のグリッド数

#### 4.5 被験者 E の識別率

被験者 E の脳活動データを解析し、機械学習した結果を表 4.5 に示す。表から、PSO を用いた場合において、 $n_p$  を 10,  $n_g$  を 100 にした場合と、 $n_p$  を 100,  $n_g$  を 100 にした場合に、0.543 と最も高い識別率を得ることが分かる。また、Grid サーチを用いた場合において、 $n_c$  を 100,  $n_\gamma$  を 100 にした場合に、0.543 と PSO と同様の識別率を得ることが分かる。

Grid サーチを用いた場合においても、PSO の場合と同じ識別率を得ているが、Grid サーチは計算に 3207 秒必要があるのに対して、PSO の場合では、47.8 秒で同様の結果が得られている。



## 4.6 被験者 F の識別率

表 4.5 被験者 E の PSO と Grid サーチの識別率

	$n_p, n_g$	C	$\gamma$	識別率	計算時間 (s)
Grid サーチ	10, 10	482	0.337	0.488	29.8
	10, 100	348	0.337	0.473	288
	100, 10	635	0.005	0.482	322
	100, 100	995	0.003	<b>0.543</b>	3207
	$n_c, n_\gamma$				
PSO	10, 10	563	0.001	0.536	35.2
	10, 100	1	0.356	<b>0.543</b>	47.8
	100, 10	425	0.001	0.492	33.6
	100, 100	350	0.001	<b>0.543</b>	4829

$n_p$  : 粒子数,  $n_g$  : 世代数

$n_c$  : C のグリッド数,  $n_\gamma$  :  $\gamma$  のグリッド数

## 4.6 被験者 F の識別率

被験者 F の脳活動データを解析し、機械学習した結果を表 4.6 に示す。表から、PSO を用いた場合において、 $n_p$  を 100,  $n_g$  を 100 にした場合に、0.446 と最も高い識別率を得ることが分かる。

#### 4.7 被験者 G の識別率

表 4.6 被験者 F の PSO と Grid サーチの識別率

	$n_p, n_g$	C	$\gamma$	識別率	計算時間 (s)
Grid サーチ	10, 10	11.9	0.056	0.439	122
	10, 100	26.1	0.063	0.430	430
	100, 10	466	0.0002	0.444	1443
	100, 100	29.3	0.007	0.444	12350
	$n_c, n_\gamma$				
PSO	10, 10	1	0.0001	0.444	60.0
	10, 100	55	0.0001	0.444	392
	100, 10	795	0.0001	0.444	1280
	100, 100	1	0.279	<b>0.446</b>	5860

$n_p$  : 粒子数,  $n_g$  : 世代数

$n_c$  : C のグリッド数,  $n_\gamma$  :  $\gamma$  のグリッド数

#### 4.7 被験者 G の識別率

被験者 G の脳活動データを解析し、機械学習した結果を表 4.7 に示す。表から、PSO を用いた全ての場合において、0.444 と最も高い識別率を得ることが分かる。また、Grid サーチを用いた場合において、 $n_c$  を 100,  $n_\gamma$  を 10 にした場合に、0.444 と PSO と同様の識別率を得ることが分かる。

Grid サーチを用いた場合においても、PSO の場合と同じ識別率を得ているが、Grid サーチは計算に 967 秒必要があるのに対して、PSO の場合では、90.0 秒で同様の結果が得られている。

## 4.8 被験者 H の識別率

表 4.7 被験者 G の PSO と Grid サーチの識別率

	$n_p, n_g$	C	$\gamma$	識別率	計算時間 (s)
Grid サーチ	10, 10	48.5	0.123	0.392	131
	10, 100	10.8	0.077	0.429	1008
	100, 10	174	0.003	<b>0.444</b>	967
	100, 100	31.0	0.009	0.443	10152
	$n_c, n_\gamma$				
PSO	10, 10	1	0.215	<b>0.444</b>	90.0
	10, 100	1	0.0001	<b>0.444</b>	231
	100, 10	162	0.001	<b>0.444</b>	530
	100, 100	1	0.208	<b>0.444</b>	3753

$n_p$  : 粒子数,  $n_g$  : 世代数

$n_c$  : C のグリッド数,  $n_\gamma$  :  $\gamma$  のグリッド数

## 4.8 被験者 H の識別率

被験者 H の脳活動データを解析し、機械学習した結果を表 4.8 に示す。表から、PSO を用いた場合において、 $n_p$  を 100,  $n_g$  を 100 にした場合に、0.510 と最も高い識別率を得ることが分かる。

#### 4.8 被験者 H の識別率

表 4.8 被験者 H の PSO と Grid サーチの識別率

	$n_p, n_g$	C	$\gamma$	識別率	計算時間 (s)
Grid サーチ	10, 10	116	0.111	0.439	88.6
	10, 100	8.45	0.067	0.498	727
	100, 10	463	0.003	0.491	975
	100, 100	24.9	0.013	0.500	10024
	$n_c, n_\gamma$				
PSO	10, 10	530	0.0001	0.487	66.8
	10, 100	1	0.945	0.479	25.9
	100, 10	1	0.114	0.505	529.4
	100, 100	1.577	0.089	<b>0.510</b>	2421

$n_p$  : 粒子数,  $n_g$  : 世代数

$n_c$  : C のグリッド数,  $n_\gamma$  :  $\gamma$  のグリッド数

## 第 5 章

# 考察

結果より、Grid サーチを用いてハイパーパラメータを定めた場合よりも、PSO を用いてハイパーパラメータを定めた方が全体的に短い時間で高い識別率を算出できることが示唆される。最も高い識別率を示した被験者 E に注目すると、Grid サーチを用いた場合において、 $n_c$  を 100,  $n_\gamma$  を 100 にした場合に、0.543 となっている。それに対して、PSO を用いた場合において、 $n_p$  を 100,  $n_g$  を 100 にした場合に、0.543 と同様の識別率を示している。これら 2 つを比較すると、Grid サーチの場合では 3207 秒、PSO の場合では 4829 秒と、Grid サーチの方が短い時間で計算されている。これは、学習回数が同じ場合には、PSO の式を更新する時間分、Grid サーチの方が短い時間となっていることが考えられる。このことから、PSO でハイパーパラメータを探索する場合は、Grid サーチを用いる場合よりも少ない学習回数で終わるようにする必要があると言える。本実験では、粒子数と最大世代数をそれぞれ 10 個の場合と 100 個の場合を組み合わせた 4 パターンでのみ検証したが、それぞれ 50 個の場合など、学習回数をさらに少なくし、その場合でも同様の識別率が算出できるかを検証する必要がある。

また、 $n_p$  を 10,  $n_g$  を 100 にした場合で 47.8 秒と極端に短い時間で高い識別率が算出されている。これは粒子の数が少ないと、それぞれの粒子が別の粒子に影響を受けやすくなり、結果的に早い段階で同じ場所に収束してしまうのが原因だと考えられる。つまり局所解に陥っている可能性が考えられる。これを回避するために、PSO 自体のハイパーパラメータである、慣性定数  $\omega$ , 加速度定数  $c_1, c_2$  の調整が必要である。これには Grid サーチが適していると考えられる。Grid サーチはある程度探索範囲が決まっている場合に有効で、PSO 自体のハイパーパラメータはそれぞれ、0~1 の間と範囲が狭く、細かい値の変化はあまり

反映されないためである。

次に、被験者 E 以外の被験者に注目すると、被験者 H 以外は識別率が 50 を切るとあまり良い結果は出なかった。被験者 E は個人解析で 20 程度の賦活ボクセルを取得できたのに対して、他の被験者は 5 個から 10 個程度とあまり取得できず、学習データが不足したことが考えられる。そのことから、今後の課題として、特徴抽出方法の検討が必要であると言える。例えば、位相幾何学を利用し、データの分布に着目するトポロジカルデータ分析を用いれば識別率が向上する可能性が考えられる。

## 第 6 章

### 結論

脳情報デコーディングで機械学習を行う際のハイパーパラメータの決定は、多くの場合、指定した範囲を総当りで探索する、Grid サーチで行うが、広範囲でハイパーパラメータを探索する際に、膨大な計算時間を要する場合がある。そこで本研究では、進化計算法の一種である、粒子群最適化を用いてハイパーパラメータを定めることで、グリッドサーチを用いた場合よりも短時間での識別精度の確保を実現している。

また、被験者 8 人分の脳活動データを解析、機械学習を行う際のハイパーパラメータを、Grid サーチで算出した場合と PSO で算出した場合を比較すると、ほぼ全ての場合で PSOの方が短い時間で高い識別率を得ることができた。しかし、そもそもの識別率が低くなる被験者も多く、課題として残っている。

今後の課題としては、過学習を回避するための PSO 自体のハイパーパラメータの探索法の検討や、脳活動データ解析時の特徴抽出方法の検討、SVM 以外の機械学習アルゴリズムへの適応が挙げられる。

# 謝辞

本研究を進めるにあたり、ご指導していただきました吉田真一先生には心から感謝いたします。吉田先生には2年間本当にお世話になりました。学部4年生という立場ながら、国際学会へ2度も参加できたことは、今後の研究において大きな経験になると確信しています。また、同時に多大なご迷惑をおかけしました。初めての海外発表の際の、発表資料のレビューは生涯忘れることのない苦い経験となりました。しかし、そのおかげで、学士学位論文発表では大きなミスもなく、私自身としてはよい発表ができたと感じています。本当にありがとうございました。深く感謝致します。

そして、本研究の副査を引き受けていただいた岩田誠先生と、門田宏先生に深く感謝致します。岩田先生には、梗概を見てもらう際に、研究をしていると気づかない、根本的な指摘をしていただき、非常に参考になりました。門田先生は忙しい中にもかかわらず、多くの時間を割いて梗概の添削をしていただけました。おかげでよりよい梗概を執筆することができました。本当にありがとうございました。

同研究室の皆様にも本当にお世話になりました。同期の4年生とは配属を機に仲良くなりました。配属された当初はまさかここまで仲良くなるとは思っておらず、少し驚いていますが、これも全て皆様の人柄のおかげだと確信しております。皆様のおかげで、研究が嫌になった時でも、研究室へ来ようと思えました。領内あゆみ氏には、研究や私生活等様々な面でアドバイスをいただきました。共に受験を乗り切ったのは大きな思い出の一つです。笹谷健文氏には、言葉では言い表せられない程助けていただきました。また、私以外で唯一の男性として非常に大きな存在でした。首藤舞氏には、全力で研究に向かう姿勢にいつも励まされてきました。しかし、来年からは無理はしすぎないようにしてください。私の姿勢と足して2で割れば丁度いいのではと思います。鈴木夏美氏には、研究が本格化した1月から毎日学校への送り迎えをしていただきました。朝の弱い私にとって、早起きは辛いものでしたが、鈴木氏のおかげで毎日学校へ朝から通うことができました。中山梨奈氏とは、共に夜遅



## 謝辞

くまで研究室にこもって研究を進めていました。その間の息抜きとしての会話は非常に楽しかったです。

2, 3年生の皆様には主に研究室活動でお世話になりました。今年は就職活動に卒業研究と忙しくなるとは思いますが、皆様なら乗り越えられます。共に過ごす時間は大切に、楽しみましょう。

最後に、大学生活4年間を支えてくださった家族、友人に深く感謝致します。皆様のおかげで非常によい4年間だったと思います。進学してからもよろしくお願ひします。

# 参考文献

- [1] 前原春菜, “fMRIによる脳情報デコーディングを用いた人の表情理解の推定”, 平成27年度学士学位論文, 2016.
- [2] 高橋宏和, “fMRIによる脳情報デコーディングを用いた快・不快画像の識別”, 平成26年度学士学位論文, 2015.
- [3] 山本朋依, “fMRIによる脳情報デコーディングを用いた顔画像の識別”, 平成26年度学士学位論文, 2015.
- [4] 菊池吉晃, 妹尾淳史, 安保雅博, 渡邊修, 米本恭三, “SPM8 脳画像解析マニュアル fMRI, 拡散テンソルへの応用”, 医歯薬出版株式会社, p10-12, p64-111, 2012.
- [5] 小池規枝, “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.
- [6] 「脳を活かす」研究会, “ブレインデコーディング”, オーム社, 2007.
- [7] 平井有三, “はじめてのパターン認識”, 森北出版株式会社, 2012.
- [8] アジス・アブラハム, クリナ・グローサン, ヴィトリノー・ラモス, “群知能とデータマイニング”, 東京電気大学出版局, 2012.
- [9] SPM Statistical Parametric Mapping, <http://www.fil.ion.ucl.ac.uk/spm/>, 2017.
- [10] MRIConvert, yanifty DICOM file converter, <http://lcn.uoregon.edu/downloads/mriconvert>, 2016.