

# 脳波利用の音楽推薦システムに向けた 前額部導出電位を利用した心理状態分類の基礎検討 (2014年12月08日版)

鄭 昇吏<sup>1,a)</sup> 山西 良典<sup>1</sup> 坪 泰宏<sup>1</sup> 佐久間 春夫<sup>1</sup> 川越 恭二<sup>1</sup>

**概要：**身体に様々な影響を与えると言われている音楽の持つ効果により、音楽はメンタルトレーニングや心理療法等、様々な分野で応用されている。しかし、音楽が身体に与える影響は、感性の違いや周囲の状況によって大きく変化する。一方、既に様々な音楽推薦システムが存在するものの、その音楽推薦精度は高いとは言い難い状況にある。そこで、脳波により検出した心理状態を入力とし、聴取したい音楽を推薦するシステムの実現を目指す。脳波の活用により音楽推薦精度を向上させることができると期待できる。しかし、音楽と脳波の関係は十分に解明されている状況にはない。このため、人の心理状態を表すと言われる脳波による心理状態分類の可能性、およびその方法と精度を明らかにすることが重要である。そこで、本論文では、前額部導出電位データからの心理状態分類に関する実験結果について報告する。心理状態想起方法や、機械学習方法、使用する脳波データとその集約化方法等、様々な条件での心理状態分類精度を比較した。これらの実験の結果、心理状態分類を行うための分類精度が高い最適な分類手法を求めた。

## 1. はじめに

音楽は、人間の身体に様々な影響を与えると言われている[1]。音楽の身体に与える効果は、新陳代謝や発汗等に変化をもたらす生理的な効果と、注意の集中やストレスの変化といった心理的な効果の2種類の効果に分けられる[1]。後者の効果により、音楽を用いた心理療法（音楽療法）やメンタルトレーニングの様な、様々な分野で音楽が活用されている。例えば、スポーツにおけるメンタルトレーニングでは、競技前の心理状態制御に音楽を取り入れることで、選手の緊張緩和や、気分の高揚などを実現している[2]。

しかし、音楽療法やメンタルトレーニングを行う際に、音楽聴取者にとって最適な楽曲を自ら選択する事は困難である。これは、聴取者の感性や心理状態、周囲の状況によって、最適な楽曲が異なるからである。また、音楽聴取者が以前に選択した楽曲を毎回聴取するのは、新鮮味が薄れ音楽効果が低減するという問題が発生する[3]。したがって、被験者の心理状態に適した選曲を行うことは音楽の効果を維持するうえで重要となる。

これまで、多くの楽曲推薦システムが提案され実用化されている[4][5][6]。多くの楽曲推薦システムでは、リズム

やテンポなどの音楽的特徴を楽曲全体から抽出し、楽曲を客観的に分類してから推薦を行っている。利用者が選択した心理状態に応じた楽曲推薦システムも実用化されているが、利用者が自身の状態を指定しなければならず、利用者の心理状態は十分には考慮されていない[7]。

そこで、脳波から検出した音楽聴取者の心理状態に基づく音楽推薦システムは、音楽効果の向上および利用者の負担軽減のためには重要であると考えられる。すなわち、利用者が任意に想起した心理状態を脳波情報から読み取ることで、利用者の心理状態に適した楽曲を選択し、その楽曲を再生する方法である。これによって、メンタルトレーニングや音楽療法に適した効率的な選曲が可能となると考える。

また、本研究では実用性を考慮して、脳波の計測が容易な簡易脳波計測器を用いる。すなわち、本研究では、簡易脳波計測器を用いて、心理状態を考慮した音楽推薦システムの実現を目指す。しかし、脳波を用いた音楽推薦システムを実現するためには、簡易脳波計測器を用いて心理状態を識別することができるかという、心理状態識別可能性が大きな課題となる。したがって、本論文ではこの可能性を明らかにし、可能な手法についての検討を行う。なお、簡易脳波計測器により取得可能な電位には、脳波以外にも他の要因から生じる影響が混在していると考えられる。すなわち、本研究で使用する簡易脳波計測器から出力された電

<sup>1</sup> 立命館大学  
Ritsumeikan University  
a) is0077ev@ed.ritsumei.ac.jp

位は、脳波だけでなく前額部で取得できる全ての電位をまとめたデータとなる。そこで、本論文では以降、簡易脳波計測器で取得したデータを、前額部導出電位データと呼ぶ事とする。

## 2. 関連研究

脳波を用いた音楽に関する研究には、これまでにも様々な研究がある。代表的な研究には、山西らの脳波を用いて和音がリラックスに及ぼす影響を調べた研究 [8] や、山野らの楽曲聴取時の脳波から機械学習を用いて感性を推定した研究 [9] がある。これらの研究は、多チャンネルの脳波計測器を使用しており、音楽が人間の心理状態に与える影響を、脳波を用いる事によって調べている。本研究の目的は、脳波を用いて音楽が与える影響を調べる事ではなく、脳波を用いてメンタルトレーニングや音楽療法に適用する音楽推薦システムを実現するという工学的なものである。

また、心理状態の分類に関する研究として、SVM を用いて睡眠の質を脳波から識別する研究 [10] が存在する。この研究は、音楽療法による睡眠障害の治療を目的としている。このため、分類する心理状態はリラックスの度合い（睡眠の質）となっている。本研究では、リラックスのみならず集中も分類を行う。分類する心理状態の範囲が広がる事によって、より多くの物事に応用できると考えられる。

さらに、日高らは簡易脳波計測器「B3-Band」を用いた BMI の研究を行っている [11]。利用者の心理状態想起によって制御するシステムを提案している。この研究では、脳波データとして B3-Band に搭載されている、Attention・Meditation の値を使用して、集中とリラックスの 2 値分類を行っている。BMI として用いる心理状態分類ならば 2 値分類でも問題はない。しかし、本研究では心理状態を考慮した楽曲推薦を目標としている。このため、本研究では集中・リラックス・平常時の 3 値分類とし、より詳細な楽曲聴取者の心理状態識別を行う。

## 3. 前額部導出電位を用いた心理状態分類

### 3.1 簡易脳波計測器

本研究では、簡易脳波計測器を用いて脳波を読み取り、心理状態分類の実現を試みる。

脳波を読み取るには、通常、簡易脳波計測器ではなく多チャンネルの脳波計測器が用いられている [12]。しかし、多チャンネル装置は高価で大型である点、脳波読み取りセンサーの取り付けには分単位の時間が必要である。多チャンネル装置は、脳波を用いた心理の実験等には適しているものの、音楽療法やメンタルトレーニング等への応用には取扱いが容易でないため適していない。そこで、本研究では、容易に脳波の計測が可能な簡易脳波計測器を用いて、心理状態の分類を試みる。本研究で使用した簡易脳波計測

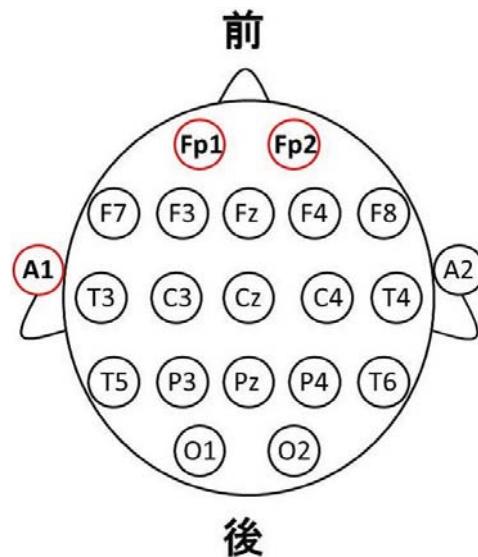


図 1 国際 10-20 法

器は、Neuro-Bridge 社の「B3-band」<sup>\*1</sup> である。

B3-band は、ヘッドバンド型の計測器であり、合計 3 個の電極がある。脳波測定における電極は、図 1 に示すような世界標準である国際 10-20 法 [13] を基に配置される。本研究で使用する B3-band の電極配置は、図 1 における「Fp1」「Fp2」「A1」に該当する。すなわち、耳朶（A1）を基準電極とし、左前頭極（Fp1）と右前頭極（Fp2）を探査電極として、脳波を計測する。

本研究では、この B3-Band より取得可能な RAW データを使用する。RAW データから FFT を用いて、周波数帯域毎にパワー値を 1 秒間に 10 データ算出し、その値を用いて心理状態の分類を行う。なお、RAW データのサンプリング周波数が 512Hz であるため、本研究ではウインドウ幅を 1 秒間、サンプリングポイント数を 512 個と設定し、統計ソフト R3.0.2<sup>\*2</sup> による FFT を行って、個々のパワー値を算出した。

### 3.2 前額部導出電位

本節では、脳波および心理状態分類で使用する、前額部導出電位について説明する。

脳波は、人間の脳から生じる 20-70  $\mu$ V の小さい活動電位である脳波を頭皮上の電極で測定を行うため、脳波以外の、何らかの生体現象による活動電位を同時に計測している可能性が高い。生体現象による活動電位の例には、骨格筋の収縮によって起こる活動電位（筋電図）や、心臓の拍動に伴う心筋の活動電位（心電図）等がある。このため、一般的に脳波計測では、脳波以外の活動電位の除去を行っている。本研究で使用する B3-Band に搭載されている TGAM (Think Gear ASIC Module) でも、取得した電位の除去が行われているものの、完全な除去は困難である。そこで本

<sup>\*1</sup> <http://neuro-bridge.com/dev/b3band.html>

<sup>\*2</sup> <http://cran.r-project.org/>

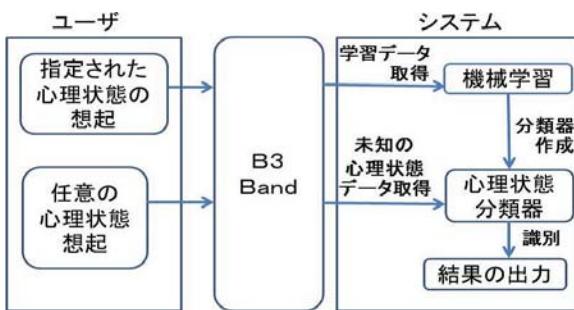


図 2 心理状態分類の流れ

研究では、活動電位が含まれる前額部から取得できる全ての電位を使用する。この前額部から取得した全ての電位をあわせた値を、前額部導出電位と定義する。また、脳波は、一般に周波数帯域によって名前がつけられている[14]。本研究でも、前額部導出電位を、脳波と同様に周波数帯域によって分割を行う。それらを、前額部導出電位周波数分割データと定義し、以下の8種類に区分する。

- $\delta$  : 0.5-2.75Hz
- $\theta$  : 3.5-6.75Hz
- L  $\alpha$ : 7.5-9.25Hz
- H  $\alpha$ : 10.0-11.75Hz
- L  $\beta$ : 13.0-16.75Hz
- H  $\beta$ : 18.0-29.75Hz
- L  $\gamma$ : 31.0-39.75Hz
- M  $\gamma$ : 41.0-49.75Hz

### 3.3 心理状態分類

前額部導出電位を用いた心理状態とその分類について述べる。

本研究は、最終的にメンタルトレーニングや音楽療法に適用する音楽推薦システムの実現を目指している。このため、心理状態をリラックス・集中・平常時の3種類とする。リラックスと集中は、Wundtが示す感情の3次元説[15]より、緊張-弛緩(集中-リラックス)の次元にあたる心理状態である。また、平常時はその2つのどちらでもない心理状態とする。本研究は、前額部導出電位データを入力とし、機械学習を用いて、これら3種類の心理状態を分類する。心理状態分類の全体の流れを図2に示す。

心理状態分類を機械学習で行うため、図2に示すように、心理状態分類方法は、分類器作成段階と心理状態分類段階の2段階から構成される。まず、分類器の作成段階では、被験者は指定された特定の心理状態を一定時間想起する。同時に、簡易脳波計測器が、心理状態想起時の前額部導出電位を取得する。取得したデータを、8種類の周波数分割データに区分し、これら8種の値をそれぞれ特徴ベクトルとする。その後、分類器作成のための学習データとして機械学習を行う。これにより心理状態分類の分類器の作成が完了する。次に、心理状態分類段階では、分類器の作成後、

利用者は任意の心理状態を想起する。その際の前額部導出電位を簡易脳波計測器より取得し、作成した分類器にこの取得したデータをテストデータとして当てはめ、心理状態を分類する。

## 4. 心理状態分類実験

### 4.1 概要

簡易脳波計測器を用いた心理状態分類のための実験を行う。3.3節で述べたように、本研究では機械学習を用いて心理状態分類を行う。どのような条件で心理状態の分類を行うと最も良い結果となるのかを、明らかにする事を目的として実験を行った。その結果を基に、最適な分類手法を求める事とする。

以下の2種類の実験を行った

- 実験1 心理状態想起方法の検証(ユーザ側)
- 実験2 心理状態分類方法の検証(システム側)

実験1では、機械学習に適した心理状態を安定して想起する手法を求める。実験2では、様々な手法での機械学習を適用し、精度の高い心理状態分類方法を求める。実験1は、3.3節で挙げた図2における、ユーザ側での実験であり、実験2は、システム側にあたる。この2つの実験の結果を基に、分類精度が最大となる分類手法を求める。実験1、実験2とともに、データの解析のためにR3.0.2のパッケージe1071, class, mvpartを使用した。

### 4.2 実験方法

被験者に各心理状態を想起してもらい、その際の前額部導出電位のデータを用いて心理状態の分類を行う。前額部導出電位の測定中は、心理状態想起と無関係な活動電位を生じさせない様に、被験者は楽な姿勢で椅子に座り、常に閉眼状態とする。被験者には、平常時、リラックス、集中の順で心理状態を想起してもらう。また、脳波には個人差が存在する[16]ため、分類器の作成は被験者毎に行う。そのため実験は、分類器の作成に用いる学習データ収集段階と、心理状態分類に用いるテストデータ収集段階の大きく2工程に分けられる。

被験者には一つの心理状態を、学習データ収集段階と心理状態識別段階で、それぞれ1回ずつ想起してもらう。各心理状態における脳波の測定時間は被験者の心理的負担を考慮して3分ずつと設定した。3分間のうち、2分間を分類器作成の学習データ収集に充て、残りの1分間を心理状態分類のテストデータ収集段階に充てるとする。測定中、被験者の心理的負担軽減のために、心理状態遷移時に10秒間のインターバルを挟む。さらに、各心理状態想起時のデータは、想起開始直後20秒は心理状態が安定していないと考え、データから除外する。

前額部導出電位の測定後、学習データから分類器を作成し、分類器にテストデータを当てはめる。被験者が想起し

た心理状態と、分類器が出力した心理状態を比較し、式(1)より分類精度を求める。

$$\text{分類精度} = \frac{\text{正解データ数}}{\text{全データ数}} \times 100(\%) \quad (1)$$

#### 4.3 実験1：心理状態想起方法の検証

実験1では、機械学習に適した心理状態を安定して想起する手法を求める。2種類の方法で心理状態を想起し、分類精度が最も高い手法を本研究で採用する。今回比較した想起方法は以下の2種類である。

(1) 任意のイメージによる想起（イメージ想起法）

(2) 特定の行動による想起（行動想起法）

イメージ想起法とは、該当する心理状態に対して、被験者が最も関係していると思う物事をイメージする事によって、心理状態を想起する方法である。行動想起法とは、リラックスは深呼吸と脱力、集中は暗算、平常時は特別な行動を行わない、といった行動によって、心理状態を想起する方法である。

実験に使用した機械学習は、先行研究[11]で使用されていたSVMである。機械学習に使用するデータは、全ての前額部導出電位周波数分割データを使用して、取得データから10秒間の平均を計算した前処理を施している。イメージ想起法での実験は被験者4人を対象に、行動想起法では被験者7人を対象に行った。

まず、イメージ想起法の分類結果を表1に示す。データ件数は、被験者1人につき、各心理状態31件ずつで、合計93件である。

表1 イメージ想起法

| 被験者    | 心理状態    |         |         |                |
|--------|---------|---------|---------|----------------|
|        | 平常時     | リラックス   | 集中      | 全体             |
| A      | 51.61 % | 0%      | 87.10 % | 46.24 %        |
| B      | 0%      | 32.26 % | 48.39 % | 26.88 %        |
| C      | 0%      | 6.45 %  | 100 %   | 35.48 %        |
| D      | 48.39 % | 48.39 % | 0%      | 32.26 %        |
| 平均分類精度 | 25.00 % | 21.78 % | 58.87 % | <b>35.22 %</b> |

表1より、イメージ想起法で分類した場合の全体平均分類精度は35.22%であった。また、作成した分類器は、分類する心理状態に大きな偏りが生じている。すなわち、表1の下線に示すように、ある特定の心理状態が分類精度が0%となり、2種類の心理状態しか分類されていない事が分かる。

次に、行動想起法での分類結果を表2に示す。

表2より、行動想起法での分類精度は47.16%であった。表1と比べて、行動想起法の方が分類精度が12.94%高く、心理状態の想起が安定している事が分かる。また、分類制度が0%となる心理状態も少なくなっている。

表2 行動想起法

| 被験者    | 心理状態   |        |        |                |
|--------|--------|--------|--------|----------------|
|        | 平常時    | リラックス  | 集中     | 全体             |
| E      | 35.48% | 48.39% | 77.42% | 53.76%         |
| F      | 96.77% | 100 %  | 38.71% | 78.49%         |
| G      | 61.29% | 41.94% | 54.84% | 52.69%         |
| H      | 77.42% | 16.13% | 54.84% | 49.46%         |
| I      | 38.71% | 38.71% | 54.84% | 44.09%         |
| J      | 0%     | 38.71% | 19.35% | 19.35%         |
| K      | 0%     | 0 %    | 96.77% | 32.26%         |
| 平均分類精度 | 44.24% | 40.55% | 56.68% | <b>47.16 %</b> |

#### 4.4 実験2：心理状態分類方法の検証

実験2では、様々な条件で機械学習を行い、最適な心理状態分類方法を求める。本研究では、機械学習に対して以下の3種類の視点から検証を行った。

- 視点a：機械学習方法
- 視点b：データ集約化方法
- 視点c：特徴ベクトル

視点aでは、7種類の機械学習方法を比較し、心理状態分類に最適な機械学習を求める。比較した方法は、SVM・決定木(CART)・K-NN[18]のあり。K-NNは、K=1,3,5,10,15の5種類を行った。

視点bでは、分類精度が最も高くなるデータ集約化方法を求める。B3-bandから取得した前額部導出電位のデータに対して、様々な集約化処理・分析対象区間を設定し、最も分類精度の高くなる前処理を求める。比較したデータ集約化方法は、以下の5種類である。

- (1) 取得データをそのまま使用(RAW)
- (2) 取得データから、5秒間の平均を計算(Ave5)
- (3) 取得データから、10秒間の平均を計算(Ave10)
- (4) 取得データから、5秒間の分散を計算(Var5)
- (5) 取得データから、10秒間の分散を計算(Var10)

視点cでは、機械学習の分類精度が最も高くなる特徴ベクトルの組合せを求める。周波数ごとに8種類に区分された前額部導出電位周波数分割データそれぞれを一つの特徴ベクトルと考える。組合せ数は255通りとなる。全ての組合せ255通りから最適な組合せを求める。

これら3種類の視点から、全ての組み合わせ8925(7×5×255)通りの条件で機械学習を行い、最も分類精度が高くなる手法を求める。この実験では、4.3節で高い分類精度を示した行動想起法を用いた。また、被験者7人を対象に実験を行った。

心理状態分類結果を表3に示す。全ての組合せで機械学習を行い、各組合せでの平均分類精度を求め、その値が高い上位20通りの組合せを表示している。データ件数は、RAWでは各心理状態40件、Ave5・Var5では各心理状態36件、Ave10・Var10では各心理状態31件となっている。

表3より、心理状態分類精度が最も高くなる組合せは、

表 3 心理状態分類精度上位 20 通り

| 順位 | 機械学習 | 集約化   | 特徴ベクトル  | 平均分類精度  | 標準偏差  |
|----|------|-------|---|---------|-------|
| 1  | 15NN | Ave10 | $\theta + L \alpha + L \beta + H \beta$                       | 53.57 % | 7.95  |
| 1  | 5NN  | Ave10 | $\theta + L \alpha + L \beta + H \beta$                       | 53.57 % | 10.91 |
| 1  | 決定木  | Ave10 | $\theta + L \alpha + M \gamma$                                | 53.57 % | 12.47 |
| 4  | 3NN  | Ave10 | $\theta + L \alpha + L \beta + H \beta$                       | 53.10 % | 10.82 |
| 5  | 10NN | Ave10 | $\theta + L \alpha + L \beta + H \beta$                       | 52.86 % | 8.76  |
| 6  | 15NN | Ave10 | $\theta + L \alpha + H \beta$                                 | 52.38 % | 8.68  |
| 6  | 5NN  | Ave10 | $\theta + L \alpha + H \beta$                                 | 52.38 % | 9.51  |
| 8  | 決定木  | Ave10 | $\delta + \theta + L \alpha + H \alpha + M \gamma$            | 52.26 % | 12.13 |
| 9  | 3NN  | Ave10 | $\theta + L \alpha + H \beta$                                 | 51.43 % | 9.19  |
| 10 | 15NN | Ave10 | $\theta + L \alpha + L \beta$                                 | 51.07 % | 6.91  |
| 10 | 10NN | Ave10 | $\theta + L \alpha + H \beta$                                 | 51.07 % | 9.22  |
| 12 | 10NN | Ave10 | $\delta + \theta + L \alpha + H \alpha + L \beta + L \gamma$  | 50.83 % | 7.98  |
| 12 | 10NN | Ave10 | $\delta + \theta + L \alpha + H \alpha + L \beta$             | 50.83 % | 9.17  |
| 12 | 決定木  | Ave10 | $\delta + \theta + L \alpha + H \alpha + L \gamma + M \gamma$ | 50.83 % | 9.87  |
| 12 | 決定木  | Ave10 | $\delta + \theta + L \alpha + H \alpha + H \beta + M \gamma$  | 50.83 % | 12.83 |
| 12 | 決定木  | Ave10 | $\delta + \theta + L \alpha + L \beta + M \gamma$             | 50.83 % | 13.18 |
| 17 | 15NN | Ave10 | $\theta + L \alpha + H \alpha$                                | 50.71 % | 7.78  |
| 17 | SVM  | Ave10 | $\theta + L \alpha + H \beta$                                 | 50.71 % | 8.11  |
| 17 | 決定木  | Ave10 | $\delta + \theta + L \alpha + M \gamma$                       | 50.71 % | 11.51 |
| 17 | 決定木  | Ave10 | $\theta + L \alpha + L \beta + M \gamma$                      | 50.71 % | 12.15 |

53.57% を示した決定木・Ave10・「 $\theta + L \alpha + M \gamma$ 」と 5NN・Ave10・「 $\theta + L \alpha + L \beta + H \beta$ 」と 15NN・Ave10・「 $\theta + L \alpha + L \beta + H \beta$ 」の 3 通りである。特に、3 通りの中でも、標準偏差が 7.95 と最も低かった、15NN・Ave10・「 $\theta + L \alpha + L \beta + H \beta$ 」の組合せが、心理状態分類に最適な組み合わせと言える。

また、視点 a に注目した場合、上位 20 通りの中で最も多く使用されている機械学習は、6 回使用されている決定木である。K-NN の場合は、15NN・10NN は 4 回、5NN・3NN は 2 回、1NN は 0 回使用されており、K の値が大きくなるにつれ分類精度が高くなる傾向がある。SVM は、上位 20 組の中で 1 回のみ使用されており、分類精度はあまり良くない。

さらに、視点 b に注目した場合、上位 20 通りの組合せは全て Ave10 の集約化処理を行っている。この結果より、心理状態分類に適した集約化処理は Ave10 である事が分かる。

視点 c に注目した場合、機械学習によって使用される特徴ベクトルに特徴的傾向が存在している事が分かる。K-NN の場合、「 $\theta \cdot L \alpha \cdot L \beta \cdot H \beta$ 」の周波数分割データを集約化した特徴ベクトルが、上位の組合せに頻出している。しかし、上位 20 通りの中で最も多く使用された機械学習である決定木では、K-NN とは対象に「 $\delta \cdot M \gamma$ 」のような特徴ベクトルが頻出している。

以上の事から、機会学習に決定木や 15-NN・10-NN を用いた場合に、心理状態分類精度が高くなる事が分かる。特に、決定木は上位 20 組中、比較した機械学習の中で最も多い 6 組存在しており、最も分類精度が高くなる機械学習である事がわかる。しかし、分類精度のばらつきである標

準偏差に注目すると、決定木は上位に存在する 6 組全てが 10 以上を示している。対して、15-NN・10-NN の標準偏差は平均が 8 程度であり、決定木に比べてばらつきが小さい事が分かる。

したがって、決定木は、分類精度は最も高くなるがばらつきが大きく、15-NN・10-NN の場合は分類精度は比較的高く、ばらつきも小さく全体的に安定していると言える。

## 5. 考察

実験では、心理状態分類に最適な手法を求めるために、2 種類の実験を行い、最後に最適な分類手法を求めた。その結果を以下にまとめる

① 4.3 節より、心理状態分類に適している心理状態想起方法は、行動想起法であることが得られた。

② 4.4 節より、まず心理状態分類に最適なデータ集約化方法は、全ての機械学習においても、Ave10 である事が得られた。

③ 特徴ベクトルの組合せは、機械学習毎に最適な組合せが異なる。K-NN では、「 $\theta \cdot L \alpha \cdot L \beta \cdot H \beta$ 」の特徴ベクトルが上位の組合せに頻出している。一般的に、周波数帯域の低い δ 波と高い γ 波は、睡眠状態や興奮状態を示す波長と言われており、リラックスや集中といった心理状態には関係ないと考えられる。今回の実験結果においても、K-NN の上位の組合せには δ・γ は含まれていないので、実験結果は妥当であると言える。しかし、決定木では、K-NN とは対象に δ や M γ といった特徴ベクトルが頻出している。

④ 最適な機械学習は、高い分類精度を示したのは決定木と 15-NN であり、機械学習毎に分類結果に特徴が存在している。決定木は分類精度が比較した機械学習の中で最も高くなるが、ばらつきが大きい。15-NN では、分類精度は比較的高く、ばらつきも全体的に小さく安定している。

以上の結果、実用性を考慮して簡易脳波計測器を用いている本研究では、安定した分類精度が期待できる 15-NN が最適な機械学習であるといえる。

分類結果を正解と不正解の 2 つと捉えるのではなく、不正解の場合の内容にも注目する事も、分類精度の向上には重要である。本研究では、リラックスと集中を心理状態の対極に存在するものとしている。すなわち、集中を平常時と分類する場合と、リラックスと分類する場合では、リラックスと分類する場合の方が大きな問題であるといえる。そこで、「 $\theta \cdot L \alpha \cdot L \beta \cdot H \beta$ 」の特徴ベクトルを用いて、15-NN・Ave10 により機械学習を行った場合の、被験者全員の出力結果をまとめた結果を表 4 に示す。

表 4 より、集中状態の分類精度が非常に高い事が分かる。さらに、分類器が集中状態を全体的に出力している中でも、被験者が平常状態を想起しているときに分類器はリラックスを多く出力しており、またリラックスを想起していると

表 4 分類結果詳細

| 想起心理状態 | 出力結果   |       |        |
|--------|--------|-------|--------|
|        | 平常時    | リラックス | 集中     |
| 平常時    | 23.93% | 38.9% | 37.14% |
| リラックス  | 23.21% | 41.4% | 35.36% |
| 集中     | 4.64%  | 12.1% | 83.21% |
| 全体     | 17.26% | 30.8% | 51.90% |

きに分類器は平常を比較的多く出力している。これらの事から、平常状態とリラックス状態の前額部導出電位は比較的類似しており、集中状態は他の心理状態とは差異が存在していると考えられる。

今回行った複数の実験により、心理状態分類精度は50%を超えた。しかし、音楽推薦システムへの応用には、機械学習による心理状態の更なる分類精度向上が必要である。この分類精度を向上させるためには、学習データの見直しが必要になると見える。機械学習で分類器を作成する際に必要となるデータが学習データであるが、本研究で行った実験では、この学習データが91~100件と少なかった。学習データのデータ量が少ない場合、学習データ収集時に少量のノイズが混入しただけで、大きく分類精度が低下する。この問題は、学習データのデータ量が増加することによって、軽減できると考えられる。しかし、学習データを増やすには、単純に心理状態想起時間を長くすれば良い訳ではない。心理状態想起時間を長くすると、被験者の心理的な負担が増加し、正確な心理状態のデータが取得できなくなる。このため、被験者の心理的な負担を考慮しながら、学習データをより多く取得する為の心理状態想起方法を考案する必要がある。

## 6. おわりに

本研究では、前額部導出電位を用いた心理状態分類手法について実験による検証を行った。集中・リラックス・平常時の3種類の心理状態を機械学習を用いて分類する手法を検討した。複数の条件で学習・分類を行う事によって、前額部導出電位を用いた際の最適な分類手法を求めた。実験の結果、行動想起法を用いた場合、「 $\theta \cdot L \alpha \cdot L \beta \cdot H \beta$ 」の特徴ベクトルを用いて、K-NN・Ave10により機械学習を行うと、高い分類精度を示すことが確認できた。今後は、効率の良い学習データ収集方法を提案し、機械学習の分類精度の向上を図る事が課題である。

謝辞 本研究の一部はJSPS科研費26540047の助成を受けたものです。

## 参考文献

- [1] 松井ら: 音楽刺激による生体反応に関する生理・心理学的研究, 臨床教育心理学研究, 2003.3, Vol.29, No.1
- [2] Costas Karageorghis et al : The Psychophysical effects of Music in Sport and Exercise : a review (Effets psychophysiques de la musique lors d'une activité physique ou sportive : revue), Journal of Sport Behavior Vol. 20 (1997)
- [3] Oliver Grewe et al: Listening To Music As A Re-Creative Process Physiological, Psychological, And Psychoacoustical Correlates Of Chills And Strong Emotions, Music Perception: An Interdisciplinary Journal, Vol. 24, No. 3, February 2007
- [4] 吉井和佳, 後藤真孝: 音楽推薦システム, 情報処理学会学誌, Vol. 50, No. 8, pp. 751-755, August 2009.
- [5] 小田川ら: 楽曲レコメンドシステム, PINOER R& D, Vol 17, No.1 ,2007
- [6] 吉井ら: ユーザの評価と音響的特徴との確率的統合に基づくハイブリッド型楽曲推薦システム, 情報処理学会研究報告, 音楽情報科学, 2006, 45-52
- [7] Ning-Han Liu: Comparison of content-based music recommendation using different distance estimation methods, Applied Intelligence, Volume 38, Issue 2, pp 160-174(2013)
- [8] R. Yamanishi et al: Effect on EEGs When Listening to Harmony, JACIII, vol.13, no.4, pp.366-372 (2009)
- [9] 山野ら: 脳波の解析に基づく音楽に関する感性推定器, The 26th Annual Conference of the Japanese Society for Artificial Intelligence(2012)
- [10] Wei Zhao, Xinxin Wang, Ye Wang: Automated sleep quality measurement using EEG signal: first step towards a domain specific music recommendation system, Proc. of ACM Multimedia, pp.1079-1082, (2010)
- [11] 日高ら: 脳波分析による意図および気分抽出に基づく制御システムの提案, DEIM Forum 2014 D9-3(2014)
- [12] 白澤厚: 医療機器のあゆみ 第五回 脳波計, 日本医用機器工業会, 医用機器 Vol.31, No.343 13-21p (2005)
- [13] 菅井 康祐: ERP(事象関連電位)データを読み解くための基礎知識, 外国語メディア学会 (LET) 関西支部めそろじー研究部会 2012 年度報告論集
- [14] 飛松省三: 脳波判読のポイント, 九州大学大学院医学研究院脳研臨床神経性理 (2006)
- [15] Wilhelm Max Wundt: Grundriss der Psychologie,XV Aufl., S.99-100
- [16] 谷口ら: 脳波にみられる個人差および恒常性, 駒沢社会学研究 22 (1990)
- [17] Corinna Cortes et al: Support-Vector Networks, Machine Learning, 20, 273-297(1995)
- [18] Xindong Wu et al: Top 10 algorithms in data mining, Knowl Inf Syst 14:1-37(2008)