

簡易脳波センサを用いた行動認識に関する研究

安部 弘通¹ 高野 茂² 馬場 謙介³ 村上 和彰⁴

概要: 本研究の最終的な目的は、高等教育における講義の受講者を観測し、観測したデータを用いて当該受講者の状態を推定することである。本研究では受講者の観測手段として、簡易脳波センサに着目した。簡易脳波センサによって受講者の状態をどの程度推定できるのかどうかは分からない。そこで、まずは一般的な人間の状態を対象とし、簡易脳波センサによって人間の状態がどの程度認識できるのかを調査した。具体的には、いくつかの種類の行動をとった時の人間の脳波データを、簡易脳波センサ MindTune によって測定し、測定したデータを解析することで行動の種類を判別することがどの程度可能であるかを調査した。

A Study of Human Action Recognition Using a Simple Electroencephalograph

HIROMICHI ABE¹ SHIGERU TAKANO² KENSUKE BABA³ KAZUAKI MURAKAMI⁴

Abstract: The final goal of this study is observing students attending lectures in higher education, and estimating their states using observation data. This study focused on simple electroencephalograph as means for observation. It is not clear how the simple electroencephalograph can estimate the states of students. Therefore, in the first place, we investigated how the simple electroencephalograph can recognize human states directed at states of general human beings. Specifically, we measured human brain wave data by a simple electroencephalograph MindTune when they take some kinds of actions, and investigated the accuracy of an activity recognition by analyzing measured data.

1. はじめに

大学における講義や、MOOC (Massive Open Online Course) と呼ばれるオンラインの講義において、講師は講義をよりよい内容にするため、1人1人の受講者の状態を知ろうとする。受講者の状態とは、受講者が講義に対し、どの程度理解しているか、集中しているか、満足しているかといったことである。講師は受講者の状態に応じて、できるだけ素早く（可能であれば講義中に）何らかのフィードバックをする。また、受講者によって状態は異なるので、1人1人の受講者に適したフィードバックを提示することが理想である。しかし、現在、講師が受講者1人1人の状態を素早く確実に量ることは困難である。例えば、受講者が講義の内容を理解しているかどうかを知るには、テストの成績を利用する、個別に試問を行うといった方法が一般的であるが、通常これらは講義の終了後に行うものであり、講義中に1人1人の受講者の理解度を量り、個人に適したフィードバックを行うということは容易ではない。そこで、受講者を何らかの手段でリアルタイムに観測し、観測データから受講者の状態を推定することを考える。これが可能となれば、講師は受講者の観測データを見るだけで、受講者の状態を容易に知ることができる。従って、講師は受講者1人1人に対して素早くフィードバックをすることができるようになる。また、受講者1人1人に対し詳細な観測を行うことで、個人に適したフィードバックを返すこともできる。本研究の目的は、以上のように、講義中

¹ 九州大学工学部電気情報工学科
Department of EECS, School of Engineering, Kyushu University
² 九州大学大学院システム情報科学研究院情報学部門
Department of Informatics, Faculty of ISEE, Kyushu University
³ 九州大学附属図書館
Kyushu University Library, Kyushu University
⁴ 九州大学大学院システム情報科学研究院情報知能工学部門
Department of Advanced Information Technology, Faculty of ISEE, Kyushu University

の受講者を観測することで、当該受講者の状態の推定を容易に行うことができるようにすることである。

本研究では、観測データからどのようにして受講者の状態を推定するのかということが最大の問題となる。そのため、観測データと受講者の状態との関係性を解析することが必要であり、関係性の最適な解析方法を調査しなければならない。

受講者を観測するセンサとしては、カメラ、マイク、スマートフォン、脳波センサ、心拍計といったものが考えられる。文献 [1] における既存研究では、映像データを取得するカメラをセンサとして利用し、受講者の講義中の振る舞いと、講義に対する理解度との関係性のある程度明らかにしているなどの成果を上げている。一方、実験の精度を今後の課題として挙げている。そこで、本研究では、センサとして脳波センサに着目する。その理由は、人間の外部から測定できる映像という情報だけでは分からなかったことが、人間の内部から測定できる脳波という情報も用いることで分かる可能性があり、実験の精度の向上が期待できるからである。

本研究では、脳波センサとして、東芝が開発・販売している MindTune という簡易的な物を使用する。簡易的な物を使用する理由は、講義中の受講者を観測することを想定している点にある。簡易的な脳波センサは、「安価である」、「簡単に測定できる」といったことが利点として挙げられる。講義は通常多くの人間が受講するものであるため、その多くの受講者 1 人 1 人の情報を個別に測定することを考えると、安価なセンサを使うということが理想である。また、測定を行うことがあまり簡単ではないセンサを使えば、受講者が講義を受けることに対する妨げになる恐れがある。以上のことを考慮し、安価で簡単な測定が可能な簡易脳波センサを用いる。ただし、簡易的な物で受講者の状態を推定するに足る性能が得られるとは限らない。そこで、本研究ではまず、簡易脳波センサで人間の簡単な状態を認識できるかどうか、また、どのようにすれば状態認識が可能であるかどうかを調査する。具体的には、簡単な状態として人間の行動を考える。そして、MindTune による人間の行動の認識の可否、方法を調査する。

本研究では、簡易脳波センサ MindTune がどの程度の性能を持つかを初めに確認することで、簡易脳波センサが講義の受講者の状態推定のための観測手段としてどの程度貢献できる物であるかどうかを検証する。人間の行動のある程度認識できるのであれば、映像を取得するカメラと合わせて、簡易脳波センサも受講者の状態推定のための観測手段として適したものである可能性があることが分かる。

本稿の構成は以下の通りである。まず、第 2 章で、状態推定に関する既存研究を紹介し、本研究の測定対象である脳波及び使用する簡易脳波センサ MindTune について説明する。次に、第 3 章で今回実施した実験の内容と実験から

得られたデータの解析方法を説明し、第 4 章でデータ解析の結果を述べる。最後に、第 5 章でまとめと今後の予定について述べる。

2. 事前知識

本章では、実験を行うに当たって必要な事前知識を説明する。まず、第 2.1 節で状態推定に関する既存研究を紹介する。次に、第 2.2 節で本研究の測定対象である脳波について簡単に説明し、第 2.3 節で本研究で使用する簡易脳波センサ「MindTune」について説明する。

2.1 既存研究

受講者の状態推定に関して、高等教育における講義の受講者の振る舞いを観察し、受講者の理解度を量ろうとする文献 [1] の研究がある。研究の目的は、受講者の様子をカメラで撮影して得られた映像データと、授業アンケートや小テストの結果によって、受講者の振る舞いと理解度との関係性を解析することである。[1] の研究では上記の関係性解析においてある程度の成果を上げている。

また、脳波を用いた人間の状態推定に関する既存研究としては、文献 [2] における研究がある。研究の目的は、脳波データに自己組織化マップ (self-organizing (feature) map : SOM) というクラスタリングアルゴリズムを適用することで、脳波データによる人間の精神状態の分類、推定を試みることである。文献 [2] では、結果として、測定した脳波に SOM を適用することで、精神状態の違いに由来する脳活動状態の違いを正しく分類したこと、また、与えられたデータがどのような精神状態で得られたものであるかを推定できる可能性が見出されたと述べている。

既存研究 [1] は、受講者を観測することで当該受講者の状態を推定できる可能性を示している。また、既存研究 [2] は、脳波を用いて人間の状態を推定できる可能性があることを示している。以上より、脳波の観測による受講者の状態推定という本研究の目的は、達成できる可能性があるものであると考えられる。

2.2 脳波について

脳波とは、人間の脳の電気活動を定量的に測定したものである [4]。その中でも、頭皮に電極を当てて測定する脳波を EEG (electroencephalography) と呼び [4]、本研究でも EEG を測定する。EEG の測定では 10-20 法に基づき、電極を当てる場所として図 1 に示すような頭皮の 20 箇所が決められている [4]。その 20 箇所の内の 1 箇所は基準電極と呼ばれ、片方の耳に置かれる [4]。一方、その他の 19 箇所の電極は探査電極と呼ばれる [4]。探査電極は 19 箇所全てに取り付ける必要はなく、通常は左右の前頭極部、側頭前部、側頭中部、中心部、頭頂部、後頭部が選ばれる [3]。脳波は、2 つの電極の間の電位変動を捉えることで測定す

電極の配置 (10-20 法)




図 1 10-20 法による電極の配置箇所 [7]




図 2 MindTune[8]

る仕組みとなっている [3]。特に、基準電極と探索電極の間で測定を行う方法を基準導出法といい [3]、本研究でもこの方法で脳波を測定する。また、脳波はサインウェーブの形で計測され、周波数帯域によって、アルファ波、ベータ波など、いくつかの種類に分類される [3]。

2.3 MindTune について

本研究では、東芝が開発・販売している「MindTune」という製品を脳波センサとして使用する。MindTune は、額（正確には図 1 における 1 に相当する左前頭極部）と左耳の部分にセンサが取り付けられた、図 2 に示すようなワイヤレスステレオヘッドホンとなっている。MindTune は、製品に同梱されている USB アダプタとの間の Bluetooth 通信によって、測定したデータをコンピュータに送信する。左耳を基準電極、左前頭極部を探索電極として用いており、この 2 箇所のみによって脳の電気活動を測定する。これは、14 箇所に電極を配置している文献 [2] における研究と比較すると、配置する電極の数が非常に少ないものとなっている。従って、MindTune が脳波センサとして簡易的なものであることが分かる。また、本製品で計測される脳の活動信号の測定値は個人差や環境条件によって影響されるため、あくまで目安であるとされている。

MindTune には、NeuroSky という企業が開発した

表 1 周波数帯域ごとに 8 分割された脳波

名称	周波数
delta	0.5～2.75Hz
theta	3.5～6.75Hz
low-alpha	7.5～9.25Hz
high-alpha	10～11.75Hz
low-beta	13～16.75Hz
high-beta	18～29.75Hz
low-gamma	31～39.75Hz
high-gamma	41～49.75Hz

ThinkGear という独自の技術が使用されている。ThinGear テクノロジーでは、1 秒間の脳波をサンプリング周波数を 512Hz として高速フーリエ変換し、0.5Hz 間隔で 50Hz まで周波数分析する。そして、得られるデータを表 1 に示すように周波数帯域ごとに 8 分割する。さらに、各帯域の平均パワースペクトルを計算し、各帯域の代表値が算出される。仕様書によると、この平均パワースペクトルは毎秒 1 回計測されるものであり、単位はないとしている。

3. 実験及びデータ解析方法

本章では、実施した実験の内容及び実験で得られたデータを解析する方法について述べる。まず、第 3.1 節で、実験の目的、内容について述べる。次に、第 3.2 節で、実験で得られたデータを解析する手順について説明し、第 3.3 節でデータ解析の詳細な方法を述べる。

3.1 実験内容

3.1.1 実験目的

本研究の最終的な目的は、講義中の受講者を観測したデータを用いて、受講者の状態推定を容易にできるようにすることである。本研究では、受講者を観測する手段として、簡易脳波センサ MindTune を利用することを述べた。簡易的でない方法で測定した脳波のデータを利用する場合には、文献 [2] が示すように、人間の状態をある程度推定できる可能性があるとされている。しかし、簡易的な脳波センサを使う場合には人間の状態がどの程度推定できるのかどうかは分からない。そこで、本研究ではまず、簡易脳波センサ MindTune によって、一般的な人間の状態をどの程度認識できるのかどうかを調査することを目標とする。ここでは、一般的な人間の状態の中でも、より単純であると考えられる「人間の大きな行動」を MindTune によってどの程度認識できるのかどうかを調査する。そのために、人間がいくつかの行動をとった際の脳波を MindTune によって測定する実験を行い、得られたデータを解析することで、MindTune の性能を検証した。

3.1.2 実験方法

実験では、著者 1 人を観測対象とし、いくつかの行動をとった際の脳波を MindTune によって測定した。行動の内

容は、「A:できるだけリラックスした状態で目を閉じる」、「B:できるだけ集中して簡単な計算をする」、「C:自分の好きな音楽を聴く」、「D:携帯電話を操作する」の4種類である。それぞれの行動は椅子に座った状態であり、行動A以外は目を開けているものとする。1回の測定時間は5分間で、各行動のデータをそれぞれ10回ずつ測定した。ここで、実験を行った時間帯や、被験者の眠気、疲れといった状態、周囲の雑音などは考慮しないものとする。

3.2 データ解析の内容

3.2.1 データ解析において着目する値

実験結果から得られたデータの解析においては、本研究と同様に MindTune を利用している文献 [6] における研究を参考にした。MindTune からは、表1に示すような周波数帯域別に分けられた8種類の脳波の平均パワースペクトルが計測できる。研究 [6] ではこの8種類の帯域の中でも、theta 帯域、low-alpha 帯域、high-alpha 帯域、low-beta 帯域、high-beta 帯域の5種類の帯域の値について調べている。ここでは、残りの3種類の帯域については除去して考えている。その理由として、delta 帯域は深い睡眠時に検出されノイズの影響を受けやすい帯域であるためとしている。また、low-gamma 帯域、high-gamma 帯域については、特殊な事例において観測される周波数帯域であるためとしている。本研究でも、文献 [6] の研究を参考にし、theta 帯域、low-alpha 帯域、high-alpha 帯域、low-beta 帯域、high-beta 帯域の5つの帯域の値に着目して調べることとする。そのようにすると、第2章で述べたように各平均パワースペクトルの値は毎秒1回計測されるため、5種類の帯域に関する値が毎秒1つずつ得られることになる。そこで、本研究ではこの5種類の帯域に関する各値を要素とする5次元ベクトルを1つの値として考えることとする。従って、今回の実験では1回の測定を5分(300秒)間で行っていることを考慮すると、1回の測定につき、300個の5次元ベクトルの値が得られることになる。

また、今回は2種類の値を定義し、2種類それぞれの値に対してデータ解析を行った。1つは、5種類の帯域の平均パワースペクトルの計測値そのままの値である。これは、上記の毎秒1回得られる5次元ベクトルそのものである。もう1つは、各帯域の平均パワースペクトルの計測値を、全体に対して各帯域が占める割合に換算した値である。ここで、前者を計測値、後者を割合と呼ぶこととする。割合は、計測値の各要素を単純に換算したものであるため、こちらも計測値同様に5次元ベクトルで表現することができる。

3.2.2 データ解析の手順

本研究では、MindTune の測定データを用いた行動認識を、教師付きの機械学習によって行うことを想定したデータ解析を行った。具体的には、まず第3.1節で述べた実験

によって測定したデータを学習データとテストデータに分割し、学習データから各行動の教師データを作成する。今回は4種類の行動の認識が目的であるため、4種類の行動それぞれの教師データを作成した。そして、作成した教師データを基に、テストデータに対して行動認識のテストを行うことで、4種類の行動を何らかの手段で認識することが可能であるかどうかを検証した。行動認識のテストとは、テストデータを各行動の教師データと何らかの方法で比較することで、当該テストデータがどの行動のものであるかを自動的に判定させる場合にどのような結果が出るかを検証する、というものである。

3.3 データ解析の詳細な方法

3.3.1 測定データの分割

テストを行うためには、まず、MindTune で測定した実験のデータを学習データとテストデータに分割する必要がある。今回は4種類の行動それぞれについて10回ずつ測定を行っているため、合計40個の測定データがある。この内、1個をテストデータとし、それ以外の39個を学習データとするという分割を行った。ここで、テストデータの選び方は40通りあるが、40通り全てについてテストを行うものとする。

また、学習データ及びテストデータの個々の値は、第3.2節で説明した5次元ベクトルであると考えられる。従って、1回の測定で300個の5次元ベクトルが得られるため、学習データには $39 \times 300 (=11700)$ 個、テストデータには $1 \times 300 (=300)$ 個の5次元ベクトルの値が含まれることになる。

3.3.2 教師データの作成方法

学習データが決まれば、次に、学習データを用いて教師データを作成する。本研究では、第3.2節で説明した計測値と割合の2種類の値を用いて教師データを作成した。ここで、その2種類の値からどのようにして教師データを作成するかを説明する。今回は2種類の値それぞれに対し、以下の2通りの方法で教師データを作成した。

- (1) k-means
- (2) ベクトル間の距離の単純な比較

以下で、それぞれの方法について説明する。

- 方法1: k-means

k-means とは、クラスタリングの方法の一種で、複数のベクトル値を、ベクトル間の距離に応じて k 個のクラスと呼ばれるグループに分割するというものである。本研究では、学習データに含まれる11700個の全ての5次元ベクトルを行動の種類によらず k-means でクラスタリングし、各ベクトルを各クラスに振り分けた。今回行ったデータ解析では $k=10$ とし、10個のクラスに分割した。ここで、各クラスに対し、クラスに含まれる全ての5次元ベク




図 3 1つの行動のヒストグラムの例




図 4 theta 帯域における 10 秒間の平均パワースペクトルの例

トルの平均値を各クラスタの代表値として算出しておく。また、クラスタリングを行う際には、各 5 次元ベクトルがどの行動のものであるかが後で分かるようにしておく。次に、クラスタリングの結果を基に、各行動ごとのヒストグラムを作成する。ヒストグラムは、横軸が、各クラスタのクラス番号、縦軸が、当該行動のベクトルが各クラスタにどの程度の割合で出現するかを表す頻度となっている。今回はクラスタ数 $k=10$ としているので、10 個の頻度の値が得られる。 $k=10$ とした時の 1 つの行動のヒストグラムのグラフの例を、図 3 に示す。図 3 に示すようなヒストグラムを 4 種類の行動ごとに作成するというのが、ここでの手順となる。方法 1 は、10 個の頻度の各値を要素とした 10 次元ベクトルを、各行動の教師データとするというものである。

また、方法 1 に関しては、さらに別の方法による教師データも作成した。上記の方法では、1 秒間の計測値、あるいは割合をクラスタリングしている。しかし、MindTune で測定した値は、図 4 に示すように数秒間で大きく変動することが多く、数秒間単位で値を見た場合も考慮した方がよいのではないかと考えた。そこで方法 1 に関しては、計測値、あるいは割合の、各 5 次元ベクトルの 5 秒平均、10 秒平均の値を同様にクラスタリングした場合についても解析し、教師データの作成、テストを行った。

● 方法 2：ベクトル間の距離の単純な比較

方法 2 は、方法 1 より単純なものとなっている。具体的には、学習データから、各行動ごとの 5 次元ベクトルの平均値を算出するのみというものである。この 5 次元ベクトルの平均値が、方法 2 における各行動の教師データとなる。

3.3.3 テスト方法

テストデータの表現方法、及びテスト方法も、方法 1、方法 2 によって異なる。

まず、方法 1 について説明する。初めに、テストデータに含まれる全ての 5 次元ベクトルを、教師データを作成した際に行ったクラスタリングによって分割した、10 個のクラスタに割り振る。ここで、各 5 次元ベクトルは、あらかじめ算出しておいた各クラスタの代表値とのユークリッド距離が最も近いクラスタに割り振るものとする。また、テストデータに含まれる 5 次元ベクトルの数は、1 秒単位の値をクラスタリングした場合には 300 個、5 秒単位の値をクラスタリングした場合には 60 個、10 秒単位の値をクラスタリングした場合には 30 個となる。次に、教師データと同様の方法でテストデータのヒストグラムを作成する。これにより、テストデータを教師データと同じ形式の 10 次元ベクトルで表現することができる。

方法 2 に関しては、教師データと同様、テストデータに含まれる 300 個の 5 次元ベクトルの平均値を算出するだけでよい。これにより、テストデータを教師データと同じ形式の 5 次元ベクトルで表現することができる。

以上の手順により、教師データとテストデータが、方法 1 では 10 次元ベクトル、方法 2 では 5 次元ベクトルという同じ次元のベクトル値で表される。これより先はどちらの方法に関しても同じ手順となる。具体的には、テストデータを各行動の教師データと比較し、ベクトル間のユークリッド距離を計算して、最も距離が近い行動がテストデータを表す行動である、と判定するというものである。

3.3.4 データ解析方法まとめ

以上のような、方法 1、方法 2 という 2 種類の方法でテストを実施した。また、方法 1 については、1 秒単位、5 秒単位、10 秒単位という 3 種類の値によってテストを行った。さらに、「計測値」と「割合」という 2 種類の値によって作成した教師データをそれぞれの方法で試行したので、合計すると表 2 に示すような 8 つの方法でテストを実施したことになる。

また、今回のデータ解析では、統計ソフトの R を用いて作成したプログラムを利用した。具体的には、方法 1、方法 2 共に、教師データの作成から、テストデータと各行動の教師データとの間のユークリッド距離の計算までをプログラムで自動的に行っている。最も距離が近い行動をテストデータの行動として判定する部分については、手作業で行った。

以上の手順により、実験データの解析を実施した。デー

表 2 8つのテスト方法

方法 1 による計測値 (1 秒単位)	方法 1 による割合 (1 秒単位)
方法 1 による計測値 (5 秒単位)	方法 1 による割合 (5 秒単位)
方法 1 による計測値 (10 秒単位)	方法 1 による割合 (10 秒単位)
方法 2 による計測値	方法 2 による割合

タ解析の目的は、教師データの作成方法、テスト方法を変えることで何回かテストを実施し、それぞれの方法においてテストの正解率がどの程度になるかを調査することである。

4. データ解析結果

本章では、第 3 章で説明したデータ解析の結果について述べる。まず第 4.1 節でテストの結果を示し、第 4.2 節で結果に対する考察を述べる。

4.1 テスト結果

4.1.1 方法 1 の結果

第 3.3 節で述べたように、テストデータの選び方は 40 通りあるため、それぞれの方法によるテストを 40 回行った。方法 1 のそれぞれの方法におけるテストの、全体の正解率及び各行動ごとの正解率を表 3 にまとめる。

表 3 を見ると、1 秒、5 秒、10 秒のいずれの時間の単位でクラスタリングをした場合でも、全体の正解率はあまり高いものになっていないことが分かる。計測値と割合を比較した場合でも、あまり大きな違いは見られず、全体的に低い正解率となっている。また、行動の種類別の正解率を見ると、全体的に B と C は正解率が比較的高いことが多く、逆に A と D は低くなっている。このことから、B と C は正しく認識できる可能性が高いようにも見える。特に、5 秒単位の計測値と 10 秒単位の計測値は、行動 B の正解率がそれぞれ 90%、100%と非常に高い結果を示している。しかし、この 2 つの方法では、40 回のテストの内のかなりの割合で判定結果が B となっていた。このことから、この 2 つの方法では行動の種類に関わらず B と判定してしまっていると言えるため、行動 B を正しく認識できているとは言えない。このように、方法 1 によるテストでは、あまり高い正解率が得られなかった。

4.1.2 方法 2 の結果

方法 2 も、合計 40 回のテストを行った点については方法 1 と同様である。方法 2 におけるテストの、全体の正解率及び各行動ごとの正解率を表 4 にまとめる。

表 4 を見ると、方法 2 によるテストでも、全体の正解率はあまり高くないことが分かる。また、こちらの方法でも、行動の種類によって正解率に差があることが分かった。

表 3 方法 1 による正解率

	全体の 正解率	A の 正解率	B の 正解率	C の 正解率	D の 正解率
1 秒単位 (計測値)	25%	0%	40%	60%	0%
1 秒単位 (割合)	27.5%	40%	10%	60%	0%
5 秒単位 (計測値)	30%	20%	90%	10%	0%
5 秒単位 (割合)	20%	10%	30%	40%	0%
10 秒単位 (計測値)	30%	10%	100%	10%	0%
10 秒単位 (割合)	35%	30%	50%	60%	0%

表 4 方法 2 による正解率

	全体の 正解率	A の 正解率	B の 正解率	C の 正解率	D の 正解率
計測値	22.5%	0%	60%	10%	23.3%
割合	35%	40%	10%	70%	43.3%

4.2 考察

方法 1、方法 2 のどちらを見ても、全体の正解率は最高でも 35%と非常に低い結果となった。これは、少なくとも今回試行した方法では、「A:できるだけリラックスした状態で目を閉じる」、「B:できるだけ集中して簡単な計算をする」、「C:自分の好きな音楽を聴く」、「D:携帯電話を操作する」という 4 種類の行動を認識することは困難である可能性を示している。また、いずれの方法でも、行動の種類によって正解率に差が生じた。全体的に、B、C は比較的高い正解率を示し、A、D はかなり低い正解率を示している。

以上のように、4 種類の行動の判別を目的とした今回のテストでは、正解率は低いものとなる。しかし、1 種類の行動に限定して考えると、多少は良い精度が出る可能性がある。例えば、方法 2 の計測値において、B の正解率は 60%であるが、B 以外のものを B と答えた割合は 30%であった。これは、4 つの行動を判別することは困難でも、あるテストデータが行動 B であるかそうでないかを判別しようとすれば、やや高めの正解率が出る可能性があることを示している。同様に、方法 2 の割合においては、C の正解率が 70%、C でないものを C と答えた割合が 43.3%であった。これは、あるテストデータが行動 C であるかそうでないかを判別しようとすれば、やや高めの正解率が出る可能性があることを示していると考えられる。以上を考慮すれば、行動の種類を限定することで、MindTune により認識できることもと考えると考えられる。

結果として、簡易脳波センサ MindTune によって、上記の 4 種類の行動を判別するということは、少なくとも今回実施した方法では困難である可能性があることが分かった。しかし、行動 B と行動 C に限定して考えれば、行動

を認識できる可能性があることも明らかになった。行動 A と行動 D に関しては、測定時の被験者の精神状態に差が出ることなどが考えられるため、MindTune による認識は困難であると考えられる。

以上のように、いくつかの行動を定義して行った今回の行動認識のテストでは、いずれの方法でも全体の正解率は低くなった。従って、MindTune によって講義中の受講者の状態推定を行うことを考慮した場合、考えられる全ての受講者の状態を正しく推定することは困難である可能性がある。しかし、今回行った方法以外のテスト方法もまだ考えられるので、今後はそれらについても検討する。以上より、現段階では、MindTune によりどの程度の状態推定が可能であるかどうかはまだ断定はできない。また、今回の実験で、MindTune で認識できる状態とそうでない状態がある可能性があり、状態の種類によってはある程度の精度での認識が可能であることが明らかになった。今後は、その点に関してもさらなる調査が必要である。

5. おわりに

本研究の目的は、高等教育における講義中の受講者を観測することで、状態推定を行うことである。本稿では、簡易脳波センサ MindTune によって取得したデータによる行動認識を行った。結果として、被験者の行動の種類によっては、ある程度の精度での認識が可能であることが明らかになった。これによって、大学の遠隔講義のように高機能なセンサを使用できない場合でも、簡易的なセンサによって取得したデータから行動認識を実現できる可能性が示された。

上記のように、今回のデータ解析だけではまだ MindTune の性能が十分に判明していない。そのため、今後はさらに異なる教師データの作成、テスト方法を試す。また、今回設定した 4 種類の行動以外の状態における脳波の測定や、別の被験者のデータをとるといった、新たな実験の実施も検討する。以上のように、今後は、MindTune を用いた状態推定についてさらなる調査を行う予定である。

参考文献

- [1] 椋木雅之, 上松信, 美濃導彦, “項目反応理論に基づく理解度と振る舞いの関係性解析”, 教育システム情報学会誌, vol30, No1, pp.65-76, 2013.
- [2] 森田尚亨, 柳瀬香南, “脳波データを用いた精神状態の推定および分類について”, 高知学園短期大学紀用, No36, pp.49-73, 2006.
- [3] 市川忠彦, 脳波の旅への誘い 楽しく学べるわかりやすい脳波入門 第 2 版, 星和書店, 東京, 2006.
- [4] 岡部靖憲, 実験数学 -地震波, オーロラ, 脳波, 音声の時系列解析, 朝倉書店, 東京, 2005.
- [5] 大熊輝雄, 松岡洋夫, 上埜高志, 脳波判読 step by step 入門編 第 4 版, 医学書院, 東京, 2006.
- [6] 伊藤桃代, 伊藤伸一, “ドライバの運転動作に基づく個人特性を考慮した危険運転予測システムの構築”, 徳島大学

大学院ソシオテクノサイエンス研究部研究報告, No58, pp.33-41, 2013.

- [7] http://naraamt.or.jp/Academic/kensyuukai/2005/kirei/nouha_mon/nouha_mon.html 2014 年 1 月確認.
- [8] <http://www.mindtune.jp/products/> 2014 年 1 月確認.