

機械学習を用いた生体情報による感情分類手法

浦部 直人¹ 菅谷 みどり¹

概要：近年、工学的に感情を分類する手法が研究されており、様々な分野で応用されている。中でも、生体情報を用いた感情分類は、中枢神経系である脳波指標や自律神経系の心拍指標などを用い、定量的なデータを取得し、分析をおこなうことで分類している。しかし、この感情分類は、個人差が考慮されていないなどの課題がある。そこで、本研究ではこれらの生体情報を入力データとしたディープラーニングで学習することで、個人差を考慮した感情分類をおこなうことを目的とした。提案では、正解データである主観感情データの取得方法を工夫し、4つの基本感情の分類を試みた。その結果、80%の精度で基本感情の4分類をおこなうことができた。さらに、入力データに関する解析をおこなうと、心拍指標が感情分類において重要な特徴である可能性を得た。このことから脳波と心拍指標の両方を感情分類に用いることの必要性が示唆された。

キーワード：深層学習, 感情分類, Affective Computing, 脳波, 心拍変動

NAOTO URABE^{†1} MIDORI SUGAYA^{†1}

1. はじめに

近年、人の感情を工学的に分類する手法の研究されている。特に、脳波や心拍などの生体情報をセンサやデバイスで測定し、それを用いて人の感情を分類する手法が提案されている[1,2]。生体情報を用いて人の感情を計測する方法は、感情をリアルタイムで応用できることから自動車やマーケティング、ロボットなど様々な分野での応用が検討され始めている。

Wang らによると工学的な分野における感情の分析方法は主に3つに分類される[3]。一つ目は、顔の表情や音声の情報を取得し、分析する手法である[4-6]。視覚や聴覚からの情報に基づく分析技術においては、多くのケースで視覚はカメラ画像、聴覚は音声情報により取得する。これらの情報はカメラやマイクなどの非接触で収集できるため、測定者に不快感を与えずに情報を収集できる。しかし、測定対象である表情や声色は、意図的に本人の感情と異なったものにできるため、本心とは異なった感情になることがある。二つ目は、心電図や皮膚コンダクタンス、呼吸、心拍など、自律神経系の変化に応じて感情状態によって変化する生理学的信号による手法である[1,2]。生理学的信号のうち、自律神経は緊張や、リラックスを計測できるとされていることから[7]、感情を計測するための指標としても用いられている[8,9]。とくに心拍変動値はより詳細で複雑な感情状態を得られる傾向があるとされていることから、近年、詳細な感情分析に用いられる。

三つ目は、脳波などの中枢神経系から記録される脳の信号による手法である。この脳信号は感情状態に対して有効な特徴を示すことが多数の研究から示されている[10-12,17]。

こうした中で、工学的な感情の分類手法は先の三つの種類の内の一つのみの特徴を用いている研究は多くある。一方、複数の種類を用いた研究、つまり、種類の異なった複数の特徴による手法はまだ十分ではない。

複数の感情推定手法を用いた研究として、池田らは脳波 (EEG)・心拍値 (ECG) から得られる変動指標の組み合わせによる感情推定手法を提案した[12]。池田らは、人の感情を Arousal(覚醒度)、Valence(快不快)の2軸で表現するラッセルモデルを用い[14]、Arousal(覚醒)を脳波、Valence(快不快)を心拍変動指標に対応づけ、それらの結果の組み合わせにより感情を分類するものとした[14]。しかし、池田らの方法では、生体情報の個人差を考慮しておらず感情分類精度が低い課題があった。

Stamos らは、個人ごとのベースラインをモデル化するために、脳波 (EEG)、心拍値 (ECG) の値を SVM, NN の機械学習により感情を推定し、平均 60%の正確さで感情を判定できることを示した[9]。しかし、脳波計のチャンネルが多く、分析に手間がかかることや、主観の取得方法、機械学習手法が十分ではなく、正確さを高めることが困難である。

本研究では、チャンネル数を減らした脳波データと心拍変動値、また、動画視聴中にリアルタイムで取得する仕組みを開発し、深層学習・SVMなどの機械学習モデルを構築し推定を行った。結果、Arousal-valence の 2D 感情モデルの4象限分類において平均 85%の感情分類精度が得られることを示した。

本論文の構成は次の通りとする。2節にて提案である感情分類手法について述べる。3節にて予備実験、4節にて評価実験、5節にてまとめと今後の課題を述べる。

¹ 芝浦工業大学
Shibaura Institute of Technology

2. 提案

2.1 課題と目的

Stamos らの手法においては[9], 感情の実験分類方法について課題がある. まず, 1 つ目の課題として, 刺激呈示とその評価方法がある. 現在, 多くの研究では画像視聴で刺激呈示を行っており, それによる感情想起と評価を行う. この刺激呈示では画像より, 動画が効果的であることが報告されており[12], Stamos とも動画を用いている. 具体的には, 短い動画を Arousal, Valence のスコアにより選定し, 感情 SAM(Self-Assessment Maskin)[16]により 1 分ごとに評価している. しかし, 感情の起伏を正確に評価するには, 感情の想起力が重要である. 本研究では, 1 分の短い動画では, 十分な成果が得られなかった. そこで, 3 分程度のストーリー性のある動画により感情を想起しつつ, 視聴中の感情評価を実施が有効と考え, それを実現するシステムを設計・実装した.

また, 2 つ目の課題として, パターン化手法である. Stamos は SVM, ナイブベイズ手法を用いて感情モデルを生成したが[8,9], 近年目覚ましく発展した深層学習は応用していない. そこで, 本研究では, 深層学習を行うことで, より正確な分類を行うことを目的とする.

2.2 感情分類モデル

感情分類は, 基本的なモデルとして数多くの文献で利用されている, 2D Arousal, Valence Model を用いる[14]. 本モデルでは, 人の感情を覚醒軸 (Arousal) と快不快感軸 (Valence) 軸に分類するもので, 基本感情は, これらの軸の直行する 4 象限 High Arousal/High Valence(HAHV), High Arousal/Low Valence (HALV), Low Arousal/Low Valence(LALV), Low Arousal/High Valence(LAHV) に分類する[8,9].

2.3 機械学習フレームワーク

機械学習を用い感情分類の目的を達成するため本研究では, 機械学習のためのフレームワークを提案する. モデルの作成と計測 (評価) を目的とし, (1)モデルの作成と(2)感情の計測の 2 工程とした. 工程の概要図を図に示し, 後の工程の概要図を図に示す. (1)モデルの作成は, 準備, 計測中, 計測後に分かれている. 準備では, 初期設定や脳波計と心拍計の装着をおこなう. 準備後, 感情想起をし, 生体情報と主観データを計測する. 計測後, それぞれの取得したデータを統合し, それを機械学習の学習データとして機械学習で学習し, モデルを作成する.

(2)感情の計測とモデルの評価は, 準備と測定に分かれている. 準備は(1)と同様の手順であるが, センサ装着後, (2)で作成したモデルを読み込み, その後計測をおこなう. 計測では 15 秒ごとに脳波・心拍データの統合をおこない, 機械学習にて分類する. その結果を画面に表示しフィードバックをおこなう.

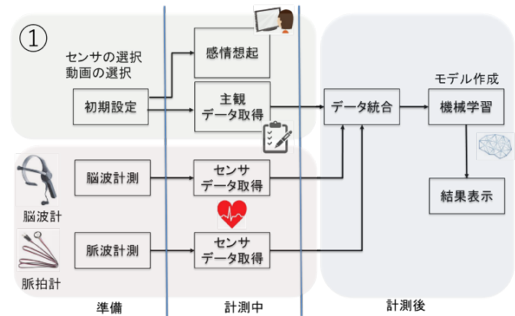


図1 機械学習による感情分類手法 (モデル作成)

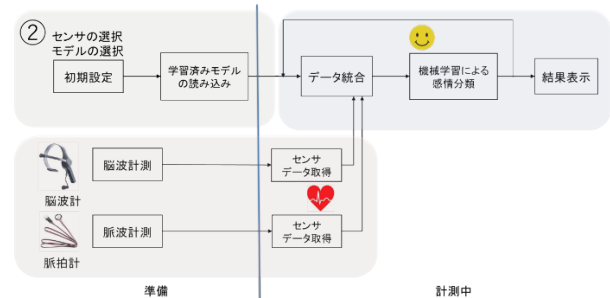


図2 感情分類手法(2)感情分類

2.4 生体情報 (脳波・心拍)

本研究で用いる覚醒-眠気度を表す脳波指標と快-不快感を表す心拍変動指標の詳細と計測方法について説明する.

2.4.1 脳波指標

脳波指標を用いて, 覚醒度を推定するのは感情研究において一般的な手法である. 中枢神経系を記録する脳波には, 周波数帯によって主に 5 種類に分けられる. α 波(14Hz~8Hz)はリラックス状態で現れ, β 波(38Hz~14Hz)は緊張や興奮状態, γ 波(26Hz~70Hz)は集中状態, σ 波(4Hz~0.5Hz)は睡眠状態, θ 波(8Hz~4Hz)は瞑想状態で現れる. 脳波は感情状態に対して有効な特徴を示すことが証明されており, 覚醒-眠気度を示す指標として適切であると考えられる. 本研究では, NeuroSky 社の MindWave Mobile2[18]を用いて脳波を計測する. MindWave Mobile2 は計測値から Attention と Meditation を算出する. Attention は集中度, Meditation はリラックス度を示し, 0~100 の範囲で記録される. 記録にはセンサと PC を Bluetooth で接続し, データを PC 上に保存する.


2.4.2 心拍変動指標

人の自律神経系の活動を反映する指標として, 心拍変動解析(HRV)が一般的に用いられる[7]. 心拍変動とは, 心電図の一心拍のピークである R 波と次の一心拍の R 波の間隔(RR 間隔)のゆらぎを示す値となる. RR 間隔は呼吸や血圧のゆらぎが関係しており, 一定でなく変動する性質を持つ. RR 間隔から算出される時間領域指標に pNN50 がある. pNN50 は多くの感情分類の研究で用いられており, 快-不快感を表す指標として用いられている [12]. pNN50 は隣接する RR 間隔の差が 50ms を超える心拍の割合で算出

される。この値が高いほど、自律神経における副交感神経優位な状態であることを示す。また、小さいほど交感神経優位（緊張状態）となる。本実験では、Switch Science社のPulse Sensor[19]を用いてpNN50を計測する。このセンサをArduinoに接続し、Processingを実行して心拍の取得とpNN50の計算をおこない、ファイルに保存した。

2.5 感情想起方法

感情想起は、予備実験ではValence(快不快度)とArousal(覚醒度)の値が付与されたIAPS画像[21]でおこなった。IAPS画像は、国際的な情動画像データベースであり感情を想起させる実験でよく用いられている感情想起方法である。ValenceとArousalの値は、1から9の範囲の小数で付与されている。この値からDini Handayaniらの評価値と感情の対応付け[20]を参考にして次のように画像を見たときに想起される感情を決定した。



予備実験では、この感情が画像を呈示したときに想起される感情として、感情が想起されやすいように刺激が強い画像で、かつ、日本人に合ったものを1感情8枚ずつの合計32枚を用いた。刺激の強さは次のように計算した。

Arousal値とValence値は、5.0が中性的な状態であり、Arousal値、Valence値が1に近いほど眠気度、不快度が大きくなる。また、Arousal値、Valence値が9に近いほど、覚醒度、快度が大きくなる。そのため、刺激の強さが大きくなるほど強い刺激になる。

$$\text{刺激の強さ} = |\text{Arousal}[\text{Valence}] \text{値} - 5.0| \quad (1)$$

2.6 主観データ取得方法

主観データの取得にはSAM尺度を用いた。SAM尺度は、非言語的な感情の評価方法で、感情を主観的に評価する際に用いられる[8,9]。SAM尺度は、言語的な感情の評価方法でないため、感情語の個人による言葉のとらえ方の違いに影響されずに評価できることが期待される。評価はSAMのアバターの用いた質問項目を用いておこない、各アバターとその間の1から9の9段階から自分の感情として近いものを選択する。この方法はIAPS画像に付与されているValenceとArousalの値の計測方法と同じである。予備実験では、SAM尺度を用いて感情想起したときの感情を紙媒体に鉛筆で選択してもらい評価した。

2.7 機械学習

本研究では、感情の分類に機械学習を用いる。機械学習とはデータを入力とし、解析することでそのデータの規則や判断基準を見つけ出し、学習する分類方法である。機械

学習は、特に大量のデータを反復的に学習してそこに潜むパターンを見つけ出し、分類することを得意にしている。また、後述の生体情報から算出される脳波指標や心拍指標は数値であるため、感情の分類に機械学習を用いた。機械学習には様々な種類の学習方法がある。本研究で用いるディープラーニング(Deep Learning; DL)について説明する。

DLの理解にあたり、ニューラルネットワーク(NN)を先に説明する。NNとは、人間の脳の構造を数式的に表し作られたモデルである。人間の脳はニューロンと呼ばれる神経細胞のネットワークでできておりニューロン間の情報伝達は電気信号によっておこなわれている。ニューロンは他の複数のニューロンからの入力を加算し、それがあるしきい値を超えると次のニューロンへ電気信号を送信する。それぞれのニューロンの電気信号の伝わり方でネットワーク全体の電気信号の伝わり方が変わりこの違いにより人間は異なるパターンの認識や物の判断をしている[22]。これを数式的に表したのでNNであり、このうち、深い階層構造を持つものをDLと呼ぶ。DLは反復的に学習してそこに潜むパターンを見つけ出すことが特に得意であり、隠れ層の数を自由に設定できるため、大量のデータも処理できる。

2.7.1 入力データ (生体情報)

予備実験では、池田らにより有効性が確認されている感情分類手法[12]を参考にし、入力データに心拍変動指標のpNN50、脳波指標のAttentionとMeditationを採用するものとした。

2.7.2 正解データ (主観データ)

ArousalとValence値から、IAPS画像をValenceとArousalの値から感情を対応付けたのと同じ方法で感情を算出した。生体情報の取得から学習までのプロセスをまとめたものを図に示す。感情想起を画像でおこない、生体情報と主観データを取得し、それを統合したものを機械学習の入力データと正解データとして学習をおこなう。

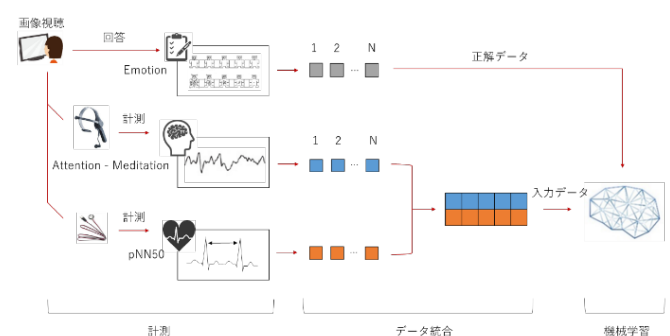


図4 生体情報取得から学習までのプロセス

2.8 システムの設計・実装

前述の図の感情分類手法をPythonで実装した。GUIはHTML, JavaScriptをオフラインで作成できるEelライブラリを使って作成した。システムは、HTMLで処理できる

内容は、HTML 側で処理し、機械学習やファイルの処理は Python 側で処理した。機械学習に関して、ディープラーニングは Tensorflow ライブラリ[23]を用いた。(1)モデルの作成の処理内容を図 5(a)に示す。初期設定、画像再生、CSV 作成までの工程で機械学習に必要な主観データを取得する。その後、データ統合で生体情報と主観データを統合し、学習データを作成し機械学習で使う Epoch 数や、中間層の数を設定する。その設定で機械学習し、その結果を画面に表示する。




図 5 モデルの作成と分類システム

次に、(2)感情の計測の処理内容を図 5 (b) に示す。まず、分類器として用いる学習済みモデルを読み込む。その後、データを統合し、入力データを作成、機械学習による分類をおこないその結果の感情を画面に表示する。この工程を 15 秒ごとに繰り返して感情を計測する。

2.9 インターフェース

開発したシステムのインターフェースを図 6 に示した。左上は、初期設定画面のインターフェースで、使用するセンサや評価方法、ビデオ数の選択を行う。次に左下は、データの統合画面のインターフェースで、機械学習の入力データの特徴として用いる指標の選択が可能である。次に右上は機械学習パラメータの設定で、エポック数や隠れ層の数、ドロップアウト率の選択ができる。最後に右下は感情計測画面である。個人のモデルを読み込んだ後に感情の計測をおこない、15 秒ごとに更新する。

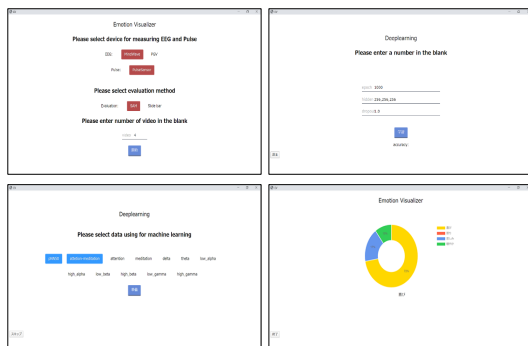


図 6 左上：初期設定，左下：データ統合，
 右上：機械学習，右下：感情計測画面

3. 予備実験

3.1 実験内容

提案した感情分類の機械学習フレームワークが有効であることを検証することを目的とし、実験をおこなう。機械学習は、入力の次元数が 2 次元で少ないため、DL だけでなく SVM も用いて学習した。この 2 つの機械学習と従来の手法の精度を比較し、その結果を考察した。協力者 3 名を対象に機械学習モデルの作成を以下の図の手順でおこなった。脳波計と心拍計の装置を装着した後に、安静状態を 30 秒取った。安静状態とは、ディスプレイに白画面を表示した状態である。次に白画面の中央に十字の印を表示させた警告画面を 2 秒間表示した。この時、協力者には十字を見るように指示した。その後、感情想起として 30 秒間、画像を表示し、15 秒間で主観アンケートの SAM 尺度に紙媒体で回答してもらった。これを 32 枚の画像ごとに繰り返した。




図 7 予備実験手順



図 8 予備実験で用いた画像の例

3.2 評価方法

SVM と DL は表 1 のように設定した。SVM の設定は最も一般的によく用いられている線形カーネルとした。DL の中間層の次元数は 2,4,8 次元で学習した結果を比較し、最もその精度が高かった 2 次元とした。中間層の活性化関数は、複雑なデータにおいても勾配が消失せずシグモイド関数や双曲線正接関数に比べて学習が早く進むため、ReLU を用いた。出力層の活性化関数は分類問題であるため Softmax とした。そして、取得した生体データ 960 個 (30 秒×32 枚) のデータの内 8 割を訓練データ、残りの 2 割をテストデータに分割し、訓練データを用いて学習した。本パラメータでのそれぞれの分類精度を比較考察した。

表 1 SVM, ディープラーニングの設定 (予備実験)

	パラメータ	値
SVM	カーネル	線形カーネル
ディープラーニング	中間層	[2,2]
	活性化関数 (中間層)	ReLU
	活性化関数 (出力層)	Softmax

3.3 実験の結果と考察

テストデータで精度の検証を実施した 10 回の平均値を

図 9 に示した。協力者 2, 3 では SVM が一番高い精度となった。しかし、DL, SVM ともに 50%未満と低い結果となった。精度が低い結果となった原因を調査するために SVM の分類の結果を可視化した結果を図 10 に示した。協力者 2 は HVHA と LAHV のみを分類し、協力者 3 は LAHV のみを分類していた。つまり SVM では、4 つの感情の分類ができていないことがわかった。




図 9 各分類手法における分類結果




図 10 SVM の分類結果の可視化

青色の範囲が HVHA, 黄色の範囲が HVLA, 緑色の範囲が LALV, 赤色の範囲が LAHV を表す。

次に生体情報をもとにデータを正解データの感情ごとに色分けしたものを図 11 に示した。協力者に関して、本来では感情ごとにまとまって分布するはずが感情間で特徴がなく同じ場所にデータがかたまっている。このことから指標と感情との間に関係が得られない入力データであったことから、4 感情に分類できなかつたと考えられる。

原因として入力の特徴が適切でなかった可能性と感情喚起が上手にできなかった可能性がある。このことを確認するために画像の付与値から求めた感情と SAM 尺度の主観評価値から求めた感情の正答率を調べた (図 12)。

協力者 2, 3 が 40%前後と 50%を切る結果になった。また、実験協力者ごとの Arousal 値と Valence 値の誤差を図 13 に示した。Arousal, Valence は最低でも 1 枚の画像で 1~2 の評価値の誤差があり、最高で 2 の評価値の誤差がある。このように、実験協力者は SAM 評価時に IAPS 画像に付与されている値と異なる評価をすることが多かった。そのため SAM 尺度で求めた感情が正しくなく、主観評価と生体情報に差が生じ、これらの関係を正確に反映するモデルの生成に失敗したと考える。




図 11 協力者の生体情報による学習データの分布




図 12 付与値と主観評価値から求めた感情の正誤




図 13 付与値と主観評価値の Arousal と Valence の誤差

本実験から、感情想起の方法の改善と機械学習の入力データとする特徴の改善と課題の解決と感情分類の実現を目指して更なる検証をおこなうことにした。予備実験での課題は、(1)IAPS 画像では想定した感情が十分に想起できていない(2)学習の入力データとする特徴が明確でなく適切でないと考えた。また、この課題を解決するために(1)日本人に適切な感情想起の刺激物を検討する(2)脳波の用いる特徴の再検討をした。(1)については、脳波計測メーカに協力してもらい、実際に感情想起に有効であったとされるストーリー性がある映画や CM の動画を用いることにした。また、脳波値を、AF3 から取得される α 波、 β 波、 γ 波、 δ 波、 θ 波の周波数ごとのデータを用いるものとした。

4. 感情評価実験

4.1 概要

感情評価を回答する適切な周期時間の調査、動的な感情評価システムの評価、機械学習の入力データに関する評価を目的として本実験をおこなう。周期時間に関しては対象の時間を 15 秒、30 秒、45 秒の 3 つの時間とし比較、検証をおこなう。実験の協力者 14 名を対象に本提案のシステムを使って実験をおこなった。実験環境は同じままで、15 秒、30 秒、45 秒の 3 つの周期時間でそれぞれの協力者に対しておこなった。

4.2 評価方法

DL は表のように設定した。中間層の数は次元数 64, 128, 256, 512 次元で比較をおこない一番良い結果となった 256 次元を用いた。活性化関数は予備実験時と変更していない。Dropout は後述より 0.0 とした。また、実験の結果である分類精度は学習データとは独立したテストデータでの精度

結果を示している。

表 2 ディープラーニングの設定 (本実験)

	パラメータ	値
ディープ ラーニン グ	中間層	[256,256,256]
	活性化関数 (中間層)	ReLU
	活性化関数 (出力層)	Softmax
	Dropout	0.0

本組み合わせで周期時間が 45 秒のデータを対象に全協力者の絶対誤差を求めた。その平均値を図 14 に示す。パターン 1 と 2 に関しては、予備実験時に用いた方法での誤差の方が少なかった。しかし、パターン 3 に関しては、今回用いた動的な感情評価システムと同じ程度の誤差値となった。パターン 3 は快-不快度の評価の組み合わせであるため、この評価に関しては、動画を感情想起に用いた感情評価において、本システムでも画像時の従来手法と同じ程度の評価を行えることがわかった。




図 14 生体情報と主観データの誤差値

4.2.1 機械学習の入力データに関する評価

機械学習の入力データの改善が精度向上の要因であるかを調査するために表 6 のパターンで入力を変更して精度を求めた。このパターンは、もとの特徴量から 1 つの特徴量を用いないで作られている。パターン 1 (Pattern1) は pNN50 を抜かした他の特徴量 5 つで学習をするということである。もし、このパターンでの分類精度が元の全特徴量での精度よりも悪ければ抜かした pNN50 の指標は機械学習での感情分類において重要な指標であることを示す。この比較により学習にとの程度、各特徴が分類精度に関わっていたかを調べた。

表 6 入力データの特徴量のパターン

	入力データ (特徴)
Pattern1	α波, β波, γ波, δ波, θ波
Pattern2	pNN50, β波, γ波, δ波, θ波
Pattern3	pNN50, α波, γ波, δ波, θ波
Pattern4	pNN50, α波, β波, δ波, θ波
Pattern5	pNN50, α波, β波, γ波, θ波
Pattern6	pNN50, α波, β波, γ波, δ波

このパターンで協力者 8 を除く協力者のデータにおいて機械学習を行った。協力者 8 は周期時間が 45 秒のデータでの機械学習の分類精度がすべて 1.00 となり、この分析では意味がないため用いないことにした。表は各パターンの

協力者ごとの分類精度を示した。さらに分析のために、全特徴量を用いた元の特徴量での分類精度と今回の結果の差を求めたものを表 7 に示す。基にする量は全特徴量での分類精度であるためこの値が正の数だと分類精度が下がったことを表している。

結果より、ほとんどの場合において精度が下がっていることがわかる。つまり全特徴量を用いて学習するのが最も分類精度向上に適している。中でも pNN50 を用いなかったパターン 1 (Pattern1) での分類精度の減少量が最も大きく、pNN50 が感情分類において重要な特徴であるといえる。これは、心拍の指標を用いて感情を分類したほうが分類精度は向上できるともいえる。指標を増やして学習させると分類精度は向上するかを確かめるため、他の心拍変動指標を用いての検証が今後必要になる。また、全体の分類精度は特徴を減らしたことで下がったため、予備実験よりも分類精度が向上したのは、入力データを改善したことがその要因であるといえる。さらに、この結果の有意差を調べるために分散分析をおこなった。その結果、パターン間において、P 値が 0.045012 となった。P 値が 0.05 より小さくなったため、統計学においても、この結果は有意であることが示された。

表 7 各パターンにおける分類精度

	Pattern1	Pattern2	Pattern3	Pattern4	Pattern5	Pattern6
協力者1	0.854	0.806	0.798	0.761	0.838	0.845
協力者2	0.807	0.858	0.867	0.841	0.888	0.889
協力者3	0.687	0.679	0.647	0.637	0.698	0.721
協力者4	0.804	0.812	0.820	0.830	0.831	0.824
協力者5	0.818	0.791	0.885	0.860	0.877	0.883
協力者6	0.779	0.850	0.832	0.782	0.839	0.813
協力者7	0.874	0.805	0.820	0.805	0.867	0.828
協力者9	0.838	0.830	0.852	0.880	0.880	0.843
協力者10	0.925	0.932	0.924	0.932	0.927	0.937
協力者11	0.712	0.754	0.741	0.753	0.775	0.752
協力者12	0.691	0.758	0.743	0.737	0.697	0.724
協力者13	0.660	0.649	0.671	0.695	0.668	0.679
協力者14	0.709	0.754	0.812	0.760	0.793	0.707
平均	0.781	0.791	0.801	0.790	0.814	0.804

4.3 予備実験の再検証

予備実験で取得したデータによる改善前の予備実験時のものと改善後の本実験時の機械学習のパラメータで学習させた分類精度を表 8 に示す。予備実験時では分類精度が上がらなかった同じデータでも改善後のパラメータで学習をおこなうと分類精度が向上した。このことより、本実験で分類精度が上がったのは機械学習のパラメータを改善したためであると再度検証することができた。本研究では、感情想起の方法と機械学習の入力データやパラメータを改善することで、感情分類の精度を向上することができた。これは、機械学習の入力データを増やしたことやパラメータ

を変更したことが大きい要因であると検証できた。

表 8 予備実験のデータによる予備実験と本実験のパラメータでの分類精度の比較

	改善前のパラメータ	改善後のパラメータ
協力者1	0.343	0.669
協力者2	0.472	0.801
協力者3	0.510	0.768

このことから、次章で述べる課題を考慮することでより精度の高い感情分類をおこなうことが可能であると考えられる。

5. まとめと今後の課題

本研究では、EEG, ECG による感情推定における個人差を考慮したモデル生成にあたり、チャンネル数を減らした脳波データと心拍変動値、また、動画視聴中にリアルタイムで取得する仕組みを開発し、深層学習・SVMなどの機械学習モデルを構築し推定を行った。結果、Arousal-valence の2D感情モデルの4象限分類において平均85%の感情分類精度が得られることを示した。今後、一般モデルをあらかじめ作成し、そのモデルで計測しながら個人適用のために学習をおこなうなど、より詳細に精度を向上させる方法を検討する。

参考文献

[1] J. Wagner, J. Kim, From physiological signals to emotions: Implementing and comparing selected methods for feature extraction and classification, in: Proceedings of IEEE International Conference on Multimedia and Expo, 2005, pp.940-943

[2] J. Brosschot, J. Thayer, Heart rate response is longer after negative emotions than after positive emotions, Int. J. Psychophysiol., 50 (2003), pp.181-187

[3] Xiao-Wei Wang, Dan Nica, Bao-Liang Lu, Emotional state classification from EEG data using machine learning approach, Neurocomputing, Volume 129, 10 April 2014, pp.94-106

[4] V.Petrushin, Emotion in speech: recognition and application to call centers, in: Proceedings of the Artificial Networks in Engineering Conference, 1999, pp.7-10.

[5] M.Black, Y.Yacoob, Recognizing facial expressions in image sequences using local parameterized models of image motion, Int. J. Comput. Vis., 25 (1997), pp.23-48

[6] K. Anderson, P. McOwan, A real-time automated system for the recognition of human facial expressions, IEEE Trans. Syst. Man Cybern. B Cybern., 36 (2006), pp.96-105

[7] 三宅 晋司 (監修), 日本人間工学会 PIE 研究部会 (編集), 商品開発・評価のための生理計測とデータ解析ノウハウ—生理指標の特徴、測り方、実験計画、データの解釈・評価方法 2017.

[8] S. Koelstra et al., "DEAP: A Database for Emotion Analysis ;Using Physiological Signals," in IEEE Transactions on Affective Computing, vol. 3, no. 1, pp. 18-31, Jan.-March 2012, doi: 10.1109/T-AFFC.2011.15.

[9] S. Katsigiannis and N. Ramzan, "DREAMER: A Database for Emotion Recognition Through EEG and ECG Signals From Wireless Low-cost Off-the-Shelf Devices," in IEEE Journal of Biomedical and Health Informatics, vol. 22, no. 1, pp. 98-107, Jan. 2018, doi: 10.1109/JBHI.2017.2688239.

[10] J. Coan, J. Allen, Frontal EEG asymmetry as a moderator and

mediator of emotion Biol. Psychol., 67 (2004), pp.7-50

[11] Soraia M, et al, Emotions Recognition Using EEG Signals A Survey, IEEE Transactions on Affective Computing, pp 1- 12 June 2017.

[12] Yuhei Ikeda, Ryota Horie, Midori Sugaya : Estimate Emotion with Biological Information for Robot Interaction, KES-2017Procedia Computer Science, 112, pp. 1589-1600, 2017.

[13] P. Petrantonakis, L. Hadjileontiadis, A novel emotion elicitation index using frontal brain asymmetry for enhanced EEG-based emotion recognition, IEEE Trans. Inf. Technol. Biomed., 15 (2011), pp.737-746

[14] James A. Russell, "A Circumplex Model of Affect", Journal of Personality and Social Psychology, Vol.39, No.6, pp.1161-1178. 1980

[15] X. Li, B. Hu, T. Zhu, J. Yan, F. Zheng, Towards affective learning with an EEG feedback approach, in: Proceedings of the 1st ACM International Workshop on Multimedia Technologies for Distance Learning, 2009, pp.33-38

[16] M. M. Bradley and P. J. Lang, "Measuring emotion: the selfassessment manikin and the semantic differential." J. Behav. Ther.Exp. Psychiatry, vol. 25, no. 1, pp. 49-59, Mar. 1994.

[17] X.-W. Wang, D. Nie, and B.-L. Lu, Emotional state classification from EEG data using machine learning approach, Neurocomputing, vol. 129, 2014

[18] NeuroSky : Mindwave Mobile, <<https://store.neurosky.com>>, 2004

[19] Switch Science : 心拍センサ, <<https://www.switch-science.com>>, 2010.

[20] Dini Handayani, Abdul Wahab, Hamwira Yaacob, Recognition of Emotions in Video Clips : The SelfAssessment Manikin Validation, TELKOMNIKA, 13(4), pp. 1343-1351, 2015

[21] IAPS : <<https://iaps-association.org>>, (2019年6月閲覧)

[22] 詳解ディープラーニング Tensorflow・Kerasによる時系列データ処理, 巢籠悠輔, マイナビ出版

[23] TensorFlow : <<https://www.tensorflow.org/>>, (2019年4月閲覧)