

脳波・心拍変動指標による感情推定の特徴量比較 および機械学習による精度評価

鈴木 圭† 松原 良太† 菅谷 みどり†

芝浦工業大学†

1. 背景と目的

近年、工学的な分野において、人の感情を脳波などの生体指標から推定する研究が数多くされている[1]。この技術は、介護やリハビリ支援ロボットの UX 向上、うつ病などの診断への応用が期待されていることから、一定の需要があると考えられる。生体指標を用いた感情推定手法の一つとして、浦部らは機械学習を適用した感情推定手法を提案した [2]。浦部らは、説明変数・特徴量を脳波・心拍変動指標とし、目的変数・正解データを感情の主観評価として機械学習を行い、個人ごとに感情推定モデルを構築した。また、感情による影響が十分に反映された脳波・心拍変動指標を計測するために、暗室という外部からの影響を受けにくい環境のもと、動画という比較的強い刺激を実験協力者に加えることで、強く感情を喚起させるという工夫をした。これにより、最大 1.00 近く、平均 0.80 近くの精度に達することに成功した。

しかし、平均精度が 0.80 程度であると、うつ病診断への応用などを考えた場合、精度が不十分である可能性がある。一般的に、機械学習による推定モデルの構築にあたり、特徴量の抽出や選択により、推定に有用な特徴量の発見や不要な特徴量の除去を行う。これにより、予測精度の向上を行うが、浦部らの研究ではこうした特徴量の抽出や選択が十分にされていないことが、精度が十分に達していない要因の一つであると考えられる。

そこで本研究では、より高い精度の感情推定モデルの構築を目的とし、脳波・心拍変動指標の特徴量を抽出・選択する手法を検討する。その後、機械学習による精度評価を行う。また、感情推定モデルの精度が高い特徴量の組み合わせや機械学習にあたり必要なデータを収集する方法を提案する。

2. 提案

機械学習に必要なデータ収集や将来的な実生活での利用を考慮した際、脳波計・心拍計は安価かつ装着が簡便なものが良いと考えられる。そのため、本研究では、安価な単一電極で装着が簡便な脳波計である Mindwave mobile2、および、光学式脈拍センサと Arduino を組み合わせた心拍計を用いてデータを収集した。その後、移動平均や周波数解析などの特徴量抽出を行い、ランダムフォレストの重要度や相関比をも

とに特徴量選択をした。そして、説明変数・特徴量を脳波・心拍変動指標とし、目的変数を喜怒哀楽の感情を表すカテゴリデータとして機械学習を行い、精度検証をした。なお、機械学習には深層学習とランダムフォレストを用いた。

3. 実験

3. 1. データ収集

20~30 代の成人 24 名の実験協力者に対して、音楽による感情喚起を行いつつ、脳波・心拍変動指標を取得する実験を実施した。実験環境は、暗室などといった制限された環境ではなく、比較的、汎用的な、まぶしくない程度の明るい部屋で実験を行った。そして、主な実験手順は次に述べる 1)~5)となる。1)実験協力者は椅子へ座り、そこで脳波計・心拍計・イヤホンの装着する。2)実験の練習として、4)の手順を簡略化したものを実施する。3)10 分間静かに待機。4)2 分間の安静、1 分間の音楽視聴、音楽により喚起された感情の主観評価を 1 施行として、8 施行分行う。なお、4)の感情の主観評価の結果から、喜怒哀楽の感情を表すカテゴリデータを生成する。5)感情の主観評価に影響を及ぼす、感情の認知能力や疲労度合などを調査する質問票への回答を行う。

以上の実験によるデータ収集の結果、総レコード数 11749、喜怒哀楽のカテゴリデータがそれぞれ、3558、2175、2704、3312 個得られた。

3. 2. 特徴量抽出

浦部らが用いた脳波指標である θ , δ , α , β , γ という指標の他に、脳波指標として Low α , High α , Low β , High β , Low γ , Mid γ を用いたうえ、これらの指標に対して区間を 15 とする移動平均を算出した。以後、これら移動平均した指標を MA15 X(X は移動平均した指標)とする。また、浦部らが用いた心拍変動指標である pNN50 の他に、IBI, BPM, pNNx(x=10, 20, 30, 40), SDNN, RMSSD, SDNN/RMSSD, CVNN, LF, HF, LF/HF を算出した。

3. 3. 特徴量選択

特徴量の選択にあたり、相関比とランダムフォレストの重要度を参考にした。ここで言う相関比とは、質的データである喜怒哀楽のカテゴリデータと量的データである脳波指標・心拍変動指標の値との相関である。また、ランダムフォレストの重要度とは、ランダムフォレストにより機械学習を行った際に算出される、各特徴量の感情推定への寄与の度合を定量化したものである。相関比とランダムフォレストの重要度により、特徴量を左から降順に並べたグラフを図 1, 2 にそれぞれ示す。

Comparing biological signal's indexes features for improving the precision of classification of emotion by machine leaning

†Kei SUZUKI, Ryota MATSUBARA, Midori SUGAYA

†Shibaura Institute of Technology




図1 ランダムフォレストの重要度




図2 相関比

3. 4. 精度評価

相関比の係数やランダムフォレストの重要度が高く、感情推定に寄与できると推察される変数から順に特徴量に加えていき、その精度の変位をグラフ化することで、精度評価を行った。図3、4にその様子を示す。なお、機械学習には、深層学習とランダムフォレストを用い、精度評価には層化10分割交差検証によって macro f1 の平均値を利用した。ここでいう macro f1 とは、目的変数の種類ごとのデータ数に偏りがある際、用いられる精度指標である。




図3 深層学習の精度変位




図4 ランダムフォレストの精度変位

深層学習は、特徴量の数が 22 の際に最大精度 0.9958(少数第 5 位四捨五入)を記録した。一方、ランダムフォレストの方は、特徴量の数が 21 の際に最大精度 0.9969(少数第 5 位四捨五入)を記録した。本研究においては、深層学習よりもランダムフォレストの方が、特徴量の数の少なさや精度の面で上回る結果となった。

先行研究の浦部らは、特徴量に脳波指標の θ , δ , α ,

β , γ を用い、心拍変動指標に pNN50 を用いた。これらの特徴量を用いて同じ深層学習のハイパラメータで精度を算出したところ、精度は 0.48(小数点第 3 位四捨五入)であった。本研究で用いた特徴量を組み合わせた場合の深層学習およびランダムフォレストの最高精度はいずれも 1.00 (小数点第 3 位四捨五入)となったことから、精度向上がなされた。このことから、浦部らの研究の問題であった、精度が不十分であるという問題を改善した。また、それぞれの機械学習アルゴリズムで精度が 0.95 を超える特徴量の組み合わせは、”MA15 Mid γ , LF/HF, MA15 γ , MA15 Low γ , MA15 High β , SDNN/RMSSD, LF, MA15 High α ”と”LF, HF, LF/HF, RMSSD, CVNN, SDNN”の組み合わせであることが判明した。

3. 5. 議論

生体情報には時間依存性があるため、モデルを構築してから時間が経過すると、説明変数として用いている生体情報の値が変化し、推定精度が落ちる可能性が考えられる。Wei らは、このような感情推定モデルの経時的な安定性の課題を指摘している[3]。本研究ではこの可能性に対する検討が十分にされていないという課題が残っている。

精度評価において、浦部らの報告と差異があったが、この原因を 1)精度評価指標の違い、2)実験環境の違い、以上の 2 つによるものだと考えられる。1)に関しては、浦部らに限らず、他研究との適切な比較のため、複数の指標を算出する必要があると考える。2)に関しては、先行研究では暗室という制限された環境で行っているのに対して、本研究では明るい部屋という、比較的、汎用的な環境で行ったために精度に差異が発生したと考える。制限された環境ではなく、比較的、汎用的な環境で生体情報の取得を行うことで、感情推定技術を実生活で利用できる可能性を広げることができたと考える。

4. まとめと今後の課題

本研究では、精度向上を目的として特徴量の抽出・選択を行ったうえで、機械学習による感情推定モデルを構築した。その結果、精度向上に成功した。

今後は、機械学習精度と質問票に関して分析を行う。また、精度の経時的な安定性の検証を目的とし、モデル構築後に時間経過した状態を人為的に再現して検証を行う。そのうえ、脳波・心拍変動指標には本研究で用いた指標以外にも存在するため、これらの指標を含めた特徴量の検討を考える。

参考文献

- [1]X.-W.Wang,D.Nie,and B.-L.Lu,“Emotional state classification from EEG data using machine learning approach”.Neurocomputing.2014.vol.129.
- [2]浦部直人, 菅谷みどり. “脳波・心拍データとディープラーニングを用いた個人ごとの感情分類手法の提案”. 人工知能学会. 2020. 第 34 回全国大会.
- [3]Wei-Long Zheng et al. ”Identify Stable Patterns Over Time for Emotion Recognition from EEG”. IEEE TRANSACTIONS OF AFFECTIVE COMPUTING. 2019. VOL. 10, NO. 3, JULY.