

脳波データからの共感状態の解析

氏名[†] 五十嵐 大地 氏名[‡] 長尾 智晴所属[†] 横浜国立大学 大学院環境情報学府所属[‡] 横浜国立大学 大学院環境情報研究院

1 はじめに

共感とは、ヒトが他者とコミュニケーションをとる上での礎とされ、磁気共鳴機能画像法を用いて神経基盤を明らかにする研究が生理学の分野で行われている。共感の1つに、見つめ合い課題を用いた場の共有における2者の関係性を解析した研究[1]があり、2者が対面で見つめ合った場合、瞬きおよび特定の脳領域で相互に同期が見られることがわかっている。本論文では、場の共有による相互認知ができていない状態を共感と定義する。共感状態の識別は、コミュニケーションに関する疾患を有する患者さんの行動療法の開発や、教育現場等における効率的な情報伝達手法の開発への応用が期待されている。一方で磁気共鳴機能画像法は実験コストが高いため、社会実装の側面では脳波による解析の需要が高い。しかし、生理学の分野において脳波における共感状態の識別は未解決の問題である。

以上の理由から、本論文では機械学習を用いて脳波データから共感状態を分類する手法を提案する。

2. 見つめ合い課題

共感・非共感の2クラス分類問題の対象として、見つめ合い課題で取得されたデータセットを利用した。1試行につき被験者2名が参加し、脳波計を装着した状態で磁気共鳴機能画像法の装置に入る。装置内のビデオカメラとディスプレイを通じて互いの顔が見られる状態となっており、ビデオカメラが遅延なく動作しリアルタイムに見つめあっている状態を Live、遅延ありでリアルタイムでなく見つめあっている状態を Replay と呼ぶ。本論文では Live と Replay 時の脳波データをそれぞれ共感、非共感状態のラベルがついたデータとして利用した。

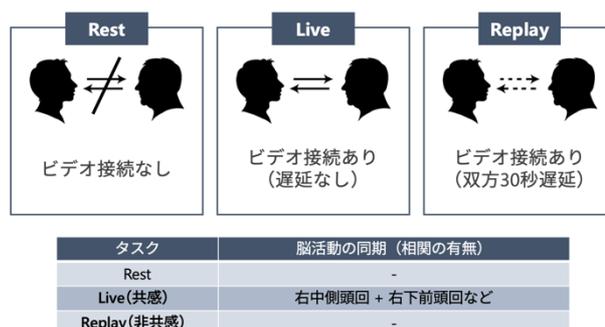


図1 見つめ合い課題の概要

3. 提案手法

3.1 データ分割

本実験で用いたデータは図2に示すような、1クラス1データあたり30秒、6000pointのデータである。機械学習を用いた脳波データからの Arousal と Valence による感情認識タスクにおいて脳波データを3-12秒の Window サイズで切り出す処理の有効性が示されていた[2]ため、今回は700point (約3.5秒)ごとに切り出す処理を行った。そして700pointで1データとして扱うこととした。

3.2 統計特徴量算出

Deep Learningを用いた脳波データからの感情認識タスクにおいて、時系列情報を1つの統計特徴量に落とし込むことの有効性が示されている[3]。今回は、3.1で切り出した700pointごとに、最大値・最小値・平均値・中央値・標準偏差・分散・レンジ(最大値-最小値)・歪度・尖度の9つの統計特徴量を算出した。全電極19チャンネルに対して9つの特長量、したがって1データあたり計171の特徴量を算出した。

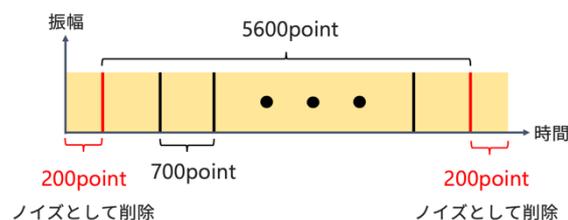


図2 データ分割の概要

Empathy Analysis of Shared Attention using Electroencephalogram

Daichi Igarashi[†], Tomoharu Nagao[‡][†] Faculty of Environment and Information Sciences, Yokohama National University[‡] Graduate School of Environment and Information Sciences, Yokohama National University

3.3 ヒストグラムの類似度計算

3.2で算出した171の特徴量それぞれに対して、以下の式により2クラス間のヒストグラムの類似度を算出した。これは、類似度が低い特徴量ほど2クラスでの差があり、分類に寄与する可能性が高いという仮説に基づき設定した。

$$\frac{\sum_i^{bin} \min(h1_i, h2_i)}{N} \quad (1)$$

(1)式における $h1_i, h2_i$ は、共感・非共感クラスの*i*番目の特徴量におけるヒストグラムを、 N は1クラスのデータ数をそれぞれ表し、ヒストグラムの bin 数は230とした。

4. 実験

4.1 実験設定

3.で述べた前処理を行った後のデータは、各クラス2304データとなった。これを8分割して288データをテストデータとして確保し、残りを1728と288データに分けて7分割交差検証を行った。実験は、1) 171個ある特徴量を、類似度が1番低いもの1つを選択した状態の精度を算出、その後類似度の低い順に1つずつ特徴量を増やして精度を算出、2) Simple GAを用いて組み合わせ最適化を行う、3) 類似度に基づく圧を加えたGAを用いる、の3種類を行った。このとき、検証データの平均精度が一番高い場合のテスト精度と、そのとき使用された特徴量の組み合わせを求めた。

識別モデルはSVMを用いた。パラメータはグリッドサーチにより探索し、C: 10, gamma: 1.0, kernel: rbfとした。

4.2 結果

実験1, 2, 3の結果を表1に上から順番に示す。テスト精度はそれぞれ、1) 類似度が低い順に32個の特徴量を使用した場合71.82%, 2) Simple GAを用いた場合57.93%, 3) 類似度に基づく圧を加えたGAによる組み合わせ最適化で72.24%であった。また、このとき使用された特徴量数は、1)が32個、2)が60個、3)が31個であり、1)と3)については平均値と中央値のみが選択されていた。

表1 テスト精度

	test(mean)	valid(mean)
実験1	0.7182 ± 0.004331	0.7043 ± 0.008994
実験2	0.5793 ± 0.003900	0.6011 ± 0.008866
実験3	0.7224 ± 0.004276	0.7123 ± 0.01006

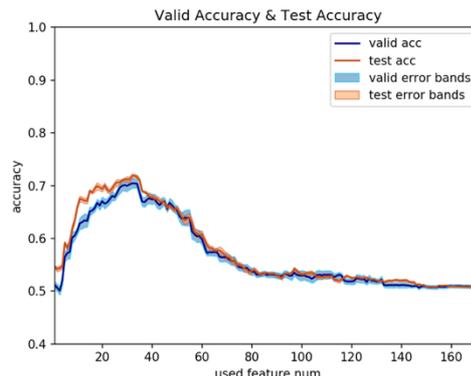


図3 実験1の精度の遷移グラフ

5. 考察

実験1, 3より、平均値と中央値の特徴量を類似度の低いものから30個程度用いた場合に、共感状態の分類が70%程度で行えることがわかった。図3および、実験1とは反対に、類似度の高いものから選択した予備実験で精度が低かった結果も受け、類似度の高いデータはノイズデータになりやすいことがわかった。従来の生理学的解析手法では共感・非共感状態の差が脳波のどこに現れるか解明されていないが、提案手法により、脳波の時系列情報における平均値と中央値に差があることを、機械学習の側面から示すことが出来た。

6. まとめ

本論文では機械学習を用いて脳波データから共感状態の分類を行うための手法を提案した。その結果、脳波における平均値と中央値に2状態の差があることを示すことが出来た。

参考文献

- [1] KOIKE, Takahiko, et al. Neural substrates of shared attention as social memory: A hyperscanning functional magnetic resonance imaging study. *Neuroimage*, 2016, 125: 401-412.
- [2] CANDRA, Henry, et al. Investigation of window size in classification of EEG-emotion signal with wavelet entropy and support vector machine. In: 2015 37th Annual international conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, 2015. p. 7250-7253.
- [3] TRIPATHI, Samarth, et al. Using Deep and Convolutional Neural Networks for Accurate Emotion Classification on DEAP Dataset. In: Twenty-Ninth IAAI Conference. 2017.