

サーモグラフィより観測した呼吸パターンからの ストレス推定への深層学習の応用

1255103 笥 拓也 【 コンピュータ構成学研究室 】

An Application of Deep Learning to Stress Estimation Based on Breathing Patterns Through Thermography

1255103 Takuya Kakehi 【 Advanced Computer Engineering Lab. 】

1 はじめに

近年、心拍数や心拍変動、脳波等の生体信号を用いてストレスを推定する手法が提案されている [1]。しかし、従来の手法では、生体信号の計測に接触型センサを用いる必要があり、日常的なストレスの推定が困難である。一方、非接触型センサを用いたストレス推定法についても研究され、赤外線カメラより観測した呼吸パターン (RVS) に基づくストレス推定法 [2] が提案された。

本稿では、文献 [2] の追検証により明らかとなった課題に対して、データセットと学習モデルの2つの側面から RVS に基づくストレス推定の精度向上に向けた深層学習の応用法について検討する。

2 RVS に基づくストレス推定の課題

RVS に基づくストレス推定の流れを図1に示す。まず、心理実験にて課題実行中の実験参加者8名の鼻孔領域サーモグラフィを撮影する。この際に、Visual Analog Scale を用いて課題実施後の主観ストレス強度を収集する (図1-1)。次に、鼻孔領域サーモグラフィから復元した呼吸信号のスペクトル分析によって RVS を生成し、主観ストレス強度は、個人毎に正規化して、k-means 法によってクラス数に応じてラベルに変換する (図1-2)。2クラスの場合、“None-stress(NS)” と “Stress(S)”，3クラスの場合、“None-stress(NS)”，“Low-level-stress(LS)”，“High-level-stress(HS)” がラベルとなる。そして、深層学習によってストレスを推定する (図1-3)。

文献 [2] では、2層2DCNNを用いた推定精度は2クラスで84.6%、3クラスで56.5%と報告され、非侵襲的かつ簡易的なストレス推定の可能性が示唆された。しかし、2クラス分類時のNSと3クラス分類時のLSの精度が十分に高くなかった。

そこで、本研究では、分類精度が高くない原因を調査するため、文献 [2] の著者から同一のデータセットを入手し、多層2DCNNや転移学習による推定を試みた。その結果、2クラス分類では、転移学習によって10%程度精度向上できた。一方、3クラス分類では、いずれも精度が向上しなかった。これらの結果を精査したとこ

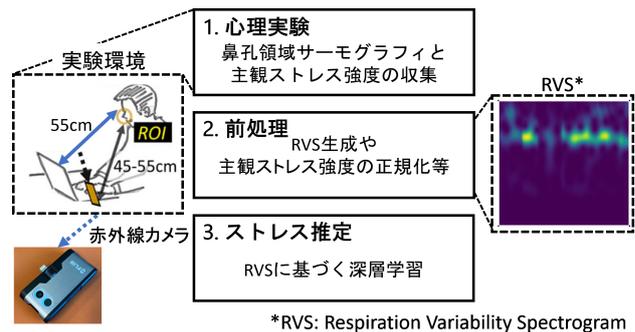


図1 RVS に基づくストレス推定の手続き

ろ、転移学習による3クラス分類時のLSのF値が数%であった。これは、データセットの質とモデル性能が不十分であったことに起因する可能性がある。そのため、本研究では、深層学習の枠組みにおけるデータセットと学習モデルの改善によってLSのF値向上を目指す。

3 RVS に着目した深層学習の応用法

データセット [2] に関して、RVSと主観ストレス強度は双方の個人差が大きいと予測されるため、より多くの参加者からデータを収集し、さらに、前処理によって個人差を緩和させる必要がある。加えて、個人毎に各ストレスのラベル数に偏りがあるため、データセットの均等化が必要と考えられる。また、モデル性能に関して、追検証時にはImageNet¹に基づく転移学習を適用したが、結果よりRVSに対する特徴抽出が十分ではなかったと予測されるため、事前学習タスクの改善が必要である。

本章では、上記のデータセットとモデル性能の改善点に着目して提案手法の検討を行う。

3.1 心理実験によるデータ収集

本研究における実験参加者は、健常な大学生11名(女性4名)であり、平均年齢は19.09(±0.30)歳であった。

実験手続きは、文献 [2] と同様に、安静状態を維持するための5分間のリラクセス期間とリラクセス直後の主観ストレス評価(Q)，そして、5分間の課題期間と課

¹<https://www.image-net.org/>

題直後のQを1セットとした4セット試行で構成した。課題は、それぞれ2段階の難易度の計算課題(Math)とストロープ課題(Stroop)で、各セットにて出題順をランダム化した。個人差の抑制および各ストレスクラスにおけるラベルの均等化のため、本研究では独自に、サーモグラフィ撮影時に顎台で顔を固定することに加え、各課題の難しい方の難易度を上げた。

赤外線カメラはFLIR ONE Gen3 for iOSを使用し、顎台使用時のディスプレイ距離は55cmで固定した。また、カメラ距離は45cm(±3.9cm)に設定した。

3.2 前処理およびデータセット構築

個人差抑制に向け、収集したデータに対して、以下の1と2の前処理を施し、データセットの均等化に関しては3の手法を適用した。さらに、4の手法によってF値の改善を試みた。

1. リラックス直後のQのベースライン化(Base)

個人によって、ストレスの解釈が異なるため、課題後のQとの差分を使用してラベルを作成する。

2. 課題開始冒頭30秒データの削除(Cut)

課題開始直後は緊張等により、呼吸が安定していない可能性があるため、cutによって個人毎に一貫したRVSを獲得する。

3. 不均質なデータセットの均等化(Bal.)

個人毎に少数派のラベルを多数派に合わせてランダムに複製し、全てのラベルを保持する参加者のデータのみ学習とテストに使用する。

4. 課題種類別にデータセットの分割(Sep.)

MathとStroopでは、認知されるストレス強度が異なるため、より効果的に弱いストレスを誘発している課題データセットを使用する。

3.3 深層学習における事前学習タスク

RVSは生体信号であるため、個人毎に特徴に偏りがあると考えられる。そこで、データセット[2]を基に既存モデルをファインチューニングし、最もロス値が減少した際の重みを用いて転移学習を行う(Xfer)。

4 評価と考察

本研究では、各提案手法の有効性について精度とLSのF値を評価指標として検証を行った。その後、有効性の高い手法を組み合わせ、データセット[2]との比較を行った。なお、深層学習モデルには2つの2DCNN(2層[2], 3層)と3つの既存モデルを使用した。

BaseとCut, Xferに関して、それぞれ適用しない場合に比べて、双方のクラスにおいて精度が向上した。また、Bal.は適用なしに比べ、F値が最大で11%向上したことから、これらの手法は有効性が高いと考えられる。一方、Sep.のStroopでは、F値が51~73%と他の手

法に比べて最も高くなったが、Sep.を適用することで、各ストレスのラベル数に偏りが生じるため、妥当な評価とは言えない。以上の結果より、BaseとBal., Cut,そして、Xferを適用することでF値の向上が期待される。しかし、Bal.のみ適用したデータセット[2]と比較したところ、全体の性能が劣る結果となった。

最終的に、本研究では、Bal.とBaseの組み合わせが最も良く、データセット[2]にBal.を適用した比較結果を一部抜粋して表1に示す。精度に関して、本研究では、全体的に低下する結果とはなかったものの、F値が飛躍的に向上した。データセット[2]のBal.の方が精度が高い理由として、学習とテストに8人中2人分のデータしか使用しておらず、データ数が少なかったことで個人差による影響を受けにくかったと考えられる。一方、本研究では、Bal.によって11人中4人とデータセット[2]の2人よりもデータ数が増え、さらに、Baseによって主観ストレス強度の個人差を抑制できたことでF値が向上したと考えられる。

表1 精度と“Low-level-stress”のF値の比較

	データセット [2]		本実験データ	
	精度	F 値	精度	F 値
2層2DCNN[2]	43.94	13.22	45.83	51.98
3層2DCNN	51.21	44.83	49.26	44.43
ResNet18	36.57	7.49	38.11	46.66
MobileNet-v3	55.26	1.59	45.57	46.78
EfficientNet-b0	52.56	1.25	35.95	34.52

5 おわりに

本研究では、RVSに基づくストレス推定においてLSのF値向上を目的にRVSに着目した深層学習の応用法について検討した。結果として、本研究のデータセットにて主観ストレス強度に対するベースラインを設け、ラベルの均等化をすることでF値が向上した。しかし、精度に関しては、データセット[2]より劣る結果となった。

今後は、ストレスの推定精度向上に向けて、呼吸パターンに加え、鼻先の温度や脈波等、複数の生体信号を用いた深層学習の手法について検討する必要がある。

参考文献

- [1] J. Healey, et al., “Detecting stress during real-world driving tasks using physiological sensors,” IEEE Trans. Intelligent Transportation Systems, Vol. 6, No. 2, pp. 156–166, Jun. 2005.
- [2] Y.Cho, et al., “DeepBreath: Deep learning of breathing patterns for automatic stress recognition using low-cost thermal imaging in unconstrained settings,” ACII, pp. 456–463, 2017.