

Real-time stress detection using Yuragi learning by multimodal integration of living-body information


大阪大学 大学院情報科学研究所 情報ネットワーク学専攻 村田研究室
博士前期課程 2年
吉田 理沙

情報ネットワーク学専攻修士論文発表会
2023年2月9日

1

研究背景と既存研究の課題

- 研究背景**
 - 労働環境や精神的負荷に基づく心理的疲労が問題
 - ストレス状態では交感神経が優位となり生体反応が発生
 - 生体情報とストレスの関係に着目した研究が盛ん
 - ストレス検知に有意な生体情報の研究^[1]
 - ウェアラブルデバイスから取得できる生体情報に着目
 - リアルタイムに生体情報を取得可能
 - 複数の生体情報を統合することで精度向上を実現^[2]
- 既存研究の課題**
 - ウェアラブルデバイスで得たデータにはノイズが含まれる
 - ストレスが生体情報に与える影響には個人差が存在
 - 判別に有用な生体情報は状況により異なる



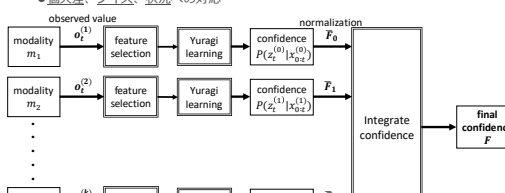
リストバンドデバイス

[1] C. Setz, B. Avrith, J. Schumm, R. La Marca, G. Tröster, and U. Ehlert, "Discriminating stress from cognitive load using a wearable EDA device," IEEE Transactions on Information Technology in Biomedicine, vol. 14, no. 2, pp. 412-417, 2009.
[2] P. Schmidt, A. Reiss, R. Baurichen, C. Marburger, and K. Van Laerehoven, "Stress-detecting using a multimodal dataset for wearable stress and affect detection," in Proceedings of the 2020 ACM International Conference on Multimodal Interaction, 2020, pp. 400-408.

2

研究目的とアプローチ

- 研究目的**
 - リアルタイムなストレス検知システムの構築
- アプローチ**
 - 特徴量選択手法、ゆらぎ学習、マルチモーダル統合処理の組み合わせ
 - 個人差、ノイズ、状況への対応

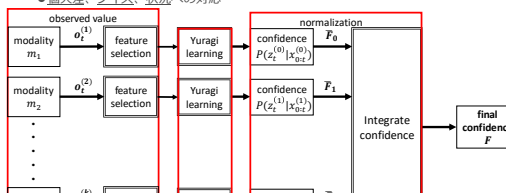


提案手法概要図

3

研究目的とアプローチ

- 研究目的**
 - リアルタイムなストレス検知システムの構築
- アプローチ**
 - 特徴量選択手法、ゆらぎ学習、マルチモーダル統合処理の組み合わせ
 - 個人差、ノイズ、状況への対応



提案手法概要図

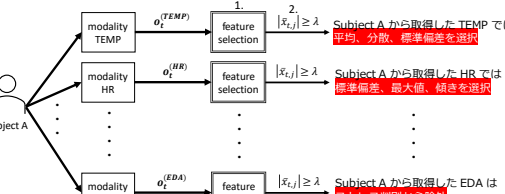
4

特徴量選択手法の仕組み

$\bullet o_t^{(TEMP)}$: TEMPの観測情報
 $\bullet x_{t,j}$: j番目の特徴量

- 個人に合わせてモダリティごとに特徴量を選択**

- 各モダリティの観測情報 $o_t^{(k)}$ から特徴量 $x_{t,j}$ を抽出
 - モダリティ: 体温 (TEMP)、心拍数 (HR)、皮膚電気活動 (EDA)、脈波、鼓動間隔など
 - 特徴量: 平均、分散、標準偏差、最小値、最大値、範囲、傾き など
- 閾値 λ を設定し、特徴量を選択
 - 全特徴量が閾値以下であれば、そのモダリティ自体を判別から除外



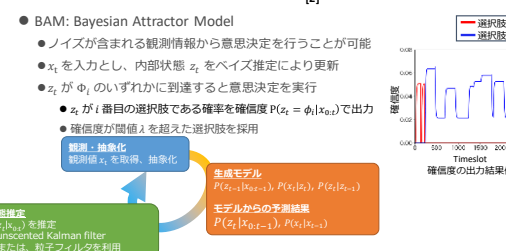
特徴量選択手法の例

5

ゆらぎ学習^[1]による判別の仕組み

- 脳の認知過程をモデル化した BAM_[2] に基づいた認知手法**

- BAM: Bayesian Attractor Model**
 - ノイズが含まれる観測情報から意思決定を行うことが可能
 - x_t を入力とし、内部状態 z_t をベイズ推定により更新
 - z_t が ϕ_i のいずれかに到達すると意思決定を実行
 - z_t が i 番目の選択肢である確率を確信度 $P(z_t = \phi_i | x_{0:t})$ で出力
 - 確信度が閾値 λ を超えた選択肢を採用

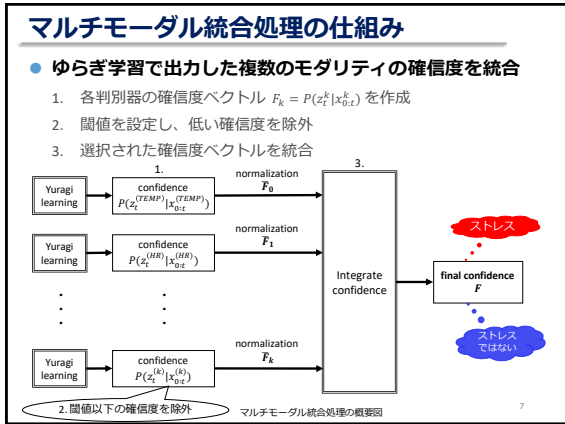


BAM 概要図

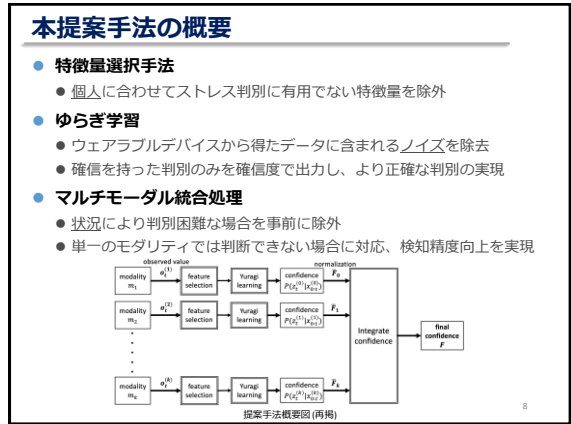
$\bullet x_t$: 時刻 t における観測値
 $\bullet z_t$: 時刻 t における認知状態
 $\bullet \phi_i$: 各選択肢に該当する典型的な観測値

[1] M. Murata and K. Yoshida, "Fluctuation-Induced Network Control and Learning," Springer, 2021.
[2] S. Bider, J. Brunberg, and S. E. Kiebel, "A Bayesian Attractor Model for Perceptual Decision Making," PLOS Computational Biology, vol. 11, Aug. 2015.

6



7



8

評価結果: データセットと評価方法

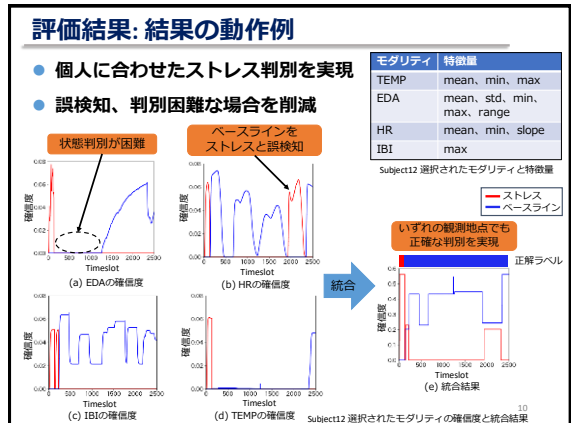
- 様々な温度環境で快適度を回答したデータ^[3]を取得
 - ウェアラブルデバイスから取得したモダリティ 8 種
 - 特徴量選択で特徴量を選択した 22 名を対象
 - ストレス状態とストレスではない(ベースライン)状態の判別
- 評価指標を元に累積分布で比較評価
 - 偽陰性率: $False\ negative\ rate = \frac{FN}{TP+FN+X}$
 - ストレスのラベルのうち、誤検知した割合
 - 偽陽性率: $False\ positive\ rate = \frac{FP}{TP+FP}$
 - ストレスと判別したうち、誤検知した割合
 - 判別不可率: $Unavailable\ rate = \frac{X}{TP+FN+X}$
 - ストレスのラベルのうち、確信度 0 を出力した割合

真の値	予測値			確信度 0
	ストレス	ベースライン	ベースライン	
ストレス	TP	FN	X	
ベースライン	FP	TN	Y	


モダリティ	特徴量
TEMP (体温)	mean, min, max
EDA (皮膚電気活動)	mean, std, min, max, range
phasicEDA (phasic筋)	
SNMAphasicEDA (下体重神経活動)	
tonicEDA (tonic筋)	
BVP (脈波)	
IBI (鼓動間隔)	
HR (心拍数)	

評価に用いたモダリティ


9



10



11



12

まとめと今後の課題

● まとめ

- 既存手法の課題に対応したストレス検知手法を提案
 - 特徴量選択手法、ゆらぎ学習、マルチモーダル統合処理
- 偽陰性率、偽陽性率の改善を達成
 - より正確な判別を実現

● 今後の課題

- 一部の被験者のストレスを判別できなかった
 - 既存手法との組み合わせによって特徴量数を増やし、選択肢の幅を広げる
 - 特徴量の選択やパラメータの更新による精度向上
- 異なる種類のストレスデータセットでの実証

13