

Extração de características a partir do dataset WESAD no apoio ao reconhecimento de estresse: Uma visão do estado da arte

Cícero C. Quarto (Pós-doutorando)
LSDi/PPGCC-UFMA

Prof. Dr. Francisco José da Silva e Silva (Supervisor)
UFMA/PPGCC-LSDi

Prof. Dr. Luciano Reis Coutinho
(LSDi/PPGCC-UFMA)

Resumo: O WESAD, um novo conjunto de dados multimodal disponível publicamente para estresse vestível e detecção de afeto, apresenta dados fisiológicos e de movimento, registrados de um dispositivo usado no pulso e no peito, de 15 sujeitos durante um estudo de laboratório. Considerando este contexto, este artigo se concentra em apresentar as características extraídas dos sinais baseadas no dataset público WESAD, às quais foram utilizadas na construção de modelos computacionais de aprendizado de máquina para apoiar o reconhecimento de estresse. Os resultados do estudo são trazidos através das Tabelas 1 e 2, contendo os trabalhos científicos prospectados e as extrações de características, respectivamente.

Abstract: WESAD, a new publicly available multimodal dataset for wearable stress and affect detection, presents physiological and movement data, recorded from a wrist-worn and chest-worn device, from 15 subjects during a laboratory study. Considering this context, this paper focuses on presenting the features extracted from the signals based on the public WESAD dataset, which were used to build machine learning computational models to support stress recognition. The results of the study are presented in Tables 1 and 2, containing the scientific papers and the feature extractions, respectively.

Tabela 1: Estudos acerca de detecção de estresse usando sinais fisiológicos e datasets públicos

Trabalhos	Autores	Datasets	Sinais fisiológicos	Sensores
Stress Detection Using Context-Aware Sensor Fusion From Wearable Devices	Rashid et al. (2023)	WESAD	EMG, ACC	Pulseira Empática E4 e RespiBAN
Stress Detection Using CNN on The WESAD Dataset	Benita et al. (2024)	WESAD	HRV	PPG
Introducing WESAD, a Multimodal Dataset for Wearable Stress and Affect Detection	Schmidt et al. (2018)	WESAD	ECG, EDA, BVP, EMG, Resp, ST	Sensor de pulso (Empática E4) e tórax (RespiBAN)

Fonte: O autor (2024)

Tabela 2: Características extraídas a partir do dataset WE-SAD aplicadas na construção de modelos de Machine Learning no apoio ao reconhecimento de estresse e afetos.

Autores	Características
Rashid et al. (2023)	ACC: $\mu\text{ACC}, i, \sigma\text{ACC}, i, i \in \{x, y, z, 3D\}$
	$ \int \text{ACC}, i , i \in \{x, y, z, 3D\}$
	f_x^y, j , onde $x = \text{ACC}$ e $y = \text{peak}$, $j \in \{x, y, z\}$
	EMG: $\mu\text{EDA}, \sigma\text{EDA}$
	rangeEDA (dynamic range of EMG)
	$ \int \text{EMG} $
	$\bar{\pi}$ (mediana de EMG)
	$P_x^{y'}, P_x^{y''}$, onde $x = \text{EMG}$, $y' = 10$ e $y'' = 90$ (Percentis)
	$\mu_x^{y'}$, onde $x = \text{EMG}$ e $y = f, f_{\text{EMG}}, f_{\text{EMG}}^{y'}$, onde $x = \text{EMG}$ e $y' = \text{peak}$ (média, mediana e frequência de picos, respectivamente)
	PSD (f_{EMG}), energia de sete bandas
	$\sharp_x^y$, onde $x = \text{EMG}$ e $y' = \text{peaks}$, número de picos
	$\mu_x^{y'}$, onde $x = \text{EMG}$ e $y' = \text{amp}$, $\sigma_x^{y''}$, onde $x = \text{EMG}$ e $y'' = \text{amp}$ (média e desvio padrão de amplitude de picos), respectivamente.
Benita et al. (2024)	Frequência Cardíaca (HR)
	LFBOXCOX (Componente de baixa frequência-box-cox transformado)
	MEDIANRR (Mediana dos intervalos RR)
	SD1BOXCOX (Desvio padrão 1-Box-Cox transformados)
	SDRR-REL-RR (Desvio padrão dos intervalos RR relativos)
Schmidt et al. (2018)	Sinal ACC: média μACC e desvio padrão σACC , com $i \in \{x, y, z\}$
	Sinal ECG/BVP: média, desvio padrão e $f_x(\text{energia em diferentes bandas de frequências})$
	Sinal EDA: média, desvio padrão, faixa dinâmica e número de picos no SCR (Nível de Condutância da Pele)

Fonte: O autor (2024)