



UNIVERSIDADE FEDERAL DO MARANHÃO

Laboratório de Sistemas Distribuídos Inteligentes

Programa de Pós-Graduação em Ciência da Computação (PPGCC)

SEMINÁRIO CIENTÍFICO II

Cícero Costa Quarto (Pós-Doutorando (UFMA/PPGCC/LSDi))

cicero@engcomp.uema.br

Luiz Gonzaga Penha (Mestrando (UFMA/PPGEE/LSDi))

luiz.penha@lsdi.ufma.br

São Luís – MA

2024

Agenda:

- Data: 17/05/2024;
- Local: Modalidade híbrida (Presencial: LSDi e Remota: [Google Meet](#));
- Horário: 14:00h

Resumo: Como parte integrante da construção do estudo acerca da compreensão do estado da arte sobre reconhecimento de emoções a partir de sensores disponíveis em dispositivos computacionais móveis vestíveis, o referente seminário científico tem por objetivo explorar os trabalhos de Wijasena et al. (2021) e Saganowski et al. (2022), intitulados, respectivamente, “[A Survey of Emotion Recognition Using Physiological Signals in Wearable Devices](#)” e “[Emotion Recognition for Everyday Life Using Wearables: A Systematic Literature Review](#)”, de forma a promover uma melhor visibilidade da importância, aplicabilidade e desafios deste campo de pesquisa no apoio à tomada de decisão dos profissionais da saúde e/ou áreas afins, assim como nortear perspectivas de direções futuras para o avanço do estado da arte em questão.

Metodologia: Na busca de contribuições para a construção do estudo acerca da compreensão do estado da arte sobre reconhecimento de emoções a partir de sensores disponíveis em dispositivos computacionais móveis vestíveis, a exploração dos trabalhos de Wijasena et al. (2021) e Saganowski et al. (2022) foi orientada através das questões de pesquisa que seguem: **QR1: Quais tipos de dados de sensores são relevantes para o reconhecimento de emoções?** **QR2: Quais tipos de emoções podem ser reconhecidos a partir destes dados?** **QR3: Quais métodos computacionais são empregados no reconhecimento de emoções a partir de dados de sensores?** **QR4: Quais são as métricas e critérios de avaliação no reconhecimento de emoções a partir de dados de sensores?** e **QR5: Qual o desempenho alcançado pelos métodos computacionais aplicados no reconhecimento de emoções a partir de dados de sensores?** Como resultado deste caminho metodológico, as Tabelas 1 e 2 sintetizam os respectivos aportes de Wijasena et al. (2021) e Saganowski et al. (2022) para o campo de reconhecimento de emoções a partir de sensores disponíveis em dispositivos computacionais móveis vestíveis.

Tabela I: Estado da arte sobre reconhecimento de emoções a partir de sensores disponíveis em dispositivos computacionais vestíveis

Origem dos eventos (Percepção)	Dados de sensores	Tipos de sensores	Emoções reconhecidas	Métodos computacionais de reconhecimento das emoções	Desempenho dos métodos no reconhecimento das emoções	Autores	Trabalhos Futuros Recomendados
Sinais Fisiológicos	ECG, HRV	Smartphone acoplado ao LaPatch (dispositivo portátil de canal único)	Fadiga mental	SVM ¹ , KNN ² , Naive Bayes (NB), LR ³	Validação cruzada média (65,37%)	Huang et al. (2018)	<p>1. o estado cansaço que é manipulado por um questionário pode ser diferente do estado de um ambiente de trabalho diário (por exemplo, excesso de trabalho devido a longas horas gastas no local de trabalho. Portanto, a validade desta pesquisa deve ser reforçada por uma análise num local de trabalho real no futuro.</p> <p>2. os resultados da</p>

1 Support Vector Machine

2 K-Nearest Neighbor

3 Logistic Regression

							nossa análise mostram que a frequência cardíaca é um indicador importante para o diagnóstico final de fadiga mental. No entanto, a frequência cardíaca pode ser influenciada por muitos fatores. Por exemplo, várias doenças (por exemplo, hipertireoidismo , miocardite,
--	--	--	--	--	--	--	---

							pericardite e condições (por exemplo, exercícios de alta intensidade podem causar taquicardia sinusal. Portanto, seria importante testar a nossa abordagem proposta em populações de pacientes com doenças crônicas (por exemplo, diabetes, hipertensão,
--	--	--	--	--	--	--	--

							doença coronariana) e em indivíduos com diferentes níveis de aptidão física no futuro.
BVP, ST	<u>Biosignal Kit de Pesquisa PLUX</u>	valênci a e excitação	KNN, RF ⁴	Média de dois cenários (96%)	Heinisch et al. (2018)	*** ⁵	
ECG, EDA, BVP, EMG, RESP, ST	► ⁶	diversão, estresse, meditação, recuperação	DT, RF, AdaBoost, LDA, KNN	Três classes (79%) Classe binária (92%)	Schmidt et al. (2018)	* ⁷	
PRV	<u>BIOPAC MP160; Huawei watch2</u> (wearable smartwatch)	estresse, não-estresse	Auto-relato com rotulagem de recursos	Acurácia: Vetor de recurso diferencial, Modelo usando PRV com auto-relato (91%)	Li et al. (2018)	(i) este modelo focou apenas no modelo de estresse agudo, enquanto a ausência de avaliação do	

4 Random Forest

5 Não recomendou trabalhos futuros

6 Artigo da ACM e não foi possível acessar, pois não é público.

7 Artigos da ACM Digital Library - não disponível publicamente

							estresse crônico é uma limitação deste estudo, uma vez que a avaliação do estresse crônico de uma pessoa reflete uma abordagem mais representativa do nível de estresse de uma pessoa. (ii) mais discussões técnicas sobre sinais PPG e ECG são bem-vindos como trabalhos futuros.
	HR	Smartwatch; pulseira de monitor de frequência	felicidade, tristeza, neutro	RF, LR	Acurácia: RF (78%) LR (71%)	Quiroz et al. (2018)	Estudos futuros devem olhar na duração de uso dos wearables (mais de 24

		cardíaca					horas ciclos) e duração da experiência de estímulos (agudos ou crônicos).
	ECG, HRV, HS ⁸	Wearable do tipo ômega; RM6240 Record ECG	descontração, tristeza, felicidade, irritação	SVM Otimizado para Algoritmo Genético	Especificidade (97,96%) Sensibilidade (99,32%)	Xiefeng et al. (2019)	***
	HR, HRV	Pulseira Empática E4	estresse	Bland-Altman Plots	Heart Rate (96%)	Menghini et al. (2019)	a) como sugerido por Laborde et al. (2017) , recomenda-se fortemente a inspeção visual dos dados coletados a partir dos sensores antes de calcular as medidas de HRV. b) sugerimos uma avaliação cuidadosa das condições antes e durante de cada gravação, assim como incluir períodos de adaptação

							antes de cada gravação para melhorar a estacionariedade dos dados. c) os dados do acelerômetro fornecidos pela Pulseira E4 e a circunferência do pulso dos participantes pode ser usado para estabelecer possíveis critérios de exclusão.
ST, BVP, HR, HRV	-	estresse	LDA, QDA, RF	LDA (87,4%) QDA (84,9%) RF (82,4%)	Siirtola (2019)	*	
PPG, GSR	-	diversão, tristeza, neutro	SVML, LDA, MN, DT, XGBoost, BLR	Melhor resultado SVML (96%), tristeza (91%)	Dominguez-Jiménez et al. (2020)	** ⁹	
ECG	Tablet NeXus-10 + Software Biotrace	valência, excitação, alegria, tristeza, tensão, paz	LS-SVM ¹⁰	valência positiva/negativa (82,78%), excitação alta/baixa (72,91%), quatro tipos de emoções	Hsu et al. (2020)	***	

9 Artigo da Scopus(Elsevier) - A base de dados é pública, mas não foi possível fazer o download do arquivo (erro de extensão de arquivo web)

10 Least Squares Support Vector Machine

					(61,52%)		
	HR	Smart Bracelet (Algoband F8)	neutro, felicidade, tristeza	KNN, RF, DT, GBDT ¹¹ , AdaBoost	feliz, tristeza, neutro GBDT (84% com K = 10)	Shu et al. (2020)	***
	EDA, HR	Watches Mobile Videos; Wearable Pupil Core ; Pulseira Empática E4	valênci, excitação	BLS ¹²	76,37% e 74,03% para v-e em CASE, 70,29% e 68,15 para v-e em MERCA	Zhang et al. (2020)	***
	EOG, EMG, GSR, BVP, ST, RESP	Smartphone, Smartwatch, Smartglasses	valênci, excitação	TTO ¹³ , VAE ¹⁴ , CNN ¹⁵ -transfer	excitação: TTO (88,71%), VAE (84,50%), CNN (91,29%). valênci: TTO (87,43%), VAE (83,12%), CNN (64%)	Li et al. (2020)	a) ampliar o escopo de nossos estudos analisando o impacto da adição, remover ou escolher modalidades de sensores e conjunto de dados específicos do domínio de origem. b) verificar a influência da quantidade de

11 Gradient Boosting Decision Tree

12 Broad Learning System

13 Train Target Only

14 Variational AutoEncoder

15 Convolutional Neural Networks

							dados de origem, número e granularidade das classes no domínio de origem, assim como adicionar diferentes tipos de séries temporais no domínio de origem, pois podem ser úteis para verificar se a nossa abordagem pode funcionar para aplicativos de destino que não usam dados de séries temporais não esparsas.
	HR, GSR, SKT	<u>Smartwatch Basis B1</u>	emoção positiva, engajamento, relação, significado, realização	Classificação Binária	Entre 55,8% e 61,3% para as cinco emoções PERMA ¹⁶	Feng et al. (2020)	1. novos estudos com um tamanho de amostra maior são necessários, assim como esforços substancialmente maiores para organizar o estudo para

16 Positive emotion, Engagement, Relationship, Meaning, Accomplishment

							participação a longo prazo; 2. a categorização dos quatro estados usando frequência cardíaca e caminhada são apenas uma definição simplificada do diário de atividades, espera-se, desta forma, extrair informações contextuais mais ricas para fornecer uma estimativa mais eficaz do estado psicológico, como bem-estar, com técnicas avançadas de detecção, como uma classificação mais precisa das atividades físicas, mais dimensões de dados fisiológicos; 3.
--	--	--	--	--	--	--	---

							embora significativo, as variações explicadas para cada dimensão PERMA (Positive emotion, Engagement, Relationship, Meaning, Accomplishment) na análise de regressão ainda são relativamente baixas, desta forma, métodos avançados de análise de dados, juntamente com uma amostra maior, pode ajudar a eficácia dos modelos.
HRV	Pulseira Empática E4, Samsung Gear S2 , Firstbeat Body-Guard2 , BITalino (r)evolution board , Polar H10 , Polar OH1	linha de base, estresse, em repouso	Bland-Altman Plots	-	Umair et al. (2021)	***	

	ECG, GSR, SKT	 ¹⁷	felicidade, tristeza, raiva, medo	KNN, LDA, LR, RF, DT, SVM	Dependente do assunto (96,33%). Independente do assunto (76,67%)	Miranda et al. (2021)	Em trabalhos futuros, os autores planejam desenvolver um banco de dados específico utilizando equipamentos profissionais e sua plataforma de hardware em desenvolvimento, que inclui dispositivos vestíveis discretos como sensores fisiológicos inteligentes.
--	------------------	---	---	------------------------------	---	--------------------------	--

17 Miranda et al. (2021) usaram o database público MAHNOB

Tabela II: Significado das siglas dos sinais fisiológicos/sensores.
Fonte: Os autores (2024).

SIGLA	SIGNIFICADO
EEG	ElectroEncefaloGram (Eletroencefalograma)
BVP	Blood Volume Pulse (Pulso de Volume Sanguíneo)
HRV	Heart Rate Variability (Variabilidade da Frequência Cardíaca)
GSR	Galvanic Skin Response/Resistance (Resposta/Resistência Galvânica da Pele)
HR	Heart Rate (Frequência Cardíaca)
EDA	ElectroDermal Activity (Atividade Eletrodérmica)
PPG	Photoplethsmograph (Fotopletismografia)
SKT	Skin Temperature (Temperatura da Pele)
RESP	Respiration (Respiração)
EMG	ElectroMyoGraphy (Eletromiografia)
PRV	Pulse Rate Variability (Variabilidade da Taxa de Pulso)
ECG	ElectroCardioGram (Eletrocardiograma)
EGO	ElectroOcculoGraphy (Eletrooculografia)

Referências

- Feng, X., Lu, X., Li, Z., Zhang, M., Li, J., & Zhang, D. (2020). Investigating the Physiological Correlates of Daily Well-being: A PERMA Model-Based Study. *The Open Psychology Journal*, 13(1).
- Heinisch, J. S., Hübener, I., & David, K. (2018, March). The Impact of Physical Activities on the Physiological Response to Emotions. In 2018 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops) (pp. 824-829). IEEE.
- Hsu, Y. L., Wang, J. S., Chiang, W. C., & Hung, C. H. (2017). Automatic ECG-based emotion recognition in music listening. *IEEE Transactions on Affective Computing*, 11(1), 85-99.
- Huang, S., Li, J., Zhang, P., & Zhang, W. (2018). Detection of mental fatigue state with wearable ECG devices. *International journal of medical informatics*, 119, 39-46.
- Li, F., Xu, P., Zheng, S., Chen, W., Yan, Y., Lu, S., & Liu, Z. (2018). Photoplethysmography based psychological stress detection with pulse rate variability feature differences and elastic net. *International Journal of Distributed Sensor Networks*, 14(9), 1550147718803298.
- Li, F., Shirahama, K., Nisar, M. A., Huang, X., & Grzegorzek, M. (2020). Deep transfer learning for time series data based on sensor modality classification. *Sensors*, 20(15), 4271.
- Menghini, L., Gianfranchi, E., Cellini, N., Patron, E., Tagliabue, M., & Sarlo, M. (2019). Stressing the accuracy: Wrist-worn wearable sensor validation over different conditions. *Psychophysiology*, 56(11), e13441.
- Miranda, J. A., F. Canabal, M., Gutierrez-Martin, L., Lanza-Gutierrez, J. M., Portela-Garcia, M., & Lopez-Ongil, C. (2021). Fear recognition for women using a reduced set of physiological signals. *Sensors*, 21(5), 1587.
- Quiroz, J. C., Geangu, E., & Yong, M. H. (2018). Emotion recognition using smart watch sensor data: Mixed-design study. *JMIR mental health*, 5(3), e10153.
- Schmidt, P., Reiss, A., Duerichen, R., Marberger, C., & Van Laerhoven, K. (2018, October). Introducing wesad, a multimodal dataset for wearable stress and affect detection. In Proceedings of the 20th ACM international conference on multimodal interaction (pp. 400-408).
- Siirtola, P. (2019, September). Continuous stress detection using the sensors of commercial smartwatch. In Adjunct proceedings of the 2019 ACM international joint conference on pervasive and ubiquitous computing and proceedings of the 2019 ACM international symposium on wearable computers (pp. 1198-1201).
- Shu, L., Yu, Y., Chen, W., Hua, H., Li, Q., Jin, J., & Xu, X. (2020). Wearable emotion recognition using heart rate data from a smart bracelet. *Sensors*, 20(3), 718.
- Umair, M., Chalabianloo, N., Sas, C., & Ersoy, C. (2021). HRV and stress: A mixed-methods approach for comparison of wearable heart rate sensors for biofeedback. *IEEE Access*, 9, 14005-14024.
- Xiefeng, C., Wang, Y., Dai, S., Zhao, P., & Liu, Q. (2019). Heart sound signals can be used for emotion recognition. *Scientific reports*, 9(1), 6486.

Zhang, T., El Ali, A., Wang, C., Hanjalic, A., & Cesar, P. (2020). Corrnet: Fine-grained emotion recognition for video watching using wearable physiological sensors. Sensors, 21(1), 52.