




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 1: Tabela síntese do estado da arte sobre reconhecimento de emoções a partir de sensores disponíveis em dispositivos computacionais vestíveis a partir do trabalho de Saganowski et al. (2022).
 Fonte: Os autores (2024).

Origem dos eventos (Percepção)	Dados de sensores	Tipos de sensores vestíveis	Emoções reconhecidas	Métodos computacionais de reconhecimento das emoções	Desempenho dos métodos no reconhecimento das emoções	Autores	Trabalhos futuros
Sinais Fisiológicos	EEG ¹ , BVP ²	Emotiv Insight , Empatica E4 Wristband	(valência, excitação) felicidade, tristeza, neutro, raiva, surpreso, relaxado, nervoso	Classificador LSTM ³ Otimizado usando algoritmo DE ⁴	Acurácia 77,68%	Nakisa et al. (2018)	1. Explorar um novo desenvolvimento de algoritmo CE (como Particle Swarm Optimization (PSO) e Evolução Diferencial (DE) para superar o problema da convergência prematura e melhorar ainda mais o desempenho da classificação de emoções; 2. Além disso, como o tempo

1EletroEncefaloGram (Eletroencefalograma)
 2Blood Volume Pulse (Pulso de Volume Sanguíneo)
 3Long Short-Term Memory
 4Diferencial Evolution

							de processamento do DE é mais caro, isso pode ser reduzido usando computação paralela e/ou em nuvem.
	VFC ⁵ , GSR ⁶	Smartphone , Smartwatch	(valência, excitação) alegria, tristeza, estresse, calma	LR ⁷ , DT, SVM, RF	Acurácia DT: 72% (valência) e 67,75% (excitação); LR: 67,05% (valência) e 70,59% (excitação); SVM: 72,73% (valência) e 92,08% (excitação); RF: 75,57% (valência) e 83,77% (excitação)	Setiawan et al. (2018)	O desempenho satisfatório de classificação do sistema proposto superou o trabalho anterior em 20% em termos de valência e excitação. Entretanto, o desempenho ainda pode ser melhorado através do desenvolvimento de métodos mais confiáveis e avançados para taxas muito baixas.
	HR ⁸ , BVP, IBI ⁹ ,	Pulseira	diversão, neutro,	Cubic KNN,	Acurácia	Saxena et al.	*11

⁵Heart Rate Variability (Variabilidade da Frequência Cardíaca)

⁶Galvanic Skin Response/Resistance (Resposta/Resistência Galvânica da Pele)

⁷Logistic Regression

	EDA ¹⁰	Empática E4	raiva, tristeza, medo	Ensemble Bagged Trees, Gaussian SRV, Ensemble Boosted Trees	HR (CubicKNN): 77,21%; EDA (Cubic KNN): 84,17%; BVP (Cubic KNN): 75,23% ; HR+EDA (Ensemble Bagged Trees): 82,5%; HR+BVP (Gaussian SRV): 81,2%; BVP+EDA (Ensemble Boosted Trees): 83,8%; HR+BVP (Cubic KNN): 87%	(2020)	
	EDA, SKT ¹² , HR	Pulseira Empática E4	felicidade, tristeza, raiva, dor	DT	Acurácia 64,66%	Pollreisz e TaheriNejad (2017)	
	EDA, SKT, BVP	Pulseira Empática E4	valência e excitação (neutro, raiva, alegria, medo, tristeza,	Algoritmo LS ¹³ -SVM	Acurácia: Em geral 75,56%; HANV ¹⁴ : 82,67%; HAPV ¹⁵ : 69,78%; LANV ¹⁶ +LAPV ¹⁷ :	Zhao et al. (2018)	(i) Planejar adicionar outras modalidades em conjunto para interpretar

8Heart Rate (Frequência Cardíaca)

9Inter Beat Interval (Intervalo entre Batimentos)

10EletrDermal Activity (Atividade Eletrodérmica)

11Não recomendou trabalhos futuros

12Skin Temperature (Temperatura da Pele)

13Least Squares

14High Arousal Negative Valence (fear: medo, anger: raiva, agitation: agitação)

15High Arousal Positive Valence (happy: feliz, excited: excitado)

			relaxado)		75,56%		estados emocionais, como informações audiovisuais, ou seja, expressões faciais, gesto, voz e informações contextuais do ser humano, que ajudará a compreender as emoções humanas mais precisamente; 2. Combinar o sistema proposto com celular Android para reconhecer emoções em tempo real.
	EDA, PPG ¹⁸ , GSR, ST, BVP, HR, HRV ¹⁹	Pulseira Empática E4	valência e excitação (neutro, felicidade, tristeza)	KNN, Algoritmo DTW ²⁰ Multidimensional (MD-DTW)	Acurácia 65,6%	Albraikan et al. (2019)	a) Integrar mais recursos à proposta, incluindo medição contínua e não

¹⁶Low Arousal Negative Valence (bored: entediado, mounful: triste)

¹⁷Low Arousal Positive Valence (pleasure: prazer, relaxed: relaxado)

¹⁸PhotoPlethsmoGraph (Fotopletismografia)

¹⁹Heart Rate Variability (Variabilidade da Frequência Cardíaca)

²⁰Dynamic Time Warping

							invasiva da pressão arterial; b) Implementar a proposta de análise e classificação de emoções em um dispositivo móvel, como um celular Android; c) O sistema poderia ser combinado com uma combinação de emoções e multimídia para aproveitar o reconhecimento de emoções em outras tecnologias digitais, como jogos de computador, educação especial e redes sociais.
	GSR, IBI, BVP, RESP ²¹ , EMG ²² , ST ²³	Smartwatch	valência e excitação	MIL (Multiple Instance Learning - Aprendizagem	Acurácia valência: mi-SVM (62,1%), MI-SVM	Romeo et al. (2022)	Ampliar a abordagem baseada em MIL em um cenário

21Respiration (Respiração)

22ElectroMyoGraphy (Eletromiografia)

				de Múltiplas Instâncias); algoritmos EMDD-SVM (Expectation Maximization Diverse Density); mi-SVM e MI-SVM	(63,6%), EMDD-SVM (56,6%). excitação: mi-SVM (58,3%), MI-SVM (58,5%), EMDD-SVM (58,9%)		diferente. Isto envolver <i>modelar, discriminar e localizar</i> emoções auto-relatadas. Seguindo essa direção, planejamos considerar experimentos nos quais possa ser possível validar os rótulos de instâncias previstos na MIL com uma espécie de aterramento. Identificar quando a resposta emocional ocorre dentro do rótulo de tempo poderia informar ainda mais a personalização que a tecnologia pode proporcionar à
--	--	--	--	---	---	--	--

							pessoa. Por exemplo, no caso de reabilitação física, saber quando uma pessoa fica ansioso durante um exercício pode ajudar o sistema de reabilitação a compreender que parte do exercício de rotina a pessoa pode ter dificuldades psicológicas, ajudando assim as intervenções médicas por parte dos profissionais de saúde.
	HR	Polar H7 (sensor torácico)	humor	Deep Learning (LSTM - Long Short Term Memory Network) combinado com GMM (Gaussian Mixture Model) e SVM -	Acurácia LSTM (71% a 73%); LSTM+SVM (70% a 74%); LSTM+GMM (70% a 72%)	Tizzano et al. (2020)	Desenvolvimentos futuros incluem a criação de um conjunto maior de dados, tanto em termos de indivíduos recrutados e da

				LSTM+SVM; LSTM+GMM			quantidade de dados para cada participante.
	EDA	Q-sensor	alegria, tédio, aceitação	Wavelet+SVM	Acurácia: 77%; AUC: 90%; Precision: 84%; Recall: 77%	Feng et al. (2018)	1. Desenvolvimento de um sistema automatizado capaz de processar os dados em tempo real; 2. Devido à limitação dos conjuntos de dados disponíveis, a criação de um conjunto de dados mais abrangente será necessário para pesquisas futuras para que possamos comparar a diferença entre grupos não-autistas e autistas em relação a reação emocional durante diferentes estímulos sociais; 3. Seria

							relevante envolver várias outras emoções nos experimentos como raiva, tristeza e surpresa.
	HR	Pulseira de frequência cardíaca Mio Link - 1Hz; Smartphone+Aplicativo Androide	medo, raiva, tristeza, neutro, felicidade	SVM+DWT (Discrete Wavelet Transform)	Acurácia: 79%	Nguyen et al. (2017)	Combinar sinais de frequência cardíaca com outros sinais corporais, como frequência respiratória, fluxo de oxigênio no sangue (que pode ser coletado de outros dispositivos vestíveis) para melhorar os resultados.
	HR, HRV	Pulseira com sensor biométrico Silmee TMW20	felicidade, raiva, relaxado, tristeza, neutro	Modelos de Regressão em Painel de Efeitos Aleatórios	Análise de significância das variáveis independentes (emoções), matriz de correlação; VIF (Fator de Inflação de Variância < 10; Análise de	Kadoya et al. (2020)	a) pesquisas futuras precisam ser direcionada para encontrar um impacto mais generalizado dos estados emocionais na

					Multicolinearidad e, <i>p-valor</i>. O modelo demonstrou que a emoção “felicidade” está significativamente relacionada com a produtividade dos funcionários.	produtividade dos trabalhadores; b) Dado que o âmbito do presente estudo se limitou aos trabalhadores de linha onde as competências técnicas eram maioritariamente e necessária para realizar o trabalho, seria interessante observar se as condições emocionais influenciam diferentes funções em outras áreas funcionais onde é necessário conhecimento sofisticado; c) Estender a pesquisa a outros setores onde os funcionários trabalham em um ambiente
--	--	--	--	--	---	---

							estressante, como transporte e serviços de saúde.
	PPG, EDA ,HR, AVNN, SDNN, rMSSD, pNN50, LF, HF, RD, AVSCL	Biopac BioNomadix MP150 , Pulseira Empatica E4 Wristband	excitação e valência	Machine Learning method (Support Vector Machine – SVM)	precisão em torno de 70% para excitação e 66% para valência	M. Ragot et al. , 2017	
	EDA, IBI, VFC, FC, ST	Shimmer GSR+ , Polar H10 , Pulseira Empatica E4	excitação e valência	ML: Random Forest (maior sucesso), Support Vector Machine, k-Nearest Neighbours e Gaussian Naive Bayes)	accuracy de 65 %	R. Wampler et al. , 2019	
	ECG	sensor AD823 , termistor NTC	felicidade, raiva, medo e tristeza	Machine Learning	A precisão da detecção de emoções foi de 48% para felicidade, 41,5% para raiva, 27% para medo e 29,3% para tristeza	Long Hu et al. , 2018	
	FC, TC, GSR,	-	medo, raiva, surpresa e excitação	ML(KNN, DFA e MBP)	Acurácia: KNN: Tristeza: 70,4% Raiva: 70,8% Surpresa: 73,9%	Lisetti et al. , 2004 .	Realização de experimentos para elicitaremoções e estados

					Medo: 80,9% Frustração: 78,3% Excitação: 69,6% MBP: Tristeza: 88,9% Raiva: 91,7% Surpresa: 73,9% Medo: 85,6% Frustração: 77,3% Excitação: 87,0%		relacionados à condução, como frustração/raiva, pânico/medo e sonolência, enquanto os participantes estão dirigindo
	IBI,HR,GSR,ST	Microsoft Band 2	Valencia, Arousal e prevalência(dom inância)	ML: MIL(multiple Instance Learning),NB,R F,SVM	Acurácia, F1	Romeo et al. 2022	Estender a abordagem baseada em Aprendizado de Múltiplas Instâncias (MIL) para localizar e discriminar emoções autorrelatadas, possibilitando a validação das etiquetas previstas pelo MIL com um conjunto de dados totalmente anotado. Explorar a aplicação da

							abordagem MIL em um cenário de formulação multi-instância e multi-rótulo, onde a resposta emocional é descrita por múltiplas instâncias e associada a múltiplos rótulos de classe. Investigar a possibilidade de mapear as perspectivas dimensionais da emoção utilizando a abordagem MIL, formulando o problema como uma tarefa de regressão multi-instância.
	BVP,EDA,FC,ST	Empatica E4	Felicidade,Tristeza,Raiva,Neutralidade	ML(Supervisionado)	-	Jahangir et al. 2020	Construção de modelo de valência-Arousal

							individualizado a partir de dados de engajamento social para melhorar a precisão na classificação emocional Integrar a coleta de dados comportamentais e sociais em um aplicativo de smartphone e realizar testes de classificação dos dados para treinar um classificador que possa determinar a atividade atual do usuário com base nos dados de aceleração.
	ECG	RF-ECG	raiva, medo	ML: LDA(análise discriminante Linear)	Acurácia: 3 características 37,64%, 11 características 61,79%	Rattanyu et al. 2010	Combinação de mais sinais biológicos, como a Respiração (RESP) e a temperatura da

							pele para melhorar a precisão no reconhecimento de emoções
	ECG,	RF-ECG (biosensor)	raiva,medo,tristeza,alegria,nojo	ML: LDA, A-KNN	Acurácia Three Features Approach Anger 68.57 % Fear 61.25 % Sadness 57.14 % Sadness 64.38 % Neutral 60.53 % Joy 56.79 % Total 61.44 % Eleven Features Approach Anger 60.00 % Fear 32.50 % Disgust 25.71 % Sadness 45.21 % Neutral 31.58 % Joy 28.40 % Total 37.23 %		Combinação de mais sinais biológicos como o (RESP) e temperatura da pele para melhorar a precisão no reconhecimento de emoções Investigação de novos serviços personalizados com base nas emoções reconhecidas
	ECG	BC1 -XYZlife (bio-clothing) - Kinpo inc.	Tristeza, Raiva, Medo, Felicidade	Análise de séries temporais, frequência, Mean Score, algoritmos para separação	Acurácia : 25% para medo , para as demais ~50% Emoção: Tristeza (Sad)		Investigar a aplicação de algoritmos de ML para a classificação e reconhecimento de emoções com base nos dados

					Sujeitos Desencadeados: 4 de 5 Pontuação Média: 1.8 ± 1.7 Precisão do Reconhecimento: 50% Emoção: Raiva (Angry) Sujeitos Desencadeados: 4 de 5 Pontuação Média: 2.8 ± 1.6 Precisão do Reconhecimento: 50% Emoção: Medo (Fear) Sujeitos Desencadeados: 4 de 5 Pontuação Média: 2.4 ± 1.5 Precisão do Reconhecimento: 25% Emoção: Felicidade (Happy)		de variabilidade de frequência cardíaca Explorar mais técnicas para extração de características e modelos de análise para melhorar a precisão do reconhecimento de emoções
--	--	--	--	--	---	--	--

					Sujeitos Desencadeados: 4 de 5 Pontuação Média: 3.6 ± 1.1 Precisão do Reconhecimento: 50%		
	ECG,HRV	sensor vestível	Tristeza, raiva, medo, felicidade e relaxamento	PCA, ML: SVM	Acurácia para 2 estados emocionais (positivo , negativo): para todas as características 70,4% para características selecionadas por meio do PCA 71,4%, Acurácia : para 5 estados emocionais (medo, raiva,felicidade,tri steza, relaxamento): para todas as características 52% e para 5		Investigar e comparar diferentes técnicas de extração de características de HRV para o reconhecimento emocional. Considerar outros sinais fisiológicos como condutividade da pele.

					característica por meio do PCA (CVRR, LF, HF, HFratio, SD1)) 56,9%		
	EDA,GSR,BVP, HR,ST	Empatica E4	Neutra, Felicidade, tristeza,medo	ML	não apresenta resultados , somente uma comparação entre os aplicativos utilizados		Integrar os feedback emocionais em ferramentas como aplicativos , jogos etc. explorar o uso do sistema de reconhecimento de emoções em outras áreas tecnológicas, como jogos de computador, educação especial e redes sociais, para ampliar o impacto e as aplicações práticas do sistema
	EDA,HR,ST,EN V- NOISE,UV,GPS	Smartphone sensors , Microsoft	Escala de valencia	ML: Ensemble Algorithms “Stacking ” -	F-measure 0.84 and Accuracy %86		investigar o impacto de outras variáveis

	, pressão do ar	Wristband 2		SVM, RF,KNN,NB			ambientais, além das consideradas no estudo, nas respostas fisiológicas e emocionais dos participantes Explorar o uso de técnicas avançadas de aprendizado de máquina, como redes neurais profundas ou aprendizado por reforço, para melhorar a precisão na previsão de estados emocionais com base nos dados multimodais coletados. validações externas do modelo desenvolvido em diferentes conjuntos de dados para
--	-----------------	-----------------------------	--	-------------------	--	--	--

							avaliar sua generalização e robustez
Variados	HR, SGR, temperatura corporal, mobilidade, NV-NOISE, UV, air pressure, localização	Smartphone sensors , Microsoft Wristband 2	Self-Assessment-Manikin (SAM) escala de valencia	ML e DL: MLP, CNN-LSTM,RNN	MLP All 0.734 0.728 0.729 72.9 0.95975 Body 0.654 0.621 0.63 62.2 1.264 Environment 0.424 0.428 0.424 42.6 1.54 Location 0.59 0.605 0.58 60.2 1.22 CNN All 0.818 0.79 0.787		Explorar a utilização de técnicas de transfer learning para melhorar a generalização dos modelos de classificação de emoções, especialmente considerando a variação entre indivíduos. Investigar a aplicação de técnicas de interpretabilidade e de modelos de deep learning para entender como as decisões de classificação são tomadas, Explorar a inclusão de mais

					78.6		modalidades de dados sensoriais para enriquecer a representação das emoções,
					0.788		
					Body		
					0.734		
					0.712		
					0.709		
					70.8		
					1.01		
					Environment		
					0.529		
					0.47		
					0.468		
					46.5		
					1.41		
					Location		
					0.79		
					0.761		
					0.769		
					78.7		
					0.99		
					CNN-LSTM		
					All		
					0.927		
					0.95		
					0.949		
					94.7		
					0.291		
					Body		
					0.881		
					0.878		
					0.874		
					87.3		
					0.6		
					Environment		

					0.607		
					0.593		
					0.574		
					59.7		
					1.18		
					Location		
					0.655		
					5.586		
					0.621		
					64		
					1.03		

Referências

- A. Albraikan, D. P. Tobon, and A. El Saddik, "Toward user-independent emotion recognition using physiological signals," *IEEE Sensors J.*, vol. 19, no. 19, pp. 8402–8412, Oct. 2019.
- B. Nakisa, M. N. Rastgoo, A. Rakotonirainy, F. Maire, and V. Chandran, "Long short term memory hyperparameter optimization for a neural network based emotion recognition framework," *IEEE Access*, vol. 6, pp. 49 325–49 338, 201.
- B. Zhao, Z. Wang, Z. Yu, and B. Guo, "EmotionSense: Emotion recognition based on wearable wristband," in *Proc. IEEE SmartWorld Ubiquitous Intell. Comput. Adv. Trusted Comput. Scalable Comput. Commun. Cloud Big Data Comput. Internet People Smart City Innov.*, 2018, pp. 346–355+.
- D. Pollreisz and N. TaheriNejad, "A simple algorithm for emotion recognition, using physiological signals of a smart watch," in *Proc. IEEE 39th Annu. Int. Conf. Eng. Med. Biol. Soc.*, 2017, pp. 2353–2356.
- F. Setiawan, Khowaja, S. A., Prabono, A. G., Yahya, B. N., & Lee, S. L. (2018, July). A framework for real time emotion recognition based on humans using pervasive device. In *2018 IEEE 42nd Annual Computer Software and Applications Conference (COMPSAC)* (Vol. 1, pp. 805-806). IEEE.
- P. Saxena, S. Dabas, D. Saxena, N. Ramachandran, and S. I. Ahamed, "Reconstructing compound affective states using physiological sensor data," in *Proc. IEEE 44th Annu. Comput. Softw. Appl. Conf.*, 2020, pp. 1241–1249.
- Romeo, L., Cavallo, A., Pepa, L., Bianchi-Berthouze, N., & Pontil, M. (2019). Multiple instance learning for emotion recognition using physiological signals. *IEEE Transactions on affective computing*, 13(1), 389-407.
- Tizzano, G. R., Spezialetti, M., & Rossi, S. (2020, June). A deep learning approach for mood recognition from wearable data. In *2020 IEEE international symposium on medical measurements and applications (MeMeA)* (pp. 1-5). IEEE.