



ISSN: 2230-9926

Available online at <http://www.journalijdr.com>

IJDR

International Journal of Development Research

Vol. 11, Issue, 08, pp. 49795-49800, August, 2021

<https://doi.org/10.37118/ijdr.22750.08.2021>



RESEARCH ARTICLE

OPEN ACCESS

RECONHECIMENTO DE EMOÇÕES UTILIZANDO BIOSSENSORES: UM ESTUDO DE CASO COM REDES NEURAIS

Juciano Cardoso and Carine G. Webber

Área de Ciências Exatas e Engenharias, Universidade de Caxias do Sul

ARTICLE INFO

ArticleHistory:

Received 10th May, 2021

Received in revised form

19th June, 2021

Accepted 27th July, 2021

Published online 29th August, 2021

Key Words:

Affective computing, Machine Learning, Multilayer Neural Networks, Biosensors.

*Corresponding author:

Jefferson Jose Oliveira Chagas De Souza

ABSTRACT

O objetivo deste artigo é descrever o processo de implementação e avaliação de um modelo de rede neural para reconhecimento de emoções a partir de biosinais. A pesquisa compreendeu etapas de concepção de um coletor de biosinais, experimentação com voluntários e implementação de uma rede neural para reconhecimento de emoções. O conjunto de emoções tratadas neste estudo englobou felicidade, raiva, tristeza e neutralidade. Foram coletados biosinais de atividade eletrodermal, temperatura periférica e volume de pulso sanguíneo de um grupo amostral composto por 15 sujeitos. A fim de gerar os estímulos emocionais desejados foi desenvolvido um software para gerenciar o tempo de exposição aos estímulos, armazenar e transmitir os dados coletados. Por meio deste estudo avaliou-se arquiteturas de redes neurais, treinadas com os dados coletados, obtendo-se resultados que evidenciam o potencial do uso deste método para reconhecimento de emoções.

Copyright © 2021, Juciano Cardoso and Carine G. Webber. This is an open access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Citation: Juciano Cardoso and Carine G. Webber. "Reconhecimento de emoções utilizando biossensores: um estudo de caso com Redes Neurais", *International Journal of Development Research*, 11, (08), 49795-49800.

INTRODUCTION

As emoções tem influência em diversas funções essenciais, como o convívio social, o aprendizado e a percepção. Implicitamente os seres humanos conseguem reconhecer emoções em seus iguais. O reconhecimento de emoções é uma área que se propõe, através da detecção de padrões em respostas emocionais, reproduzir essa habilidade humana (Picard, 2000). Algumas das áreas que se beneficiam do estudo do reconhecimento de emoções são: a interface humano-computador, o acompanhamento médico e o cuidado de pessoas com necessidades especiais (Picard, Vizas e Healey, 2001; Costa *et al.*, 2019). No âmbito das interfaces humano-computador, fazer com que computadores reconheçam e reajam a emoções manifestadas por humanos pode tornar-los mais próximos e favorecer interações (Picard, 2000). De maneira aplicada, o reconhecimento de emoções pode ainda detectar alterações no humor de pessoas que não conseguem ou tem dificuldade em se expressar, como idosos, crianças e portadores de doenças físicas e mentais. O reconhecimento de alterações emocionais neste público pode prevenir ou detectar surtos e crises (Costa *et al.*, 2019). Picard (2000) destaca as diversas formas de manifestações emocionais ou modulações sensoriais. Algumas delas são: expressões faciais, entonação vocal, reconhecimento de

gestos e biosinais. O reconhecimento emocional por meio das expressões faciais e da entonação vocal são largamente explorados. Contudo, o reconhecimento de emoções por meio de biosinais, apresenta desafios ainda não superados, tais como diversidade humana que implica na dificuldade de se estabelecer padrões (Jerritta *et al.*, 2011,]; Doma e Pirouz, 2020). Os biosinais consistem em sinais fisiológicos originados no Sistema Nervoso Autônomo. Estes sinais não podem ser intencionalmente dissimulados, o que constitui uma das vantagens dessa forma de modulação sensorial (Picard, 2000). Biosinais são também independentes de cultura, ao contrário das expressões faciais, por exemplo, onde pessoas de determinadas culturas podem ser menos expressivas do que outras. Entretanto, os biosinais não são independentes de gênero e idade. Pessoas idosas manifestam sinais fisiológicos de maneira distinta de pessoas jovens. Já a maioria das mulheres manifesta emoções de maneira mais intensa do que homens (Rani e Sarkar, 2006; Park *et al.*, 2007). Alguns biosinais utilizados no reconhecimento emocional são: o eletrocardiograma (ECG), a atividade eletrodermal (EDA ou GSR), a eletromiografia (EMG), a temperatura periférica (SKT), o pulso de volume sanguíneo (BVP) e a respiração (RESP). Esses sinais são medidos por meio de biossensores (Haag *et al.*, 2004; Doma e Pirouz, 2020; Domínguez-Jiménez *et al.*, 2020).



Figura 1. Emoções em relação a valência e excitação

As emoções podem ser representadas em três dimensões: excitação, valência e dominância. A excitação varia de pouco impactante a muito impactante e corresponde a intensidade com que uma emoção afetou um indivíduo. A valência varia de negativa a positiva, correspondendo a emoções que provocaram bem ou mal estar a um indivíduo (Lang, 1995). A dominância por sua vez, corresponde a quanto uma emoção abalou o controle do indivíduo. Esta dimensão é pouco usada, por apresentar baixa relevância (Lang, 1995). Por esta razão, ela não foi considerada neste estudo. A figura 1 ilustra as emoções dispostas em coordenadas representando as dimensões de valência (ordenada) e excitação (abscissa). Estímulos emocionais são comumente utilizados em ambiente laboratorial para provocar respostas emocionais. As principais formas destes estímulos são: imagens, música e filmes (Coan e Allen, 2007). Lang, Bradley e Cuthbert (2008) desenvolveram um banco de imagens para esse fim, chamado: IAPS (*International Affective Picture System*). O banco contém imagens que provocam emoções variadas, em diferentes graus de valência e excitação. Usualmente tal conjunto de imagens é utilizado em experimentos envolvendo geração de dados a serem interpretados em termos de emoções. O banco de imagens IAPS é disponibilizado sob demanda para pesquisas na área.

Dado o contexto desta pesquisa, o presente artigo apresenta o desenvolvimento e avaliação de um modelo de rede neural para reconhecimento de emoções a partir de biossinais. A pesquisa compreendeu etapas de concepção de um coletor de biossinais, experimentação com voluntários e implementação de uma rede neural para reconhecimento de emoções, descritos nas seções seguintes. O artigo finaliza apresentando os resultados obtidos e as conclusões do estudo.

MATERIAIS E MÉTODOS

O método empregado neste trabalho seguiu etapas de: coleta de dados e rotulação, pré-processamento, extração de características, redução de dimensionalidade, treinamento e teste de um classificador baseado em rede neural multicamadas. Cada etapa é detalhada a seguir.

Coleta e Rotulação dos Dados: Um processo de coleta consiste em expor o indivíduo a um estímulo emocional e gravar seus sinais enquanto estimulado (Haag et al., 2004). Neste estudo preferiu-se utilizar estímulos visuais na forma de imagens. Imagens são uma forma de estímulo conveniente para ser utilizada em laboratório, pois pode-se produzir uma exposição controlada em termos de tempo e de intensidade (Lang, 1995). O banco de imagens IAPS (Lang et al., 2007) foi utilizado. Esse banco de imagens foi testado com indivíduos de diferentes idades, gêneros e culturas, mostrando-se independente em todos estes aspectos.

Destaca-se a sua fácil aplicação em ambiente laboratorial. O acervo do IAPS corresponde a mais de 1000 imagens com diferentes atividades humanas. Além do banco de imagens, estão incluídos relatórios contendo dados, tais como a média e desvio padrão em termos de valência, excitação e dominância de cada imagem.

Além do conjunto de dados foi empregado um teste de auto-avaliação, denominado SAM (*Self-Assessment Manikin*). Este teste compreende um conjunto de pictogramas por meio dos quais o sujeito pode, após ser exposto a um estímulo emocional, indicar a sua reação emocional em uma escala hedônica de 9 pontos para cada dimensão (Bradley e Lang, 1994). O teste SAM foi explicado aos voluntários da pesquisa, que fizeram uso para fins de indicação da sua reação face aos estímulos. Posteriormente, essas indicações foram usadas para rotular os dados coletados. Mapeou-se assim o conjunto de biossinais a uma emoção, relatada pelo sujeito durante o tempo do estímulo. Para se fazer a seleção das imagens a serem utilizadas neste estudo, empregou-se o relatório do IAPS com indicações. As sessões de coletas seguiram o modelo de Haag, que consiste em expor as imagens por 15 segundos ao indivíduo lendo os biossinais a uma frequência de 50 Hza cada 20 milissegundos. A ordem das imagens também seguiu o modelo de Haag, exibindo os estímulos em ordem crescente de excitação, intercalando-os com imagens neutras (Haag et al., 2004). Utilizando-se os valores das médias no relatório do IAPS, os estímulos foram separados em 7 grupos. Para cada sessão os estímulos foram exibidos na seguinte ordem: 10 imagens neutras, 5 imagens de valência positiva e excitação baixa, 10 imagens neutras, 5 imagens de valência negativa e excitação baixa, 10 imagens neutras, 5 imagens de valência positiva e excitação neutra, 10 imagens neutras, 5 imagens de valência negativa e excitação neutra, 10 imagens neutras, 5 imagens de valência positiva e excitação alta, 10 imagens neutras, 5 imagens de valência negativa e excitação alta (Haag et al., 2004). As imagens selecionadas para exibição compreenderam aquelas situadas nos intervalos citados na Tabela 1. Elas foram ordenadas em ordem decrescente de desvio padrão de excitação, com o intuito de selecionar as imagens com menor variação na avaliação dos indivíduos em estudos precedentes. Como recomendação, notou-se que as imagens de excitação alta devem ser exibidas no final da sessão para que seu impacto emocional não afete o indivíduo ao ponto dele não se recuperar a tempo para o próximo estímulo, podendo gerar algum tipo de ruído nos sinais (Haag et al., 2004). Observou-se também que intercalar imagens neutras permite neutralizar os sinais.

Tabela 1. Subconjunto de estímulos selecionados

Descrição das imagens	Valência média	Excitação média
Neutras	(4, 6)	(1, 4)
Com baixa excitação e valência positiva	(6, 10)	(1, 4)
Com excitação neutra e valência positiva	(6, 10)	(5, 6)
Com alta excitação e valência positiva	(6, 10)	(6, 10)
Com baixa excitação e valência negativa	(1, 4)	(1, 4)
Com excitação neutra e valência negativa	(1, 4)	(5, 6)
Com alta excitação e valência negativa	(1, 4)	(6, 10)

Outro aspecto relevante diz respeito ao fato de que os sinais fisiológicos podem variar para um mesmo indivíduo em dias diferentes (Picard et al., 2001). Por isso, foi necessário realizar coletas de sinais dos sujeitos da pesquisa em dias distintos. O grupo amostral da pesquisa compreendeu 15 voluntários participaram, sendo 10 homens e 5 mulheres. Cada indivíduo teve seus sinais coletados durante 3 sessões, com intervalo de 7 dias entre as sessões. Preferiu-se neste estudo utilizar sensores não intrusivos e de baixo custo. Foi utilizado um sensor de fotopleitismografia (*photoplethysmography* ou PPG) que mensura o pulso referente ao volume sanguíneo (*blood volume pressure* ou BVP), um sensor para atividade eletrodermal (*electrodermal activity* ou EDA) e um sensor de temperatura periférica (*peripheral temperature* ou SKT). Considerou-se as quatro principais emoções, mapeadas nos quatro quadrantes do plano de valência e excitação: raiva, felicidade, tristeza e neutralidade (figura 2). O processo de rotulação dos biossinais considerou três componentes:

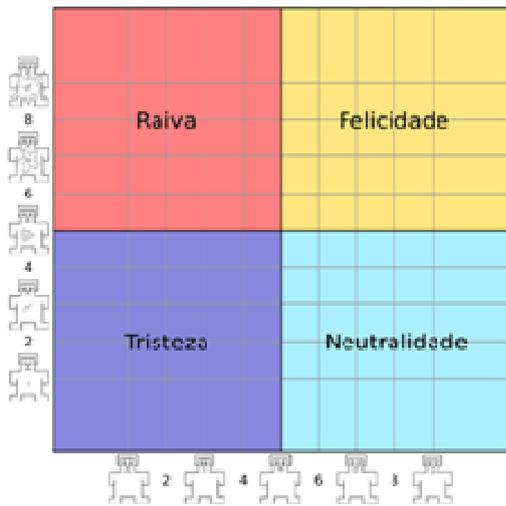


Figura 2. Mapeamento do SAM em valência e excitação

- Rótulo extraído do IAPS: consiste nos resultados de médias de valência e excitação do estímulo utilizado, de acordo com estudos prévios descritos em relatórios dos próprios autores. Estes valores são mapeados no modelo de valência e excitação ilustrado pela Figura 2 (Land e Bradley, 2007).
- Rótulo extraído do SAM: após a exibição de um estímulo, os sujeitos deviam indicar a sua reação emocional em termos de valência e excitação, conforme a Figura 2.
- Rótulo extraído da *Microsoft Emotion API*: este rótulo foi desenvolvido baseado na metodologia de Costa (Costa *et al.*, 2019). Durante o processo de exposição das imagens, foram feitas capturas da face de cada sujeito. As faces foram posteriormente submetidas a *Microsoft Emotion API*¹, retornando um valor referente a emoção detectada.

A *Microsoft Emotion API* avalia faces em termos de oito emoções: raiva, neutralidade, nojo, medo, felicidade, contentamento, tristeza e surpresa. A API retorna valores probabilísticos que indicam a confiança no reconhecimento de cada emoção. A emoção escolhida para o rótulo foi aquela que obteve a maior probabilidade durante a exposição do sujeito ao estímulo. O processo de coleta consistiu numa seguinte sequência de eventos: exibir um estímulo, coletar os sinais fisiológicos, capturar imagens da face do sujeito, aplicar o teste SAM. Repetiu-se essas etapas até o final do conjunto de imagens. Um programa, integrando o coletor, a exibição do estímulo, a captura da face e a aplicação do SAM, foi desenvolvido². Este software recebe como parâmetros: o conjunto de imagens usadas como estímulo, o identificador do sujeito, o identificador da sessão, o tempo de exibição do estímulo, o tempo de captura das faces e a porta serial onde o coletor está conectado. O programa em questão opera com três processos: um processo principal e dois processos auxiliares, responsáveis pela leitura do coletor e a captura das faces. Os processos auxiliares operam apenas durante a exibição de um estímulo e são suspensos no restante do tempo. O processo principal é responsável pelo disparo dos eventos que suspendem e liberam os processos auxiliares além da exibição do estímulo, da aplicação do SAM e por serializar dos dados obtidos. Os dados obtidos são salvos em banco de dados relacional SQLite³, em uma tabela cuja estrutura é apresentada pela Tabela 2. Após o processo da coleta, os dados são armazenados em banco de dados ainda os três rótulos das emoções. Os rótulos são adicionados após a etapa de extração de características.

Dispositivo Coletor: Diversas pesquisas relacionadas utilizam sensores intrusivos ao usuário, como eletrocardiograma e eletromiograma.

Tabela 2. Atributos correspondentes aos dados coletados

Sinais
id: Integer (PK)
id_subject: Integer
id_session: Integer
id_collect: Integer
date_time: DateTime
ppg_signal: Float
eda_signal: Float
skt_signal: Float
sam_arousal: Integer
sam_valence: Integer
id_iaps: Integer

Nesta pesquisa buscou-se utilizar sensores que fossem de fácil instalação, não intrusivos aos voluntários e possuíssem baixo custo. Em artigo recente de Costa e outros autores (2019) é descrita a construção de um dispositivo coletor denominado Emotional Smart Wristband (ESW). Tal coletor utiliza os sensores de fotopletismografia, temperatura periférica e atividade eletrodermal. O presente estudo se guiou pelos processos precedentes de Costa e seus colegas, bem como as lições aprendidas descritas. Definiu-se assim um conjunto de componentes. Utilizou-se um sensor de temperatura periférica desenvolvido pela fabricante Malexis modelo (MLX90615)⁴ que utiliza luz infra-vermelha para ler temperaturas de objetos e de ambientes. O MLX90615 possui uma resolução de 0.02 graus Celsius e é capaz de ler temperaturas de -20 graus Celsius a +85 graus Celsius. O sensor foi posicionado a uma distância média de 5 centímetros da mão não dominante do voluntário. Apenas a temperatura da mão dos sujeitos avaliados foram armazenadas. O valor lido pelo sensor é convertido internamente para graus Celsius, facilitando a manipulação dos dados. O sensor escolhido para a leitura de atividade eletrodermal é desenvolvido pela fabricante Grove modelo Grove-GSR v1.0⁵. Este sensor é capaz de mensurar a voltagem de 0 a 1023 V. Sua instalação consiste em fixar o eletrodo positivo na parte inferior da falange proximal do dedo polegar e seu eletrodo negativo na parte inferior da falange média do dedo médio da mão não dominante, conforme indica o fabricante. Para evitar ruídos neste sinal provenientes das mãos do indivíduo estarem em condições de umidade alteradas, todos os voluntários aplicaram uma solução de álcool gel em suas mãos antes da coleta. A utilização de soluções condutividade nos eletrodos não era especificada pelo fabricante e em seus exemplos em vídeo nada era aplicado, por essa razão soluções deste tipo não foram utilizadas. Inicialmente buscou-se utilizar para fotopletismografia o mesmo sensor utilizado por Costa, Rincon, Carrascosa, Julian e Novais, fabricado pela Pulse Sensor⁶. Todavia, os exemplares adquiridos apresentaram mal funcionamento com leituras de valores demasiadamente elevados. Além disso, por não apresentarem uma estrutura de fixação nos dedos observou-se distorções e ruídos frequentes. A fim de evitar erros devido ao mal funcionamento deste sensor, ele foi substituído por um outro sensor desenvolvido pela Ebedded Lab, modelo Easy Pulse v1.1⁷. Este

⁴ Especificação em <https://www.melexis.com/-/media/files/documents/datasheets/mlx90615-datasheet-melexis.pdf>

⁵ https://github.com/SeeedDocument/Grove-GSR_Sensor/raw/master/res/Grove-GSR_Sensor_WiKi.pdf

⁶ <https://pulsesensor.com/>

⁷ <http://embedded-lab.com/blog/easy-pulse-version-1-1-sensor-overview-part-1/>

¹ <https://azure.microsoft.com/en-us/services/cognitive-services/emotion/>

² Software disponível em <https://github.com/JucianoC/emotion-biosignal-collector>

³ SQLite disponível em <https://www.sqlite.org/index.html>

sensor possui um encaixe em silicone para o dedo do usuário, o que reduz a chance de ruídos por movimentação. Neste encaixe, nota-se na parte superior um LED e na parte inferior um receptor infravermelho, responsáveis pela emissão da luz no tecido e posterior leitura. Testes foram feitos com todos os dedos da mão não dominante utilizando o software fornecido pelo fabricante. Cruzou-se a informação de frequência cardíaca fornecida por este software com as medidas feitas por um sensor de pulsos para atividades físicas. O polegar foi o dedo que apresentou os melhores resultados e consequentemente foi o dedo selecionado para a coleta. A Figura 3 apresenta a disposição e interligação dos componentes do coletor. Além dos sensores, foi utilizada uma pequena placa de ensaio para se interligar os componentes e um microcontrolador Arduino UNO⁸ para fazer a alimentação e leitura dos sensores.

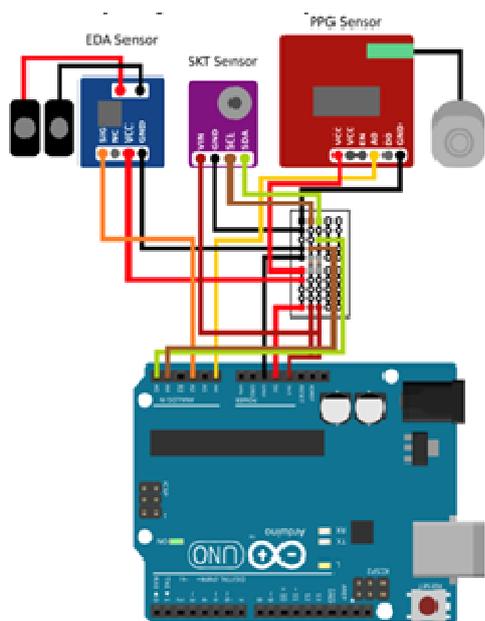


Figura 3. Microcontrolador e componentes do coletor

Todos os sensores utilizados possuíam bibliotecas compatíveis com o Arduino. Para a integração entre sensores e Arduino foi desenvolvido um software⁹ responsável pela captura dos sinais e envio destas para a porta serial que é lida no software de exibição e coleta.

Pré-processamento e extração de características: Para cada estímulo exibido a um sujeito, 6 características estatísticas foram extraídas de cada sinal, sendo as mesmas previamente descritas e utilizadas por Picard, Vyzas e Healey (2001). Durante a exibição de um estímulo pode haver diferenças no número total de amostras de sinais extraídas dos sensores. Picard, Vyzas e Harley (2001) indicam que as características devem ser extraídas de um conjunto de amostras de tamanho fixo. A fim de corrigir eventuais diferenças no número de amostras de sinais obtidas durante cada exibição de estímulos, as amostras foram truncadas em um número que corresponde a aproximadamente 13 segundos de exibição de um estímulo. A junção de todas as amostras de um sinal para uma exibição de estímulo foi organizada em um vetor, posteriormente normalizado. Um conjunto de dados contendo as características extraídas e seus respectivos rótulos foi produzido a partir deste processo. A estrutura do conjunto de dados é representado na Tabela 3.

Nos resultados provenientes da *Microsoft Emotion API* não tivemos nenhuma imagem facial mapeada para nojo e medo. Contentamento foi mapeado para neutralidade. A emoção que se repetiu em ao menos dois dos três rótulos (*emotion_label_iaps*, *emotion_label_iaps* e *emotion_label_sam*) foi atribuída a coluna *label*, usada como rótulo no aprendizado supervisionado do classificador. O *dataset* final obtido

conteve 1403 instâncias, representando ocorrências convergentes em ao menos dois dos três *labels* (*emotion_label_iaps*, *emotion_label_iaps* e *emotion_label_sam*) criados. Neste conjunto, 75 instâncias foram mapeadas para a emoção de felicidade, 82 instâncias para raiva, 196 instâncias para tristeza e 1050 instâncias para neutralidade.

Classificação e redução de dimensionalidade: A fim de possibilitar o processo de classificação a partir do *dataset* criado optou-se por verificar a sua dimensionalidade utilizando PCA (*Principal Component Analysis*), conforme Tipping e Bishop (1999). Essa prática é extensivamente aplicada na redução de dimensionalidade, como mostram também (Johnstone e Paul, 2018; Wu, Wai e Scaglione, 2018). Antes de serem submetidos ao redimensionamento, os dados foram normalizados para valores entre -1 e 1. Testes foram efetuados variando o número de componentes e observou-se que dez componentes representavam 90% da variabilidade, abaixo deste valor a representatividade de variabilidade caía de forma significativa. Com a aplicação do método PCA, o *dataset* foi redimensionado mantendo apenas dez características principais. Uma rede neural *perceptron* multicamadas foi usada para a classificação, uma vez que esse tipo de classificador apresentou resultados satisfatórios em outros estudos relacionados envolvendo conjunto de sinais e características similares (Costa, 2019). A implementação usada para o classificador está disponível na biblioteca Scikit-Learn¹⁰.

Três métodos foram aplicados a fim corrigir o desbalanceamento das classes minoritárias. Inicialmente foi testado o método de amostragem aleatória (*random oversampling*) que gera amostras aleatórias de classes minoritárias até que o total de amostras seja igual ao da classe majoritária (Tantithamthavorn, Hassan e Matsumoto, 2018). O segundo método testado foi o aprendizado sensível a custo (*cost sensitive learning*). Este método tem como princípio gerar uma penalidade para classificações incorretas em que uma instância de classe minoritária é classificada como sendo de classe majoritária (Prati, Batista e Monard, 2009). Neste caso o balanceamento das classes foi realizado por método específico da biblioteca Keras¹¹. O terceiro método testado foi o SMOTE¹² (*synthetic minority oversampling technique*) que gera amostras para as classes minoritárias evitando problemas de overfitting gerados por outros métodos de sobreamostragem precedentes. O balanceamento de classes produziu três *datasets*, com diferentes distribuições. Todos foram submetidos ao processo de validação cruzada utilizando de 5 a 10 partições de dados. Testes foram realizados, seguindo métodos próprios da área detalhados em (Karlik e Olgac, 2011). Aplicou-se o método *gridsearch*, variando-se o número de partições, camadas ocultas, número de neurônios nas camadas ocultas, *solver*, parâmetros e funções. Os testes realizados foram analisados e produziram um melhor resultado a ser apresentado na seção seguinte.

RESULTADOS

A partir dos testes realizados identificou-se que o balanceamento com o método SMOTE produziu o melhor conjunto de dados (575 instâncias). Como melhor configuração obteve-se uma rede neural apresentando 9 neurônios na camada de entrada, duas camadas ocultas, contendo 21 e 18 neurônios respectivamente, e uma camada de saída com 4 neurônios. A função de ativação das camadas ocultas que apresentou o melhor resultado foi a tangente hiperbólica. O método *solver* que melhor operou sobre os dados foi o *sgd* (*standard gradient descent*). Assumiu-se o número máximo de 7000 iterações. O método de amostragem usado foi a validação cruzada com 5 partições, sendo as instâncias aleatoriamente selecionadas. Nesta configuração obteve-se uma acurácia do classificador de 93%. A Tabela 4 apresenta a matriz de confusão obtida.

¹⁰ Disponível em https://scikit-learn.org/stable/modules/generated/sklearn.neural_network.MLPClassifier.html

¹¹ Disponível em <https://keras.io/>

¹² Disponível em <https://imbalanced-learn.org/>

⁸ <https://store.arduino.cc/usa/arduino-uno-rev3>

⁹ https://github.com/JucianoC/emotion-biosignal-collector/blob/master/arduino_collector/arduino_collector.ino

Tabela 3. Conjunto de características incluídas no dataset

Características + rótulos
ppg_mean: Float
ppg_stdev: Float
ppg_mean_first_diff_raw: Float
ppg_mean_first_diff_normalized: Float
ppg_mean_second_diff_raw: Float
ppg_mean_second_diff_normalized: Float
eda_mean: Float
eda_stdev: Float
eda_mean_first_diff_raw: Float
eda_mean_first_diff_normalized: Float
eda_mean_second_diff_raw: Float
eda_mean_second_diff_normalized: Float
skt_mean: Float
skt_stdev: Float
skt_mean_first_diff_raw: Float
skt_mean_first_diff_normalized: Float
skt_mean_second_diff_raw: Float
skt_mean_second_diff_normalized: Float
emotion_label_iaps: String
emotion_label_eapi: String
emotion_label_sam: String
label: String

Tabela 4. Matriz de confusão para reconhecimento de emoções

		classe prevista			
		felicidade	raiva	tristeza	neutralidade
classe real	felicidade	42	5	1	2
	raiva	7	47	1	1
	tristeza	4	0	115	8
	neutralidade	2	1	6	333

Tabela 5. Desempenho do classificador por classe

	felicidade	raiva	tristeza	neutralidade
precisão	0,76	0,89	0,93	0,97
recall	0,84	0,84	0,91	0,97
f1-score	0,80	0,86	0,92	0,97

A tabela 5 detalha o desempenho do classificador em termos das quatro emoções trabalhadas. Comparativamente a trabalhos precedentes os resultados obtidos sinalizam que os métodos de sobreamostragem contribuíram para a obtenção de melhores resultados. Para a classe felicidade, os resultados se aproximaram dos trabalhos anteriores. Contudo, para as classes raiva e tristeza os resultados foram melhores. Rigas, Katsis, Ganiatsas e Fotiadis (2007) tiveram uma acurácia de 62,7% utilizando o método KNN (*k-nearest neighbors*) e 62,4% com o método *Random Forest*. As pesquisas descritas por Kim, Bang e Kim (2004) apontaram uma acurácia de 78,4% assumindo um conjunto de 3 emoções e 61,8% para um conjunto de 4 emoções. Em trabalho posterior, Kim e André (2008) trabalharam com o mesmo grupo de emoções descrito aqui utilizando um classificador independente de usuário, baseado em análise discriminante linear, obtendo uma acurácia de 70%. Outros trabalhos identificados na literatura pesquisaram classificadores dependentes de usuário para o mesmo grupo de emoções. Neste contexto, Zhu (2010) obteve uma acurácia de 82,3% e Hoenig, Wagner, Batliner e Noeth (2009) obtiveram uma acurácia de 83,4%.

CONCLUSÃO

Este trabalho demonstrou que o reconhecimento de emoções é uma tarefa possível de ser realizada a partir de sinais obtidos por sensores de fotopleletismografia, de atividade eletrodermal e de temperatura periférica. Métodos de seleção de características (PCA) e balanceamento de classes (SMOTE) foram fundamentais para o refinamento do modelo. Considerou-se as quatro principais emoções, mapeadas nos quatro quadrantes do plano de valência e excitação: raiva, felicidade, tristeza e neutralidade. Embora o conjunto amostral deste estudo seja pequeno, entende-se que os resultados evidenciam que esta linha de pesquisa é promissora. Ao longo do desenvolvimento do trabalho percebeu-se que a coleta dos sinais deve ser padronizada e precisa, pois dela depende a acurácia do modelo gerado. A qualidade dos sensores impacta diretamente neste fator. O coletor construído e o software de gerenciamento de coleta operaram com êxito, podendo ser reutilizados em trabalhos futuros. Embora relativo progresso tenha sido obtido nos métodos de reconhecimento de emoções, estudos e pesquisas ainda são necessários para identificar a eficiência dos estímulos em provocar emoções e sentimentos que estão fortemente ligados a aspectos cognitivos e culturais. Como apontam diversos autores, embora as emoções humanas básicas sejam as mesmas, os estímulos que provocam emoções intensas nos seres humanos não são os mesmos. Neste sentido esta pesquisa contribui com a investigação sobre as reações emocionais humanas face a estímulos variados. Como trabalhos futuros, pretende-se expandir os testes para outros métodos de *machine* e *deep learning*, que vem sendo citados na literatura. Experimentos relacionados indicam que tais abordagens devem ser exploradas, podendo resultar em melhores modelos auxiliando na compreensão dos fatores que provocam emoções nos seres humanos.

REFERÊNCIAS

- Bradley, M. M., Lang, P. J. 1994. "Measuring emotion: the self-assessment manikin and the semantic differential". *Journal of behavior therapy and experimental psychiatry*, 25:1:49-59.
- Coan, J.A., Allen, J. J. 2007. "Handbook of emotion elicitation and assessment". Oxford university press.
- Costa, A., Rincon, J. A., Carrascosa, C., Julian, V., Novais, P. 2019. "Emotions detection on an ambient intelligent system using wearable devices". *Future Generation Computer Systems*, 92:479-489.
- Doma, V., Pirouz, M. A comparative analysis of machine learning methods for emotion recognition using EEG and peripheral physiological signals. *J Big Data* 7, 18 2020.
- Domínguez-Jiménez, J.A.; Campo-Landines, K.C.; Martínez-Santos, J.C.; Delahoz, E.J.; Contreras-Ortiz, S.H. A machine learning model for emotion recognition from physiological signals, *Biomedical Signal Processing and Control*, Volume 55, 2020
- Haag, A., Goronzy, S., Schaich, P., Williams, J. 2004. Emotion recognition using bio-sensors: First steps towards an automatic system. *Affective Dialogue Systems*, pages 36-48.
- Honig, F., Wagner, J., Batliner, A., Noth, E. 2009. Classification of user states with physiological signals: On-line generic features vs. specialized feature sets. In 2009 IEEE 17th European Signal Processing Conference, pages 2357-2361.
- Jerritta, S., Murugappan, M., Nagarajan, R., Wan, K. 2011. Physiological signals based human emotion recognition: a review. In 2011 IEEE 7th International Colloquium on Signal Processing and its Applications, pages 410-415. IEEE.
- Johnstone, I. M., Paul, D. 2018. PCA in high dimensions: An orientation. *Proceedings of the IEEE*, 1068:1277-1292.
- Karlik, B., Olgac, A. V. 2011. Performance analysis of various activation functions in generalized MLP architectures of neural networks. *International Journal of Artificial Intelligence and Expert Systems*, 14:111-122.

- Kim, J., Andre, E. 2008. Emotion recognition based on physiological changes in music listening. *IEEE transactions on pattern analysis and machine intelligence*, 30(12):2067–2083.
- Kim, K., Bang, S., Kim, S. 2004. Emotion recognition system using short-term monitoring of physiological signals. *Medical and Biological Engineering and Computing*, 42(3):419–427.
- Lang, P., Bradley, M. M. 2007. The international affective picture system iaps in the study of emotion and attention. *Handbook of emotion elicitation and assessment*, 29.
- Lang, P. J. 1995. The emotion probe: studies of motivation and attention. *American psychologist*, 50(5):372.
- Lang, P. J., Bradley, M. M., Cuthbert, B. N. 2008. International affective picture system iaps: affective ratings of pictures and instruction manual. University of Florida, Gainesville. Technical report, Tech Rep A-8.
- Park, C., Ryu, J., Sohn, J., Cho, H. 2007. An emotion expression system for the emotional robot. In *2007 IEEE International Symposium on Consumer Electronics*, pages 1–6. IEEE.
- Picard, R. W. 2000. *Affective computing*. MIT press.
- Picard, R. W., Vyzas, E., Healey, J. 2001. Toward machine emotional intelligence: Analysis of affective physiological state. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 23(10):1175–1191.
- Prati, R. C., Batista, G. E., Monard, M. C. 2009. Data mining with imbalanced class distributions: concepts and methods. In *IICAI*, pages 359–376.
- Rani, P., Sarkar, N. 2006. A new approach to implicit human-robot interaction using affective cues. In *Mobile Robots: towards New Applications*. IntechOpen.
- Rigas, G., Katsis, C. D., Ganiatsas, G., Fotiadis, D. I. 2007. A user independent, biosignal based, emotion recognition method. In *International Conference on User Modeling*, pages 314–318. Springer.
- Tantithamthavorn, C., Hassan, A. E., Matsumoto, K. 2018. The impact of class rebalancing techniques on the performance and interpretation of defect prediction models. *IEEE Transactions on Software Engineering*.
- Tipping, M. E., Bishop, C. M. 1999. Mixtures of probabilistic principal component analyzers. *Neural computation*, 11(2):443–482.
- Xiaoxiao Wu, S., Wai, H.-T., Li, L., Scaglione, A. 2018. A review of distributed algorithms for principal component analysis. *Proceedings of the IEEE*, 106(10):1321–1340.
- Zhu, X. 2010. Emotion recognition of emg based on bp neural network. In *Proc Int Symposium Network. Network Security*, pages 227–229. Jingtangshan.
