

Predição do estado afetivo de usuários a partir da análise de dados fisiológicos

Paulo A. Martins Januário Julio C. dos Reis

Relatório Técnico - IC-PFG-22-21
Projeto Final de Graduação
2022 - Julho

UNIVERSIDADE ESTADUAL DE CAMPINAS
INSTITUTO DE COMPUTAÇÃO

The contents of this report are the sole responsibility of the authors.
O conteúdo deste relatório é de única responsabilidade dos autores.

Predição do estado afetivo de usuários a partir da análise de dados fisiológicos

Paulo Afonso Martins Januário

Julio Cesar dos Reis*

Resumo

Emoções são respostas fisiológicas que podem ser capturadas a partir de sensores. Neste trabalho utilizamos dados coletados de eletroencefalograma (EEG), que avalia a atividade elétrica do cérebro. Essa atividade é separada em bandas de frequência (Alpha, Beta, Theta, Delta e Gamma) e podem ser analisadas para entender o funcionamento do cérebro do indivíduo examinado. Conduzimos uma oficina para coleta dos dados na Universidade Estadual de Campinas com 21 voluntários que foram expostos a diferentes experiências sensoriais pela visão, audição e tato. Nosso objetivo foi induzir quatro diferentes estados afetivos (alegria, tristeza, medo e nojo) enquanto utilizavam um equipamento que coleta os dados de EEG. Os dados foram analisados e pré-processados para permitir o treinamento de um modelo de aprendizado de máquina para a classificação. O algoritmo investigado foi o *Support Vector Machine* (SVM) que se mostrou efetivo em outras implementações de classificação de dados de EEG e em datasets menores. Os melhores resultados obtidos foram sobre a identificação de ‘alegria’ e ‘medo’ com base em dados de todos os voluntários sumarizados pela média de dez medições, obtendo um resultado de 59% de acurácia e 59% de F1-score.

1 Introdução

Parte importante da comunicação humana envolve entender quais são as emoções sentidas pelo interlocutor. Emoções são respostas que podem ser sensoriais (externos) ou mentais (internos) [1] e levam a respostas psicológicas e fisiológicas. Como existe uma resposta fisiológica entende-se que seja possível a partir da medição de sinais como de eletrocardiograma (ECG) ou eletroencefalograma (EEG) detectar e classificar atividades relacionada às emoções. Existem evidências de que diferentes emoções são causadas por áreas cerebrais diferentes e que, por meio de EEG, essas emoções podem ser reconhecidas [2].

*Instituto de Computação, Universidade Estadual de Campinas, 13081-970 Campinas, SP.

O eletroencefalograma é uma gravação da atividade cerebral, detectada por meio de um ou mais sensores em contato com a testa ou couro cabeludo do indivíduo que coletam sinais elétricos produzidos pelo cérebro. Esses sinais são convertidos para permitir uma melhor análise. A análise normalmente é feita separando as ondas coletadas em cinco bandas de frequência (alpha, beta, theta, delta e gamma). A faixa Alpha (8 - 14 Hz) são originadas em períodos de relaxamento durante a vigília. Ondas Beta (14 - 30 Hz) se originam durante períodos conscientes e com concentração ativa. A faixa Theta (4 - 8 Hz) é observada em alguns períodos do sono e de foco. Ondas Delta (0.5 - 4 Hz) são ondas mais lentas, normalmente detectadas durante o sono. Por fim, ondas Gamma (acima de 30 Hz) tem maior atividade em resposta a estímulos visuais [3].

Existe um padrão adotado pela Federação Internacional de Neurofisiologia Clínica (IFCN) que utiliza pontos de referência do crânio para a localização de sensores para o EEG, que é o sistema 10-20 (Figura 1). Nesse sistema, a cabeça é dividida em posições proporcionais para cobrir todas as regiões do cérebro. O nome de cada eletrodo consiste em uma letra e um número, onde cada letra se refere à região do cérebro onde o eletrodo está posicionado e o número está relacionado ao hemisfério cerebral [4].

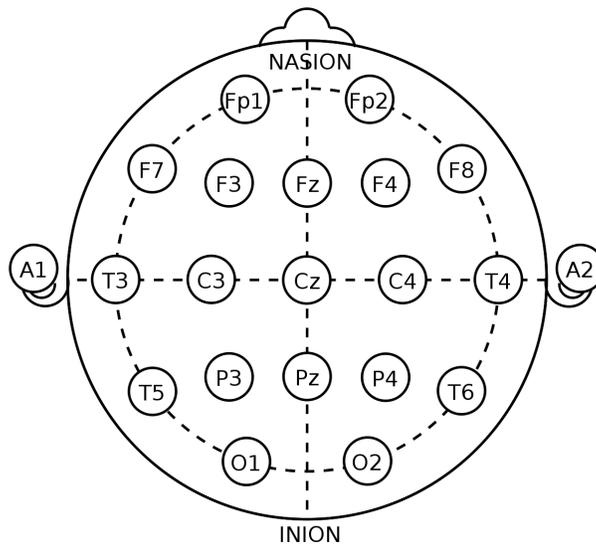


Figura 1: *Posição de sensores para o eletroencefalograma*

Nos dias atuais, o acesso a equipamentos que possuem sensores para EEG está mais difundido, permitindo que esse tipo de análise seja elaborada em ambientes fora de hospitais. Além da disponibilidade, há uma maior variedade nos tipos de equipamento, afetando como a coleta é feita e como os dados são disponibilizados.

Este trabalho explora um equipamento de EEG para entender como diferentes

emoções afetam as ondas cerebrais a partir de uma análise preditiva utilizando algoritmos de aprendizado de máquina para classificação. Atualmente, modelos diferentes são gerados a partir de bases de dados prontas, como o *DEAP* [5], que classifica a atividade cerebral em níveis de valência e alertamento (*valence* e *arousal*) e visam encaixar as diferentes emoções nesse modelo [2].

Nesta investigação realizamos a coleta dos dados de eletroencefalograma de participantes de uma oficina influenciando diferentes tipos de emoção em voluntários, como alegria, tristeza, medo e nojo. Em nosso estudo, a classificação dos estados afetivos é feita a partir desses dados.

Este relatório está organizado da seguinte forma: Na Seção 2 citamos alguns trabalhos relacionados ao nosso estudo. Na Seção 3 descrevemos a metodologia do trabalho, explicando como os dados foram coletados e tratados para criar um modelo de classificação. Apresentamos também como os experimentos foram organizados e como as técnicas foram aplicadas. A Seção 4 apresenta os resultados obtidos; A Seção 5 desenvolve uma discussão sobre os resultados. Por fim, apresentamos uma conclusão na Seção 6.

2 Síntese da Literatura

Diversos estudos feitos nos últimos anos sobre interfaces cérebro-computador baseados em EEG podem ser encontrados na literatura. A Tabela 1 apresenta alguns deles, que serão descritos a seguir.

No trabalho de Wang *et al.* [2], técnicas de reconhecimento de emoções por ondas cerebrais foram consideradas e um método de análise de emoções foi proposta utilizando o domínio de *valence-arousal* (valência e alertamento). Um modelo multi-dimensional de reconhecimento de emoções foi utilizado para analisar e caracterizar os sinais de EEG como algoritmo SVM como método de aprendizado de máquina aplicado. O resultado mostrou que cada canal de 4 bandas de frequência pode reconhecer eficientemente 20 emoções diferentes.

Utilizando redes neurais profundas baseado em 1D-CNN (rede neural convolucional de uma dimensão), Jiang *et al.* [6] propôs um método de classificação de EEG para melhorar a acurácia de reconhecimento de padrões de BCI (Interfaces cérebro-computador). O trabalho considera pacientes com Doença de Alzheimer por meio de cenas e imagens mostradas em um ambiente de realidade virtual. O dispositivo EEG recebe os sinais cerebrais do paciente e rotula a imagem de acordo com o tipo do sinal.

Gena *et al.* [7] conduziu um experimento no qual usuários eram expostos a um conjunto de trabalhos artísticos que sugeriam emoções para identificar os níveis de atenção pelas ondas cerebrais. O dispositivo Emotiv EPOC foi utilizado para obter os dados. O trabalho analisou a existência de diferenças sobre as ondas cerebrais

nos diferentes hemisférios cerebrais em relação a emoções. Um índice de atenção foi medido de maneira assimétrica utilizando a informação de eletrodos posicionados em ambos hemisférios cerebrais. O índice foi comparado com o engajamento dos participantes para testar a confiabilidade de detecção de atenção baseada em BCI.

Kujit e Almardani [8] adotaram uma abordagem preditiva ao estudar processamento emocional humano baseado em atividade cerebral. Eles investigaram a predição de empatia humana por autoavaliação baseando-se na assimetria cortical em diferentes áreas do cérebro pela análise de EEG. Foram avaliados diferentes tipos de modelos preditivos, como análises de regressão linear e classificadores binários. Os resultados mostraram que a análise da lateralização das oscilações do cérebro em faixas de frequência específica é importante para prever níveis de empatia por autoavaliação.

Assim como no trabalho de Wang *et al.* [2], o nosso presente trabalho utiliza um classificador SVM. Exploramos dados para treinamento do modelo que foram coletados de maneira diferente, sem a quantificação por meio do domínio valência-alertamento.

Tabela 1: Estudos relacionados a interfaces cérebro-computador baseados em EEG.

Ano	Título
2021	Multidimensional emotion recognition based on semantic analysis of biomedical EEG signals for knowledge discovery in psychological healthcare [2].
2020	An EEG emotion classification system based on one-dimension convolutional neural network and virtual reality [6].
2020	Prediction of Human Empathy based on EEG Cortical Asymmetry [8].
2019	Do BCIS detect user's engagement? The results of an empirical experiment with emotional artworks [7].

3 Metodologia

Nosso estudo está separado em três partes principais, que são coleta de dados, preparação dos dados e aplicação dos algoritmos para classificação. Figura 2 apresenta o processo utilizado para coletar a atividade cerebral e os passos subsequentes. Explicamos cada etapa do processo.

3.1 Coleta de Dados

3.1.1 Equipamento para coleta de ondas cerebrais

O dispositivo utilizado para coleta de dados de ondas cerebrais foi o NeuroSky MindWave Mobile (Figura 3). O dispositivo contém 2 sensores/canais para cole-

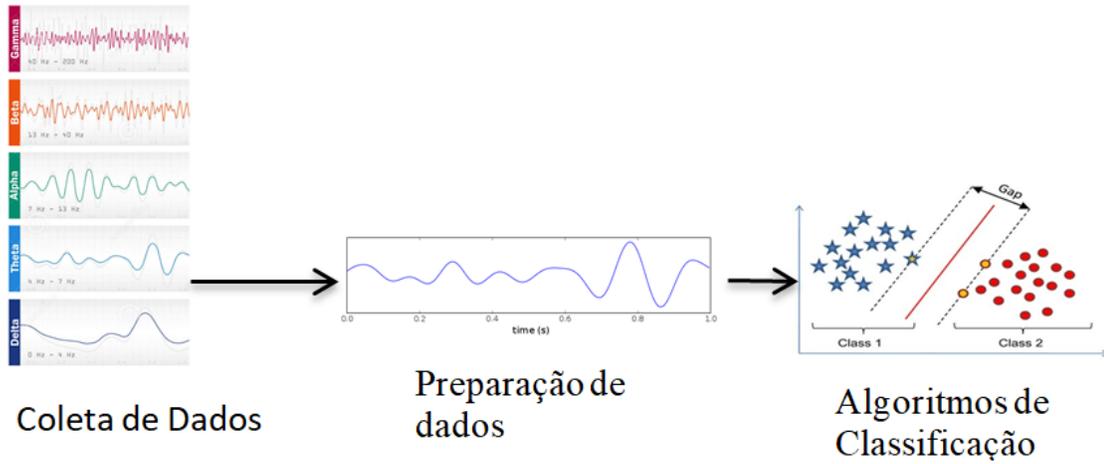


Figura 2: Metodologia

tar dados da atividade cerebral, sendo um eletrodo em contato com a testa acima dos olhos na posição Fp1 (como mostrado na Figura 1) e um eletrodo terra como uma presilha na posição A2, que serve como referência do headset. Ondas cerebrais analógicas são coletadas e transformadas em ondas digitais. O dispositivo se conecta ao computador por meio de uma conexão Bluetooth.



Figura 3: Headset de EEG NeuroSky Mindwave Mobile

3.1.2 Oficina para coleta de ondas cerebrais

Para a coleta de dados, foram realizadas oficinas no Instituto de Computação da Universidade Estadual de Campinas (UNICAMP) com voluntários para que emoções fossem experienciadas durante o uso do aparelho de EEG. Uma oficina baseada no artefato “Memoção”, parte do projeto temático FAPESP Socienativos (2015/165280), foi criada como base para fomentar essas experiências emocionais [9, 10].

A oficina, que buscava explorar diferentes sensações, consistiu em caixas contendo texturas relacionadas ao tato e vídeos projetados na tela que apresentam quatro tipos de emoções ao participante. Foram criadas quatro caixas correspondendo às diferentes emoções (alegria, tristeza, medo e nojo), que visavam deixar a experiência mais imersiva. Ao interagir com as caixas, o participante assiste a um vídeo ao apertar um botão conectado ao computador por meio de uma placa Arduino. A Figura 4 mostra uma imagem da sala em que aconteceu a oficina.



Figura 4: Oficina para coleta de dados

O fluxo da interação se inicia quando o participante, após colocar o headset de EEG NeuroSky MindWave Mobile (Figura 3), escolhe uma caixa que se refere à emoção esperada para realizar a interação e assistir ao vídeo vinculado. Durante a interação, dados das ondas cerebrais são coletados pelo dispositivo de EEG e rotulados de acordo com a emoção estimulada. Ao final, os participantes respondem a um questionário para avaliar qual foi a influência dos estímulos na percepção real de

emoção. A Figura 5 apresenta um diagrama que descreve o fluxo.

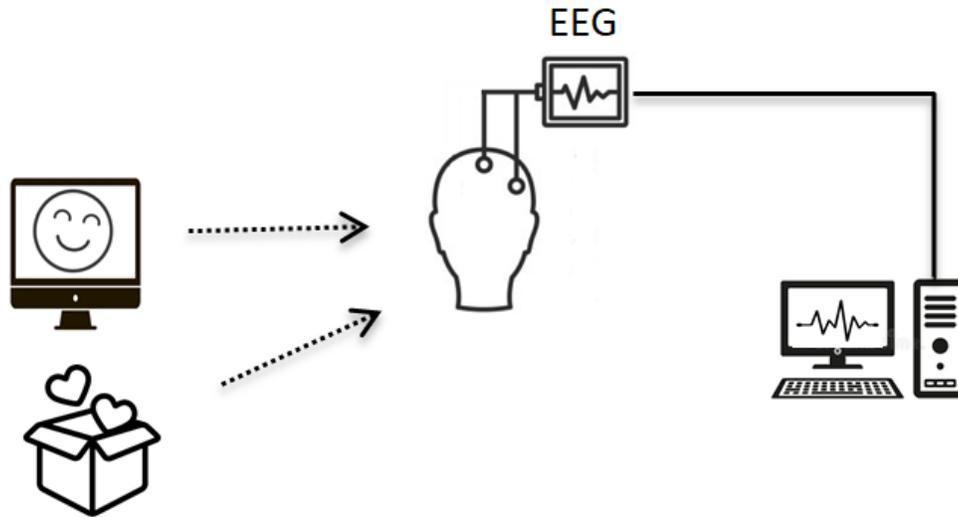


Figura 5: *Fluxo de dados*

3.1.3 Caracterizando os dados

O headset é conectado ao computador por meio de uma conexão Bluetooth e o software Neuro Experimenter Version 6.6 (Figura 6) foi utilizado para a coleta das ondas cerebrais. O software coleta a cada segundo os sinais enviados pelo headset, que são: Delta, Theta, Alpha 1, Alpha 2, Beta 1, Beta 2, Gamma 1, Gamma 2, Attention, Meditation e totPwr. Os oito primeiros são correspondentes às faixas de frequência das ondas cerebrais já decompostas, separados entre faixa alta e faixa baixa (exceto Delta e Theta). Além disso, também coleta o índice da medição (obs), tempo (time) e classe (class).

Durante a sessão de cada participante, quatro arquivos *.csv* são gerados, correspondendo aos quatro tipos de emoções estimuladas pela tela e pela caixa. Cada linha de cada arquivo corresponde a uma medição instantânea feita pelo headset e coletada pelo software.

3.2 Preparação dos Dados

Os dados coletados e armazenados são utilizados no pré-processamento de dados. Esse processo envolve realizar uma limpeza dos dados, removendo linhas com erros e colunas que não serão úteis para análise e agregando os dados para deixá-los prontos para a classificação pelo algoritmo. A forma que os dados são armazenados previamente e o processo de pré-processamento é detalhado a seguir.

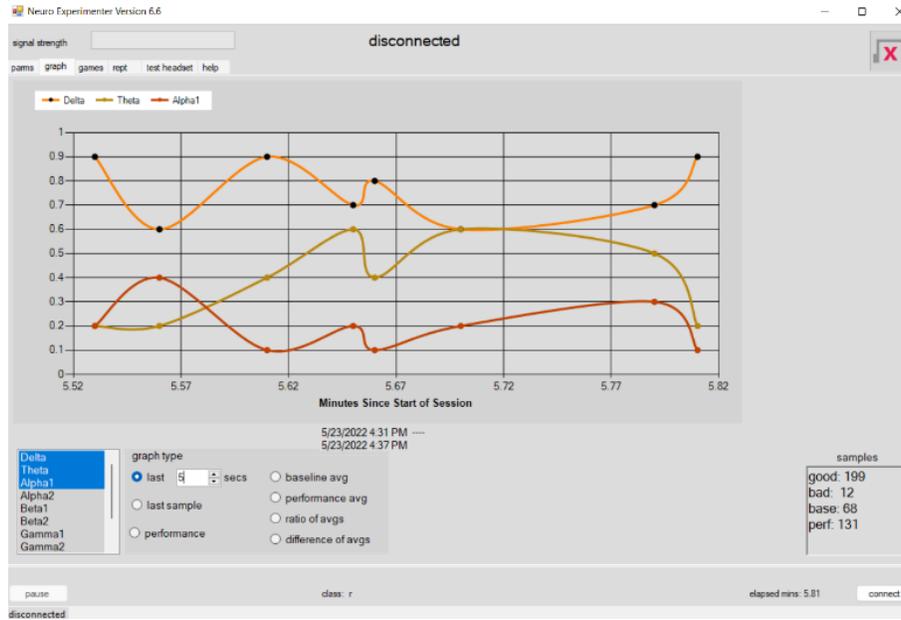


Figura 6: Interface do software *Neuro Experimenter*

3.2.1 Pré-processamento dos dados

Com os dados coletados, é necessário que eles sejam pré-processados antes de iniciar a classificação. Inicialmente isso é feito removendo os espaços dos nomes das colunas, removendo linhas em que houve erro na coleta, gerando valores não numéricos e removendo colunas que não serão úteis, como obs, time e class.

Para alguns experimentos, os dados foram sumarizados, ou seja, cada conjunto de dados de uma emoção de um indivíduo foi separado em conjuntos menores de 10 medições em que a média dos valores de cada coluna foi calculada e utilizada para o treinamento. Além disso, para garantir um menor tempo de treinamento dos modelos, houve a normalização das features.

Por fim, os dados coletados são separados em conjuntos de treino e conjunto de teste para iniciar a construção do modelo e permitir a análise de sua eficácia. O conjunto de treino corresponde a 70% do tamanho total do dataset.

3.3 Classificação

Support Vector Machine (SVM)

Para a tarefa de classificação (classes são os estados afetivos) exploramos o algoritmo SVM. O Support Vector Machine é um algoritmo classificador de aprendizado de máquina supervisionado que atribui categorias a dados. É um algoritmo que oferece uma alta acurácia se comparado com outros algoritmos de classificação e uti-

lizado em uma alta variedade de aplicações como classificação de e-mails e notícias, detecção facial, reconhecimento de escrita à mão, entre outros. O algoritmo funciona separando os dados utilizando um hiperplano com maximização da margem. O SVM busca encontrar um hiperplano ótimo para ajudar na classificação de novos dados [11].

Para classificação de dados de EEG, o SVM se mostrou efetivo em outras implementações, com valores de acurácia que chegam a 83% e F1-score de 85% [12, 13].

3.4 Protocolo experimental

Realizamos experimentos para investigar um modelo que seja efetivo em classificar os dados fisiológicos. Visamos entender se os dados coletados são suficientes para encontrar esse modelo para uma variedade de pessoas. Realizamos três experimentos, que se diferenciam nos dados utilizados e a forma que eles foram pré-processados. O treinamento do modelo foi conduzido da mesma forma em todos os experimentos, utilizando o classificador SVM do pacote sklearn com kernel linear (parâmetro *kernel* com o valor *'linear'*). O modelo utiliza os dados de ondas cerebrais para classificar qual o tipo da emoção sentida a partir dos rótulos que fizeram parte do treinamento. Ao final, medimos a acurácia e geramos a matriz de confusão para visualizar a relação entre dados preditos e reais e calcular o F1-score, que computa essa relação.

- **Experimento #1**

O primeiro experimento foi feito antes da oficina e da coleta dos dados. Portanto, antes da obtenção dos dados de diferentes participantes. Exploramos dados gerados por uma sessão de teste em apenas um participante. O objetivo foi realizar um teste inicial com a aplicação do algoritmo como preparação para a oficina.

- **Experimento #2**

O segundo experimento foi realizado após a obtenção de todos os dados da oficina. Nem todos os dados coletados foram utilizados nos experimentos realizados. Após a análise do questionário, percebemos que a oficina foi pouco eficaz em estimular as emoções, recebendo notas baixas de intensidade de emoção sentida, principalmente para tristeza e nojo. Por conta disso, os experimentos utilizaram apenas os dados de alegria e medo.

Foram obtidos dados de 21 participantes, com em média 64 medições válidas para cada emoção, com 9 colunas cada, gerando um dataset de tamanho 2687×9 após o pré-processamento para o experimento. Esse foi o dataset utilizado no experimento para gerar o modelo de classificação.

- **Experimento #3**

Um terceiro experimento foi realizado utilizando os mesmos dados do experimento #2 (de todos os participantes das oficinas), porém com um pré-processamento diferente, utilizando a média de valores de grupos de medições contínuas, como descrito em 3.2.1. O método foi utilizado neste e em outros estudos que utilizam o classificador SVM em dados de EEG [14] para minimizar flutuações aleatórias que poderiam alterar os resultados mas ainda utilizando o todos os valores do dataset. Após esse processamento, o tamanho do dataset foi de 258×9 .

4 Resultados

4.1 Experimento #1: teste inicial com o algoritmo SVM

Nesse cenário, obtivemos uma acurácia de 67% e F1-score de 69%, calculado pela média entre os resultados de *alegria* e *medo*. A Figura 7 apresenta a matriz de confusão para o modelo gerado.

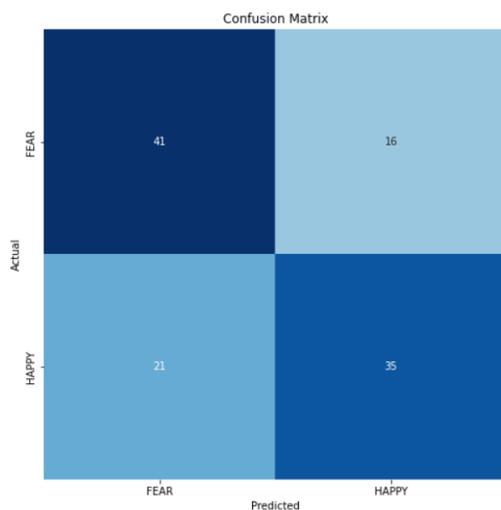


Figura 7: Resultado da matriz de confusão do experimento #1

4.2 Experimento #2: análise de dados não sumarizados

Aplicando o algoritmo SVM nos dados coletados pela oficina no dataset inicial, obtivemos uma acurácia de 54% e F1-score de 53%, calculado pela média entre os resultados de *alegria* e *medo*. Figura 8 apresenta a matriz de confusão para o modelo.

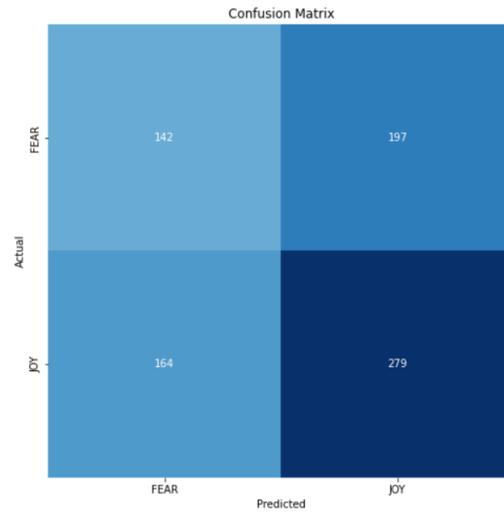


Figura 8: Resultado da matriz de confusão para o experimento #2 (dados não sumarizados)

4.3 Experimento #3: análise de dados sumarizados

Utilizando os mesmos dados do experimento #2, ao sumarizar os dados em médias de grupos de 10 medições, obtivemos acurácia de 59% e F1-score de 59%, calculado pela média entre os resultados de *alegria* e *medo*. Figura 9 apresenta a matriz de confusão para o modelo.

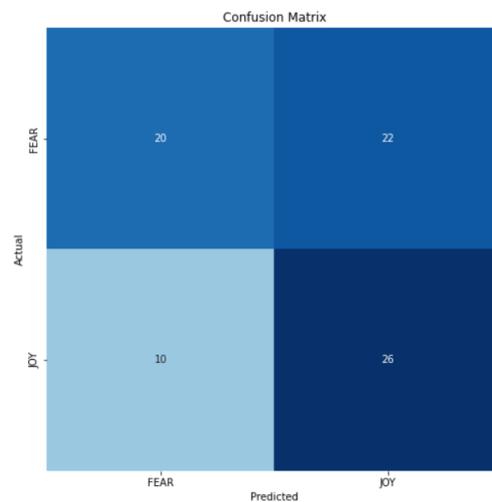


Figura 9: Resultado da matriz de confusão para o experimento #3 (dados sumarizados)

5 Discussão

Nos experimentos conduzidos, o primeiro atingiu uma maior acurácia, porém com dados de apenas um indivíduo, o que pode acabar não classificando bem dados para uma população mais ampla.

Ao utilizar o dataset que agrupa as características pela média de um grupo de medições, a acurácia do modelo com os dados de todos os voluntários aumentou, passando de 54% para 59%. O conjunto de dados obtido é pequeno, com registros de apenas 21 participantes e com autoavaliação baixa sobre a intensidade das emoções, indicando que os dados coletados podem não refletir o efeito real das emoções esperadas sobre as ondas cerebrais dos indivíduos. Esses fatores podem ter sido limitadores da acurácia dos modelos.

Em trabalhos futuros visamos aprimorar o design da oficina de coleta de dados para que a captura do estado afetivo seja refinada. É importante coletar dados de mais indivíduos, para que o algoritmo utilizado consiga aprender efetivamente a partir de um conjunto de dados mais representativo. Visamos igualmente experimentar outras classes de algoritmos incluindo redes neurais profundas que podem aumentar a acurácia do modelo.

6 Conclusão

Neste trabalho exploramos dados fisiológicos para construir um modelo preditivo para classificação de estados afetivos. Os dados foram coletados a partir de um equipamento de eletroencefalograma (EEG) em oficinas em que os participantes foram expostos a experiências multi sensoriais. Os dados coletados e processados foram utilizados para treinar um modelo de aprendizado de máquina com o algoritmo de classificação SVM. Com dados coletados de 21 participantes e utilizando duas emoções (alegria e medo) obtivemos uma acurácia de 59% e F1-score de 59%.

Agradecimentos

Este trabalho teve apoio da aluna de Doutorado, Geovanna Evelyn Espinoza Taype, da aluna de graduação, Luma Oliveira Lombello, do laboratório de pesquisa InterHAD do IC/UNICAMP e do projeto temático FAPESP Socienativos (#2015/165280) [10].

Referências

- [1] Cabanac de Lafregeyre, Michel. (2002). What is emotion?. Behavioural processes. 60. 69-83. 10.1016/S0376-6357(02)00078-5.

- [2] Wang, L.; Liu, H.; Zhou, T.; Liang, W.; Shan, M. Multidimensional Emotion Recognition Based on Semantic Analysis of Biomedical EEG Signal for Knowledge Discovery in Psychological Healthcare. *Appl. Sci.* 2021, 11, 1338.
- [3] Abo-Zahhad, Mohammed & Ahmed, Sabah & Seha, Sherif Nagib. (2015). A New EEG Acquisition Protocol for Biometric Identification Using Eye Blinking Signals. *International Journal of Intelligent Systems and Applications (IJISA)*. 07. 48-54. 10.5815/ijisa.2015.06.05.
- [4] Rojas, Gonzalo & Alvarez, Carolina & Montoya Moya, Carlos & de la Iglesia Vaya, Maria & Cisternas, Jaime & Gálvez, Marcelo. (2018). Study of Resting-State Functional Connectivity Networks Using EEG Electrodes Position As Seed. *Frontiers in Neuroscience*. 12. 10.3389/fnins.2018.00235.
- [5] Koelstra, Sander & Mühl, Christian & Soleymani, Mohammad & Lee, Jong-Seok & Yazdani, Ashkan & Ebrahimi, Touradj & Pun, Thierry & Nijholt, Anton & Patras, Ioannis. (2011). DEAP: A Database for Emotion Analysis Using Physiological Signals. *IEEE Transactions on Affective Computing*. 3. 18-31. 10.1109/T-AFFC.2011.15.
- [6] Jiang, X., Gao, T. (2021). An EEG Emotion Classification System Based on One-Dimension Convolutional Neural Networks and Virtual Reality. In: Barolli, L., Poniszewska-Maranda, A., Park, H. (eds) *Innovative Mobile and Internet Services in Ubiquitous Computing . IMIS 2020. Advances in Intelligent Systems and Computing*, vol 1195. Springer, Cham.
- [7] Gena, Cristina & Mattutino, Claudio & Pirani, Simone & Carolis, Berardina. (2019). Do BCIs Detect User's Engagement?: The Results of an Empirical Experiment with Emotional Artworks. 387-391. 10.1145/3314183.3323865.
- [8] Kuijt, Andrea & Alimardani, Maryam. (2020). Prediction of Human Empathy based on EEG Cortical Asymmetry.
- [9] Duarte, Emanuel & Maíke, Vanessa & Mendoza, Yusseli & Brennand, Camilla & Baranauskas, M. Cecilia. (2019). "The Magic of Science:" Beyond Action, a Case Study on Learning Through Socioenaction. 501. 10.5753/cbie.wie.2019.501.
- [10] Maria Cecília C Baranauskas. *Sistemas socio-enativos: investigando novas dimensões no design da interação mediada por tecnologias de informação e comunicação*. FAPESP Thematic Project (2015/165280), 2015.
- [11] Colas, F., Brazdil, P. (2006). Comparison of SVM and Some Older Classification Algorithms in Text Classification Tasks. In: Bramer, M. (eds) *Artificial Intelligence in Theory and Practice. IFIP AI 2006. IFIP International Federation for Information Processing*, vol 217. Springer, Boston, MA.

- [12] Ali, M.; Mosa, A.H.; Al Machot, F.; Kyamakya, K. EEG-based emotion recognition approach for e-healthcare applications. In Proceedings of 8th International Conference on Ubiquitous and Future Networks (ICUFN 2016), Vienna, Austria, 5–8 July 2016; pp. 946–950.
- [13] 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).
- [14] Nisrine Jrad, Marco Congedo, Ronald Phlypo, Sandra Rousseau, Rémi Flamary, et al.. sw-SVM : sensor weighting Support Vector Machines for EEG-based Brain Computer Interfaces. *Journal of Neural Engineering*, IOP Publishing, 2011, 8 (5)