



**UNIVERSIDADE FEDERAL DO VALE DO SÃO FRANCISCO
PROGRAMA DE PÓS-GRADUAÇÃO CIÊNCIAS DA SAÚDE E
BIOLÓGICAS**

CÍCERO ADSON BARBOSA ALMINO DE LIMA

**EFEITO DA LATERALIZAÇÃO CORTICAL NA CLASSIFICAÇÃO
MULTICANAL DE EMOÇÕES ATRAVÉS DE SINAIS DE
ELETROENCEFALOGRAMA A PARTIR DE JOGOS DIGITAIS**

PETROLINA

2023

CÍCERO ADSON BARBOSA ALMINO DE LIMA

**EFEITO DA LATERALIZAÇÃO CORTICAL NA CLASSIFICAÇÃO
MULTICANAL DE EMOÇÕES ATRAVÉS DE SINAIS DE
ELETROENCEFALOGRAMA A PARTIR DE JOGOS DIGITAIS**

Dissertação de mestrado apresentada a Universidade Federal do Vale do São Francisco - UNIVASF, Campus Petrolina (Centro), como requisito para obtenção do título de Mestre em Ciências da Saúde e Biológicas, com ênfase em Saúde, Sociedade e Ambiente.

Orientador: Prof. Dr. Rodrigo Pereira Ramos
Coorientador: Prof. Dr. Leonardo Sampaio

PETROLINA

2023

L732e Lima, Cícero Adson Barbosa Almino de
Efeito da lateralização cortical na classificação multicanal de emoções através de sinais de eletroencefalograma a partir de jogos digitais / Cícero Adson Barbosa Almino de Lima. - Petrolina, 2023.
xii, 60 f. : il. ; 29 cm.

Dissertação (Mestrado em Ciências da Saúde e Biológicas)
Universidade Federal do Vale do São Francisco, Campus Petrolina,
Petrolina - PE, 2023.

Orientador (a): Prof. Rodrigo Pereira Ramos.

1. Sinais de eletroencefalograma. 2. Jogos digitais. 3. Estudo das emoções. 4. Emoções - Cérebro. I. Título. II. Ramos, Rodrigo Pereira. III. Universidade Federal do Vale do São Francisco.

CDD 794.17

UNIVERSIDADE FEDERAL DO VALE DO SÃO FRANCISCO
PÓS-GRADUAÇÃO CIÊNCIAS DA SAÚDE E BIOLÓGICAS

FOLHA DE APROVAÇÃO

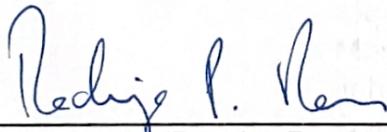
CÍCERO ADSON BARBOSA ALMINO DE LIMA

EFEITO DA LATERALIZAÇÃO CORTICAL NA CLASSIFICAÇÃO MULTICANAL DE EMOÇÕES ATRAVÉS DE SINAIS DE ELETROENCEFALOGRAMA A PARTIR DE JOGOS DIGITAIS

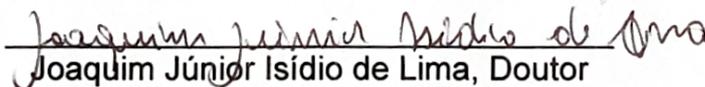
Dissertação apresentada como requisito para obtenção do título de Mestre em Ciências com ênfase na linha de pesquisa: Fundamentação Conceitual e Metodologias Inovadoras Integradoras em Ambiente, Tecnologia e Saúde, pela Universidade Federal do Vale do São Francisco.

Aprovada em: 21 de março de 2023

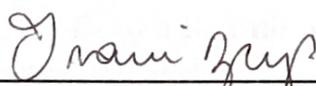
Banca Examinadora



Rodrigo Pereira Ramos, Doutor
Universidade Federal do Vale do São Francisco – Univasf



Joaquim Júnior Isídio de Lima, Doutor
Universidade Federal do Vale do São Francisco – Univasf



Ivani Brys, Doutora
Universidade Federal do Vale do São Francisco – Univasf

AGRADECIMENTOS

Agradeço primeiramente ao meu orientador Prof. Dr. Rodrigo Pereira Ramos e coorientador Prof. Dr. Leonardo Sampaio, pelo suporte e acompanhamento durante a escrita desse trabalho. Em segundo lugar a minha família, que é a minha base. Agradeço a Universidade Federal do Vale do São Francisco e a todos os professores, técnicos e funcionários que contribuíram para a minha formação, em especial, a todas as pessoas envolvidas no Programa de Pós-Graduação Ciências da Saúde e Biológicas (PPGCSB).

Agradeço também aos participantes da banca examinadora, que contribuíram bastante para a conclusão do presente trabalho. Agradeço a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), e principalmente a Fundação de Amparo à Ciência e Tecnologia de Pernambuco (FACEPE), pelo suporte por meio de bolsa de estudos.

“Se você quiser descobrir os segredos do Universo, pense em termos de energia,
frequência e vibração.”
- Nikola Tesla

RESUMO

Neste estudo, apresentamos um novo método de classificação de emoções a partir de sinais de EEG, baseado na lateralização de emoções no cérebro. Usamos um conjunto de dados públicos de sinais de EEG, extraídos através do *gadget* EMOTIV EPOC+ MobileEEG de 14 canais, para detecção de emoções em diferentes cenários de videogames com quatro videogames comerciais diferentes, representando quatro estados emocionais (alegria, calma, tristeza, raiva). O foco do estudo é investigar os efeitos das teorias de lateralização de valência, dominância do hemisfério direito e lateralização de aproximação-retirada, em três algoritmos de classificação (KNN, SVC e Random Forest). Os resultados mostram que, usando quatro pares de canais assimétricos frontais relacionados à emoção no cérebro e três cenários de lateralização de emoção, é possível melhorar a precisão do reconhecimento de emoção na classificação multi-classe de emoções com relação a classificadores que desconsideram essas hipóteses, usando o método de validação cruzada de 10 *folds* nos três classificadores. Foram selecionados quatro pares de canais assimétricos relacionados à emoção no cérebro (AF3-AF4, F3-F4, P7-P8, T7-T8) e três cenários de lateralização de emoção para testar nosso método. Houve um aumento de performance em todos os classificadores relacionados aos esquemas de lateralização, exceto da hipótese de hemisfério direito.

Palavras-chave: eeg; jogos; emoções; classificador;

ABSTRACT

In this study, we present a new method for classifying emotions from EEG signals, based on the lateralization of emotions in the brain. We used a public dataset of EEG signals, extracted through the 14-channel EMOTIV EPOC+ MobileEEG gadget, for emotion detection in different video game scenarios with four different commercial video games, representing four emotional states (happiness, calmness, sadness, anger) . The focus of the study is to investigate the effects of the theories of valence lateralization, right hemisphere dominance and approach-withdrawal lateralization, on three classification algorithms (KNN, SVC and Random Forest). The results show that, using four pairs of emotion-related frontal asymmetric channels in the brain and three emotion lateralization scenarios, it is possible to improve the accuracy of emotion recognition in the multi-class classification of emotions with respect to classifiers that disregard these assumptions, using the 10-fold cross-validation method on the three classifiers. Four pairs of emotion-related asymmetric channels in the brain (AF3-AF4, F3-F4, P7-P8, T7-T8) and three emotion lateralization scenarios were selected to test our method. There was a performance increase in all classifiers related to lateralization schemes, except for the right hemisphere hypothesis.

Key-words: eeg; games; emotions; classifier;

LISTAS DE FIGURAS

Figura 1 -	Sistema internacional 10/20.	21
Figura 2 -	Modelo Valência-Excitação.	23
Figura 3 -	Classificador de florestas aleatórias.	26
Figura 4 -	Classificação de dados com SVC. O kernel refere-se à função de expansão de dimensão.	27
Figura 5 -	Funcionamento do algoritmo k-NN.	29
Figura 6 -	Fluxo de operações usadas no trabalho.	31
Figura 7 -	Figura 7 - Detalhamento do processo de obtenção das características para um dos canais considerados (AF3). O processo se repete para os demais canais.	37
Figura 8 -	Figura 8 - Detalhamento do processo de fusão de características em um único vetor: (a) domínio tempo-frequência; (b) domínio do tempo.	39
Figura 9 -	Gráfico boxplot - domínio de tempo-frequência	49
Figura 10 -	Gráfico boxplot - domínio do tempo	53

LISTAS DE TABELAS

Tabela 1 -	Extração de características por hemisfério, considerando os esquemas de lateralização avaliados: Hipótese de aproximação-retirada (AP); Hipótese do Hemisfério Direito (R), Hipótese de Valência (V), Todos os eletrodos (T).	35
Tabela 2 -	Jogos e emoções correspondentes	35
Tabela 3 -	Características de domínio de tempo e domínio de tempo-frequência.	36
Tabela 4-	Vetor de características de cada esquema de canais	39
Tabela 5-	Espaço de busca - Florestas Randômicas.	45
Tabela 6 -	Espaço de busca - KNN.	45
Tabela 7 -	Espaço de busca - SVC.	45
Tabela 8 -	Acurácias dos classificadores usando características no domínio tempo-frequência.	48
Tabela 9 -	Precisão dos classificadores para características no domínio de domínio tempo-frequência.	50
Tabela 10 -	Acurácias dos classificadores para características no domínio de tempo.	51
Tabela 11 -	Precisão dos classificadores para características no domínio do tempo.	52

LISTA DE ABREVIATURAS E SIGLAS

SVC	Support Vector Machine Classifier (Máquina vetor de suporte).
KNN	K-Nearest Neighbors (k-ésimo vizinho mais próximo).
RF	Random Forest (Florestas randômicas).
R	Right Hemisphere Hypothesis (Hipótese do hemisfério direito dominante).
V	Valence Hypothesis (Hipótese da Valência).
AP	Approach-Withdraw Hypothesis (Hipótese da aproximação-afastamento).
T	Todos os eletrodos

SUMÁRIO

1. INTRODUÇÃO.....	14
1.1. TRABALHOS CORRELATOS.....	17
2. OBJETIVO.....	19
2.1. OBJETIVO GERAL.....	19
2.2. OBJETIVOS ESPECÍFICOS.....	19
3. REFERENCIAL TEÓRICO.....	19
3.1. LATERALIZAÇÃO HEMISFÉRICA.....	19
3.2. SINAIS DE ELETROENCEFALOGRAFIA E SEU PROCESSAMENTO.....	20
3.3. ANÁLISE WAVELET.....	23
3.4. CLASSIFICADORES COMPUTACIONAIS.....	24
3.4.1. Florestas aleatórias.....	25
3.4.2. Máquinas de vetor de suporte.....	27
3.4.3. K-ésimos vizinhos mais próximos.....	28
3.5. OTIMIZAÇÃO DE HIPERPARÂMETROS.....	29
4. MATERIAL E MÉTODOS.....	30
4.1 AQUISIÇÃO DOS DADOS.....	31
4.2. GAMEEMO.....	31
4.3. PRÉ-PROCESSAMENTO DOS SINAIS.....	33
4.4. EXTRAÇÃO DE CARACTERÍSTICAS.....	33
4. 5. VETOR DE CARACTERÍSTICAS.....	36
4.6. CARACTERÍSTICAS DO DOMÍNIO DO TEMPO.....	40
4.6.1. Parâmetros de Hjorth.....	40
4.6.2. Parâmetros estatísticos.....	41
4.7. CARACTERÍSTICAS DO DOMÍNIO DE TEMPO-FREQUÊNCIA.....	42
4.7.1. Entropia aproximada.....	42

4.7.2. Entropia de energia logarítmica.....	42
4.7.3. Raiz do valor quadrático médio.....	42
4.7.4. Operador de energia de Teager–Kaiser.....	43
4.8. NORMALIZAÇÃO.....	43
5. RESULTADOS.....	47
5.1. DOMÍNIO DE TEMPO-FREQUÊNCIA.....	47
5.2. DOMÍNIO DO TEMPO.....	50
6. DISCUSSÕES.....	53
7. CONCLUSÃO.....	55
REFERÊNCIAS.....	56

1. INTRODUÇÃO

A emoção é uma resposta breve e com múltiplos componentes a alguma alteração no modo como as pessoas interpretam - ou avaliam - suas circunstâncias atuais. Quando um indivíduo avalia sua circunstância atual como algo ruim , uma emoção negativa é originada, e quando ele registra uma perspectiva otimista , surge uma emoção positiva. O componente que reconhecemos de forma mais frequente é a experiência subjetiva da emoção - o estado afetivo ou tom do sentimento que a emoção traz - acompanhada de respostas fisiológicas, particularmente aquelas que envolvem o sistema nervoso autônomo, como mudanças na frequência cardíaca e atividade da glândula sudorípara. (ATKINSON, HILGARD, 2018)

A emoção tem uma influência substancial em processos de aprendizagem, incluindo aprendizagem espacial, bem como em processos cognitivos característicos dos seres humanos tais como percepção, atenção, memória, raciocínio e solução de problemas, especialmente modulando a seletividade da atenção, assim como motivando a ação e o comportamento. Esse controle atencional e executivo está intimamente ligado aos processos de aprendizagem, pois as capacidades atencionais intrinsecamente limitadas são mais bem focadas em informações relevantes. A emoção também facilita a codificação e ajuda na recuperação de informações de forma eficiente, tendo influência direta em diversos ambientes, incluindo aqueles que favorecem o processo de aprendizagem (TYNG *et al.*, 2017).

O estudo das emoções eliciadas por jogos digitais vem recebendo atenção dos pesquisadores, principalmente por envolverem experiências cognitivas mais complexas, podendo haver uma indução de emoções positivas e negativas durante a mesma experiência de jogo em diferentes intervalos de tempo (RAVAJA *et al.*, 2008). Nesse sentido, estudar como um conjunto de emoções se desenvolve durante a imersão em um ambiente com vários estímulos externos como os jogos digitais pode contribuir para um melhor entendimento das emoções e suas influências nos processos cognitivos que regem a experiência humana como indivíduos.

Os jogos digitais são ferramentas interativas que podem evocar emoções nos jogadores utilizando recursos como narrativa, mecânica de jogo, estética e mídia digital (como música, sons, imagens, vídeos). O ato de jogar é tanto intelectual quanto emocionalmente envolvente, evocando sentimentos positivos e negativos nos jogadores, sendo que alguns estudos de reconhecimento de emoções a partir de sinais fisiológicos têm utilizado videogames como ferramenta de estímulo emocional, principalmente em cenários de criação de jogos para testar como diferentes fases do jogo provocam sentimentos como tédio, tensão, terror ou engajamento (MARTÍNEZ-TEJADA *et al.*, 2021).

Os sinais fisiológicos podem ser divididos em duas categorias: aqueles provenientes do sistema nervoso periférico como, por exemplo, frequência cardíaca, eletromiograma, resposta galvânica da pele, e aqueles provenientes do sistema nervoso central, como o sinal de eletroencefalograma (EEG), que é o foco da presente dissertação. O estudo do sinal de EEG em cenários de jogo pode fornecer uma aproximação de como as emoções se manifestam em um cenário de interação humano-computador, não apenas para eventos relacionados a jogos, mas também para cognição, treinamento e aplicações de interface homem-máquina (CHANEL *et al.*, 2011).

Alguns trabalhos de reconhecimento de emoções têm usado jogos digitais como estímulo emocional, principalmente em cenários de desenvolvimento de jogos, para atingir emoções específicas como tédio, estresse, medo ou engajamento. No entanto, uma das principais limitações da atual literatura é ausência do uso de teorias psicológicas promissoras, como a lateralização da emoção e a exploração de seus impactos nos algoritmos de classificação, sendo estas duas abordagens recomendadas. A lateralização da emoção é uma predisposição de cada hemisfério do cérebro para processar certas emoções (CHANEL *et al.*, 2011).

Existem três hipóteses de lateralização básicas de emoção no córtex cerebral que são apoiadas por pesquisas empíricas que empregam uma variedade de modalidades de recursos, incluindo neuroimagem e EEG:

lateralização de valência (V), dominância do hemisfério direito (R) e lateralização de aproximação-retirada (AP). Para todos os tipos de estímulo emocional, o hemisfério direito é dominante sobre o hemisfério esquerdo, de acordo com a teoria do hemisfério direito. Por outro lado, certas regiões do hemisfério esquerdo são especializadas no processamento de emoções positivas, enquanto certas regiões do hemisfério direito são especializadas no processamento de emoções negativas, de acordo com a hipótese de lateralização de valência. A hipótese conhecida como lateralização de aproximação-retirada afirma que as emoções que provocam ações de aproximação são lateralizadas para o hemisfério esquerdo, enquanto as emoções que provocam comportamentos de retirada são lateralizadas para o hemisfério direito (PEREIRA; KHAN, 2017).

Assim, o presente trabalho teve como objetivo explorar os efeitos dessas três teorias de lateralização emocional na performance de três algoritmos de classificação, usando um conjunto de dados públicos de sinais de EEG para detecção de emoções em diferentes cenários de videogames.

Para obter os sinais de EEG, um conjunto de dados públicos criado por Alakus, Gonen e Turkoglu (2020) foi utilizado, o qual consiste em quatro jogos comerciais representando quatro estados emocionais diferentes (Train Sim World - G1: raiva, Unravel - G2: calma, Slender—The Arriva - G3: tristeza, Goat Simulator - G4: alegria). Particularmente, queremos mostrar os resultados do uso de quatro pares de canais assimétricos relacionados à emoção no cérebro (AF3-AF4, F3-F4, P7-P8, T7-T8) e três cenários de lateralização de emoção, para melhor entendermos como estas hipóteses influenciam o processo de classificação de quatro emoções (alegria, calma, tristeza, raiva).

Até onde é de conhecimento do autor, este é um dos primeiros trabalhos a abordar os efeitos da lateralização da emoção em algoritmos de classificação de emoções multi-classe com jogos de computador

O restante deste trabalho está organizado da seguinte forma: na Capítulo 1.1, constam outros estudos referentes à extração de características de sinais eletrofisiológicos de jogos digitais. O Capítulo 2 apresenta os

objetivos do trabalho. Já o Capítulo 3 diz respeito ao referencial teórico. O Capítulo 4 explica a metodologia utilizada, que discorre sobre as bases de dados, o pré-processamento dos sinais, as abordagens usadas na etapa de aquisição e construção do vetor de características, e por fim, a etapa de classificação das imagens. Os resultados obtidos encontram-se no Capítulo 5, as discussões do trabalho se encontram no Capítulo 6 e a conclusão do trabalho pode ser vista no Capítulo 7.

1.1. TRABALHOS CORRELATOS

No trabalho de Marín-Morales *et al.* (2018), os sinais de EEG foram coletados em um ambiente de realidade virtual imitando espaços arquitetônicos apresentados por meio de panoramas de 360° durante períodos de 90 segundos para conduzir a identificação de emoções. Eletrodos frontais (Fz, F3 e F4), centrais (Cz, C3 e C4) e parietais (POz, P3 e P4) foram usados para capturar a atividade elétrica. Para gerar quatro estados emocionais diferentes, quatro cenários-base separados foram criados alterando diferentes valores de três variáveis de projeto: iluminação, cor e forma. Os autores obtiveram características de frequência e atributos de conectividade funcional das bandas (4–8 Hz), (8–12 Hz), (13–25 Hz) e (25–40 Hz). As características mais significativas foram escolhidas usando seu modelo de máquina de vetor de suporte de eliminação de recursos com base na pesquisa de conectividade funcional de EEG, o que implica que a conectividade funcional cortical oferece correlações emocionais eficientes, tendo aplicações em áreas diversas como a arquitetura, a saúde, a educação e os jogos digitais.

Já no trabalho de Ghosh, Saha e Konar (2021), Candy Crush Saga, um jogo de lazer, e Stickman Archers, um jogo violento, foram usados como estímulos emocionais para evocar seis emoções diferentes: alegria, tristeza, surpresa, nojo, raiva e humor neutro. Eles usaram um dispositivo da marca Nihon Kohden, com 21 canais para capturar os dados de EEG. Cada pessoa participou do experimento por 30 dias, com cinco testes experimentais todos os dias, durante os quais cada participante jogou um jogo por 10 minutos. Dados de EEG foram usados para determinar as áreas cerebrais que

exibiram ativação emocional. Os autores descobriram que, durante os estados de excitação das cinco emoções (exceto neutra), as regiões pré-frontal, frontal e temporal do cérebro permaneceram altamente ativas, mas apenas o lobo occipital foi ativado durante a condição neutra (sem tarefa cognitiva/neutra).

CHANEL *et al.*, (2011) propuseram uma técnica para ajustar a complexidade de um jogo de Tetris com base nas emoções do jogador, as quais foram avaliadas por meio de um EEG de 19 canais. Os voluntários participaram de seis sessões durante as quais utilizaram o jogo em um limite de tempo de 5 minutos. Usando questionários, eles classificaram a dificuldade de cada jogo junto com uma resposta emocional. Foram observadas várias diferenças nas bandas oscilatórias Teta e Beta relacionadas aos eletrodos à esquerda (Teta: C3, T7, P3, P7, O1; Beta: Fp1, P7, O1), centrais (Teta: Fz, Cz; Beta: Cz), e à direita (Teta: F4, C4, T8, O2; Beta: C4, T8, P8, O2) entre três condições de dificuldade (fácil, normal e difícil).

Em outro estudo (ALAKUS; GONEN; TURKOGLU, 2020), os autores usaram sinais de EEG de seu próprio conjunto de dados, denominado GAMEEMO. Os dados foram utilizados para distinguir emoções positivas e negativas. A investigação começou com a determinação da entropia espectral dos sinais. Em seguida, foi usado um algoritmo de classificação para diferenciar as emoções pretendidas. A arquitetura de memória de longo prazo bidirecional profunda (BiLSTM) foi empregada como algoritmo classificador. A abordagem resultou em 76,91% de acurácia e uma área sob a curva de característica operacional do receptor (ROC, do termo em inglês) de 90% .

Em resumo, a literatura conta com um acervo de pesquisas que relacionam jogos digitais e classificação de emoções a partir de sinais de EEG. No entanto, uma das principais deficiências da atual literatura é ausência do uso de teorias psicológica promissoras, como a lateralização da emoção, e a exploração de seus impactos nos algoritmos de classificação. O presente estudo pretende incentivar, a partir dos resultados mostrados neste

trabalho, que tal caminho é promissor, de forma que possamos melhor compreender os processos relacionados à emoção que ocorrem no cérebro.

2. OBJETIVO

2.1. OBJETIVO GERAL

O objetivo deste trabalho é analisar a classificação de quatro emoções (alegria, calma, tristeza, raiva) induzidas por jogos digitais, usando características que levam em consideração as teorias da lateralização cortical.

2.2. OBJETIVOS ESPECÍFICOS

- Desenvolver formas de extração de características que levam em consideração as teorias da lateralização de valência, dominância do hemisfério direito e lateralização de aproximação-retirada.
- Desenvolver um sistema computacional capaz de analisar e determinar o estado emocional do sujeito de forma automatizada.
- Criar um método de otimização de hiperparâmetros do sistema computacional que possibilite a reprodução dos resultados.
- Comparar os resultados obtidos dos classificadores em cada um dos três cenários de lateralização emocional.
- Buscar evidências da possível ocorrência dos fenômenos evidenciados através das teorias da lateralização de valência, dominância do hemisfério direito e lateralização de aproximação-retirada, a partir dos resultados obtidos e trabalhos na literatura.

3. REFERENCIAL TEÓRICO

3.1. LATERALIZAÇÃO HEMISFÉRICA

As pesquisas acerca da neurociência afetiva debatem com frequência a questão de como o cérebro se organiza para processar emoções, com ênfase considerável na lateralização desses processos entre os dois hemisférios do cérebro. Para a expressão comportamental da emoção, evidências sugerem que as regiões anteriores do cérebro são organizadas de

forma assimétrica, com o hemisfério cerebral esquerdo especializado no processamento de emoções positivas ou relacionadas à aproximação, e o hemisfério direito, especializado no processamento de emoções negativas ou relacionadas à retirada (esquiva). Para a percepção de estímulos emocionais, no entanto, a evidência de lateralização tem sido menos consistente (PEREIRA; KHAN, 2017).

As três principais teorias sobre a questão da lateralização cerebral da percepção emocional, de acordo com Pereira e Khan (2017), são:

I) Hipótese de aproximação-retirada (AP): afirma que as emoções que provocam comportamentos de aproximação (como raiva e alegria) são lateralizadas para o hemisfério esquerdo, enquanto as emoções que provocam comportamentos de retirada (como tristeza e calma) são lateralizadas para o hemisfério direito.

II) Hipótese do Hemisfério Direito (R): afirma que o hemisfério direito do cérebro é especializado na percepção, expressão e experiência da emoção.

III) Hipótese de valência (V): afirma que o hemisfério direito é dominante para emoções negativas e o hemisfério esquerdo é dominante para emoções positivas

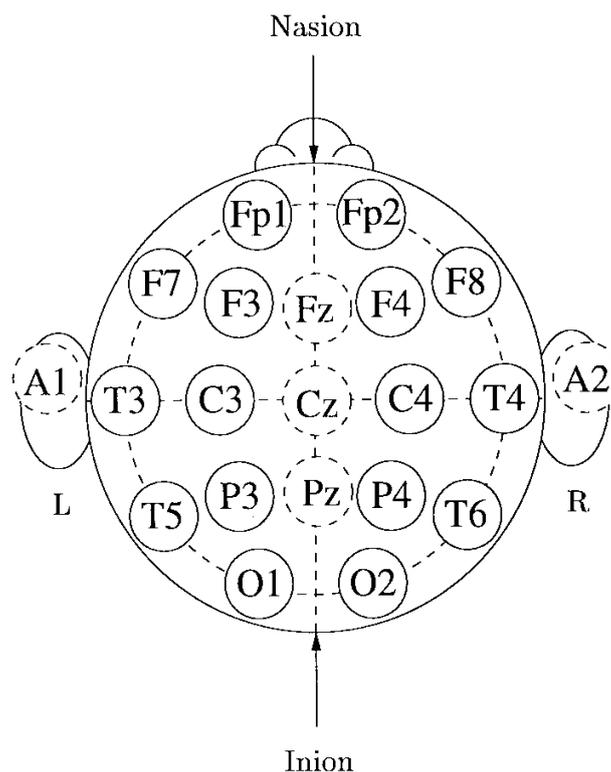
3.2. SINAIS DE ELETROENCEFALOGRAFIA E SEU PROCESSAMENTO

O eletroencefalograma (EEG) é um método não invasivo amplamente utilizado para monitorar sinais cerebrais. Baseia-se na colocação de eletrodos de metal no couro cabeludo que medem os pequenos potenciais elétricos que surgem devido à ação neuronal dentro do cérebro. Seus principais benefícios, em comparação com outras técnicas de imagem cerebral, são que ela tem uma resolução temporal muito alta - capaz de rastrear eventos dentro do cérebro com precisão de milissegundos - e que é, em princípio, portátil. Como resultado, o EEG se apresenta como uma modalidade de detecção muito utilizada para uma variedade de aplicações de saúde e bem-estar, desde o diagnóstico de epilepsia até o monitoramento emocional (CASSON *et. al.* 2018).

Os sinais de EEG variam temporal e espacialmente e por isso vários eletrodos são usados simultaneamente, posicionados, em geral, seguindo o chamado padrão 10-20, que é baseado na relação entre a localização de um eletrodo e a área subjacente do córtex cerebral. Os números 10 e 20 indicam as distâncias entre os eletrodos adjacentes, que deve ser 10% ou 20% das dimensões do crânio (BINNIE *et. al.* 1982).

A disposição dos eletrodos no padrão 10-20 pode ser observada na Figura 1. Cada eletrodo possui uma letra e um número de identificação: as letras se referem ao lóbulo (F de frontal, T de temporal, C de central, P de parietal e O de occipital) e os números se referem aos hemisférios (números pares para o hemisfério direito e ímpares para o hemisfério esquerdo); já a letra z indica a linha média (ALARCÃO; FONSECA, 2019).

Figura 1- Sistema internacional 10/20.



Fonte: (WARD *et. al.* 1999).

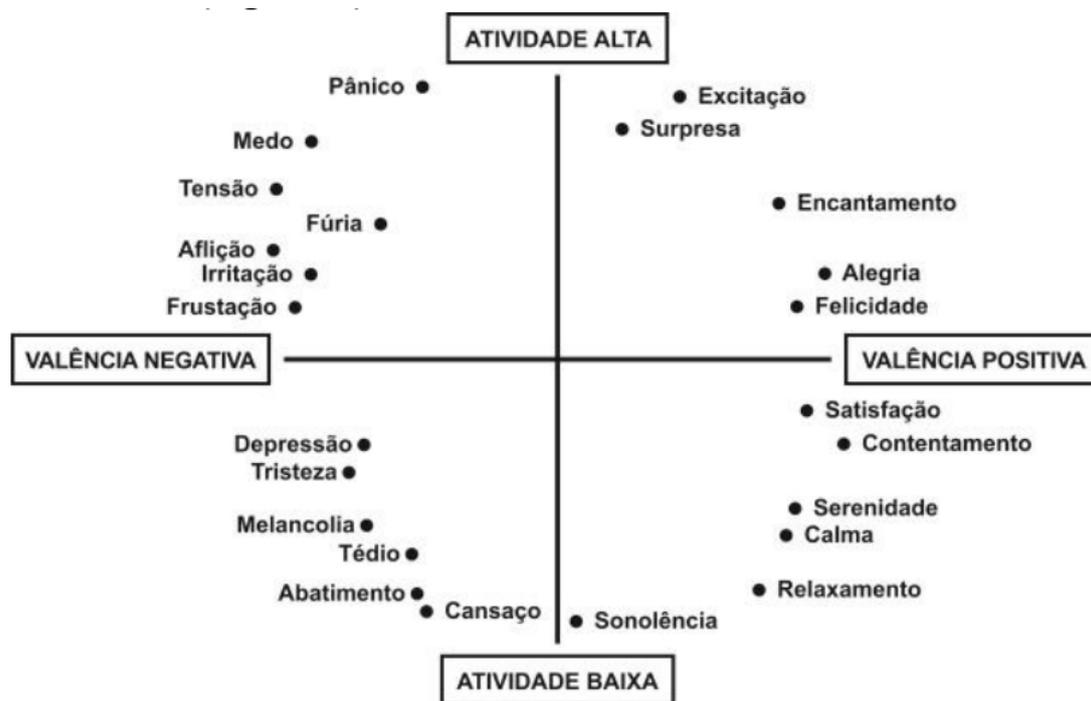
Os sinais de EEG são altamente sensíveis a movimentos do sujeito, a ruídos externos, assim como a movimentos oculares, musculares e à interferência de dispositivos elétricos próximos. O movimento no corpo humano altera a condutividade do eletrodo ou as reações físico-químicas ocorridas nos locais dos eletrodos e resultam nos chamados artefatos. Esses artefatos podem ser categorizados como artefatos musculares (EMG), artefatos glossocinéticos, artefatos de piscar de olhos (EOG), artefatos de movimento dos olhos, artefatos de ECG, artefatos de pulso, artefatos de respiração, artefatos de pele, entre outros. A representação de tais artefatos deve ser devidamente minimizada ou removida para garantir que não haja perda das principais características dos sinais de EEG (ROY, 2021).

3.2. MODELOS DE EMOÇÃO

Os dois tipos de modelos de emoção mais usados na literatura são os modelos de emoções discretas e dimensionais. Modelos de emoções discretas incluem dois tipos de emoções (positivo-negativo) e contêm oito emoções principais, que são raiva, antecipação, alegria, confiança, medo, surpresa, tristeza e nojo. Por outro lado, modelos de espaço dimensional são utilizados para representar emoções em diferentes dimensões como o modelo Valência-Excitação (do inglês, *Valence-Arousal*) (ALAKUS; GONEN; TURKOGLU, 2020).

No modelo de Valência-Excitação, de acordo com Russel (1980), conforme Figura 2, a valência emocional, que corresponde ao eixo X, descreve até que ponto uma emoção é positiva ou negativa. Já a excitação, também chamada de atividade, que corresponde ao eixo Y, e refere-se à sua intensidade.

Figura 2 - Modelo Valência-Excitação



Fonte: (RUSSELL, 1980)

3.3. ANÁLISE WAVELET

A maioria dos sinais da EEG são não estacionários, o que significa que suas propriedades estatísticas mudam ao longo do tempo. A análise tempo-frequência é amplamente utilizada para localizar os eventos de interesse em sinais elétricos. A forma convencional de análise tempo-frequência é a Transformada de Fourier de Tempo Curto (TFTC), onde a transformada de Fourier do sinal é tomada em janelas curtas, resultando no gráfico conhecido como espectrograma (BAJAJ, 2021)

O TFTC não é adequado para analisar sinais não estacionários, como os sinais de EEG, devido ao princípio da incerteza de Heisenberg, onde a resolução de tempo resulta em resolução de frequência mais baixa e vice-versa. Para analisar diferentes frequências com diferentes resoluções, é empregada a técnica de transformada wavelet, que utiliza multirresolução. Além disso, a transformada wavelet pode oferecer menos recursos para o sinal a ser processado, podendo ser adequada para evitar o problema de dimensionalidade associado (ALTURKI et. al., 2020).

De acordo com Alturki *et al.* (2020), as transformadas wavelet analisam as características do sinal nos domínios do tempo e da frequência, decompondo tais sinais em várias funções usando a chamada wavelet mãe. A wavelet mãe é dada pela fórmula a seguir, onde x e y são os parâmetros de escala e deslocamento, respectivamente, e S é o espaço wavelet:

$$\psi(t) = \frac{1}{\sqrt{2}} \psi\left(\frac{t-y}{x}\right) \dots x, y \in S, x > 0 \quad (1)$$

A transformada wavelet é expressa pela equação:

$$F(x, y) = \frac{1}{\sqrt{x}} \int_S \psi\left(\frac{t-y}{x}\right) dt \quad (2)$$

Empregamos a transformada wavelet discreta (DWT, do termo em inglês) porque ela fornece uma representação altamente eficiente e pode ser obtida por meio de algoritmos computacionais. Neste estudo, empregamos a wavelet mãe Daubechies 5 (db5) com cinco níveis de decomposição, que foram empregados por fornecerem um bom número de características para aplicação ao processo de classificação de sinais de EEG.

3.4. CLASSIFICADORES COMPUTACIONAIS

Um classificador é uma sistema computacional que toma valores de várias características (variáveis independentes) em uma amostra (o conjunto de valores de variáveis independentes) e prevê a classe a que esse exemplo pertence (variáveis dependentes). Um classificador tem uma série de parâmetros que devem ser aprendidos a partir de um conjunto de dados de treinamento. O classificador aprendido é essencialmente um modelo do relacionamento entre as características e o rótulo da classe no conjunto de treinamento (PEREIRA; MITCHELL; BOTVINICK.2019).

Depois de treinado, o classificador pode ser usado para determinar se as características usadas contêm informações sobre a classe de uma amostra. Essa relação é testada usando o classificador aprendido em um conjunto diferente de amostras, o conjunto de dados de teste. Intuitivamente, a ideia é que, se o classificador realmente capturou a relação entre as características e classes, ele deve ser capaz de prever as classes de

exemplos que ainda não havia analisado (PEREIR; MITCHELL; BOTVINICK. 2019).

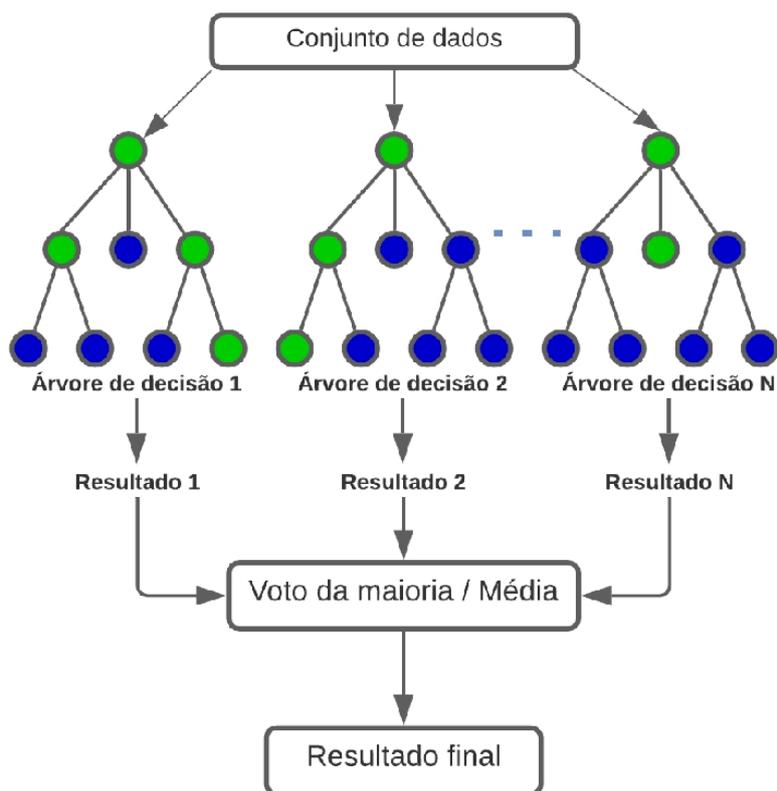
Muito da robustez de um classificador reside na existência de diferentes níveis de complexidade para um modelo, que podem vir a ser escolhidos, assim como as possíveis configurações do algoritmo de treinamento. Estes ajustes impactam diretamente no erro de generalização do modelo. Hiperparâmetros são as variáveis que controlam estas funções, e que precisam de uma definição de valor antes mesmo que o treinamento do modelo seja realizado. Por isto, a estimação do valor ótimo para os hiperparâmetros é fundamental para a obtenção de um modelo com melhor desempenho de predição (DE ALVARENGA JÚNIOR, Wagner José. 2018).

A seguir, serão detalhados os algoritmos computacionais utilizados para o processo de classificação dos sinais de EEG.

3.4.1. Florestas aleatórias

O classificador de floresta aleatória usa um método de aprendizado de agrupamento para classificação que emprega várias árvores de decisão durante a fase de treinamento e gera uma previsão média de árvores individuais. Este classificador gera florestas com quantidade aleatória de árvores. A Figura 3 ilustra um funcionamento geral do classificador. Na figura, cada árvore de decisão aleatória tem uma saída. A votação majoritária é realizada e a saída do classificador é definida como pertencente à classe k se obtiver a maioria dos votos.

Figura 3 - Classificador de floresta aleatória.



Fonte: (EDLA *et. al.* 2018).

Os hiperparâmetros do classificador de florestas aleatórias considerados neste trabalho, de acordo com Ramayanti e Salmah (2018), considerados neste trabalho são os seguintes.:

- *n_estimators*: quantidade de árvores na floresta.
- *criterion*: função usada para medir o grau de qualidade de uma divisão de nó. Em outras palavras, indica como vai ocorrer a busca de características.
- *max_depth*: profundidade máxima das árvores.
- *max_features*: é a quantidade de características a ser considerada ao se definir a melhor divisão.
- *min_sample_splits*: o mínimo de amostras necessárias para dividir um nó interno.
- *min_samples_leaf*: o mínimo de amostras necessárias para estar em um nó da folha.

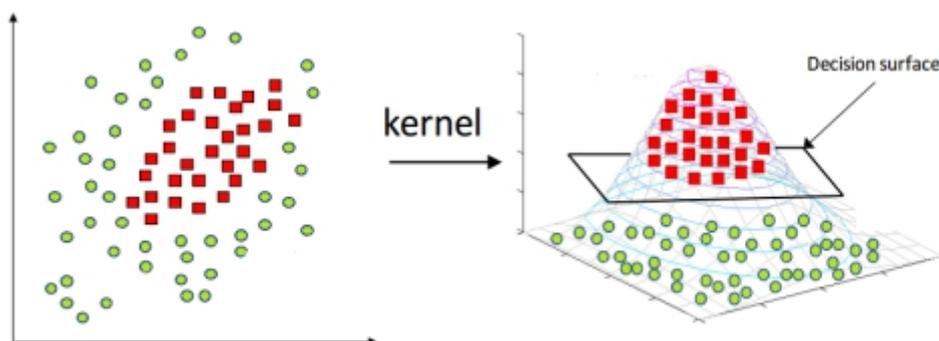
- *bootstrap*: amostras usadas na construção de árvores.

3.4.2. Máquinas de vetor de suporte

A máquina de vetores de suporte (SVC, do termo em inglês) é um método de classificação baseado em teoria de aprendizado estatístico. Para um determinado problema de classificação linearmente separável de duas classes, o SVC tenta encontrar um hiperplano que separa o espaço de entrada com uma margem máxima de separação (BAYRAM; KIZRAK; BOLAT, 2013).

De acordo com Bayram, Kizrak e Bolat (2013), gerar um separador não linear é o conceito principal do SVM. A tarefa de mapeamento de dados para um espaço de alta dimensão é realizada para facilitar a classificação de dados em superfícies de decisão lineares. Assim, a reformulação de dados é realizada para dados mapeados implicitamente para este espaço. A tarefa de reformulação é mostrada na Figura 4.

Figura 4 - Classificação de dados com SVM. O *kernel* refere-se à função de expansão de dimensão.



Fonte: (BAYRAM; KIZRAK; BOLAT, 2013).

Essa transformação é realizada por funções de *kernel*, que podem ser de vários tipos, destacando-se o *kernel Radial Basis Function* (RBF) ou o *kernel* polinomial. Os dados são transformados para um novo espaço com uma maior dimensão por meio da função de *kernel* para facilitar o processo de separação linear. Classificadores SVM podem ser implementados na forma linear ou não linear. O classificador não linear deve implementar a

função de *kernel* especificada para transformar os pontos do conjunto de dados em dimensões mais altas do espaço de recursos (AL-MEJIBLI; ALWAN; ABD DHAFAR, 2020).

Os hiperparâmetros do classificador SVC empregados neste trabalho, ainda de acordo com Al-mejibli, Alwan e Abd Ahafar (2020), são:

- *gamma*: O parâmetro não intuitivo *gamma* define a largura ou inclinação da função do *kernel*.
- *kernel*: função de *kernel*.
- *C*: parâmetro de regularização do classificador.
- *degree*: grau do polinômio (quando usado o *kernel* polinomial).

3.4.3. K-ésimos vizinhos mais próximos

A classificação *k*-NN (do inglês, *k-nearest neighbours*) é um modelo de classificação não paramétrico que é descrito como aprendizado baseado em instância, caracterizado por memorizar o conjunto de dados de treinamento. O algoritmo *k*-NN também é um exemplo típico de um aprendiz preguiçoso, chamado dessa forma não por causa de sua aparente simplicidade, mas porque não aprende uma função discriminativa dos dados de treinamento, mas memoriza o conjunto de dados de treinamento. O aprendizado preguiçoso é um caso especial de aprendizado baseado em instâncias associado a custo zero durante o processo de aprendizado (ISA *et al.*, 2017).

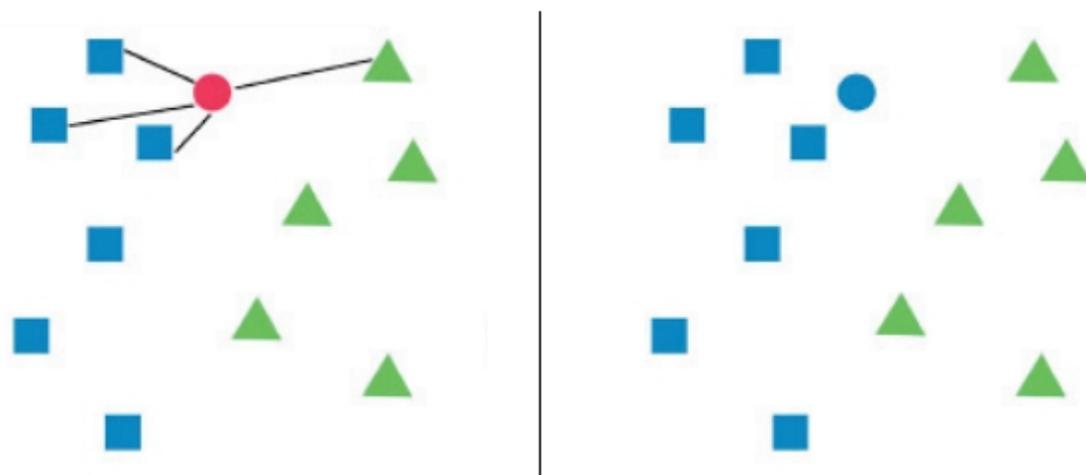
O algoritmo *k*-NN é adequado para classificar dados de EEG, pois é uma técnica robusta para grandes dados ruidosos. As amostras são classificadas pelo voto majoritário da classe de seu vizinho. Para determinar a que classe pertence uma amostra apresentada ao modelo, este algoritmo requer dados de treinamento e um valor *k* predefinido, pois ele buscará no espaço amostral de treinamento as *k* amostras mais semelhantes, com base em uma função de medida de similaridade ou distância. O valor de *k* e a métrica de distância afetarão o resultado da classificação (ISA *et al.*, 2017).

O desempenho desse algoritmo varia amplamente com base nos valores de seus hiperparâmetros. Os hiperparâmetros considerados neste artigo mencionados a seguir desempenham um papel crucial na determinação da saída do algoritmo (ISA *et al.*, 2017).

- *n_neighbors*: Número de vizinhos a serem usados por padrão.
- *weights*: A função peso afeta a previsão das classes, pois determina a maneira como os pontos são tratados. Por exemplo, os pontos mais próximos podem ter maior influência do que os pontos mais distantes.
- *algorithm*: Existem diferentes algoritmos usados para calcular os vizinhos mais próximos.
- *metric*: Este parâmetro especifica a métrica de distância que deve ser usada para calcular a distância no algoritmo

A Figura 5 retrata o funcionamento do classificador *k*-NN. Na figura, pode-se observar que o ponto vermelho é classificado como azul usando a regra dos vizinhos mais próximos.

Figura 5 - Funcionamento do algoritmo *k*-NN



Fonte: (RANJAN; ERMA; RADHIKA, 2019).

3.5. OTIMIZAÇÃO DE HIPERPARÂMETROS

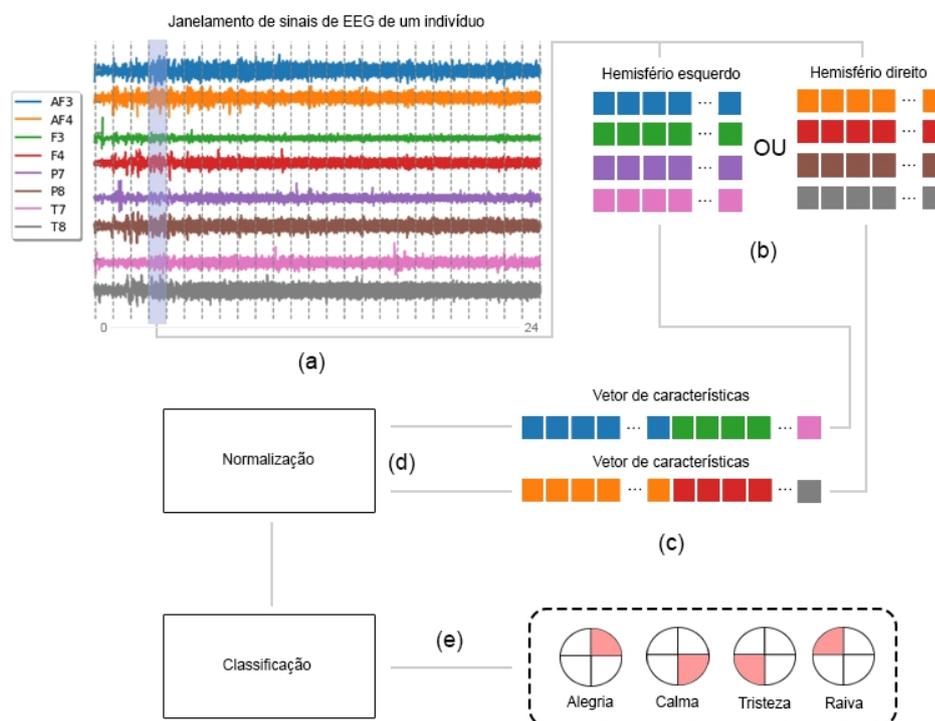
A otimização de hiperparâmetros tem relação com a natureza de busca do problema de otimização dos classificadores. Existem diferentes estratégias de busca para encontrar um conjunto de parâmetros com um desempenho aceitável. Neste trabalho, foram usados dois algoritmos: a otimização *bayesiana* sobre hiperparâmetros e a pesquisa de grade com validação cruzada de 10 *folds* (*Grid Search CV*, do inglês). A pesquisa de grade é uma abordagem para ajuste de parâmetros que constrói e avalia metodicamente um modelo para cada combinação de parâmetros de algoritmo especificados em uma grade (RANJAN; ERMA; RADHIKA, 2019).

Na otimização *bayesiana*, ao contrário do *Grid Search CV*, nem todos os valores de parâmetros são testados, mas um número fixo de configurações de parâmetro é amostrado das distribuições especificadas. Trata-se de um algoritmo de busca informada, o que significa que cada iteração deste algoritmo aprende com a anterior, e os resultados de uma iteração ajudam na criação da próxima. O algoritmo vê o processo de ajuste de hiperparâmetros como a otimização de uma função caixa-preta. Qualquer estrutura de otimização global pode ser aplicada para minimizar essa função (ELGELDAWI *et al.*, 2021).

4. MATERIAL E MÉTODOS

Para alcançar os objetivos propostos neste trabalho, algumas etapas foram seguidas. Observando-se a Figura 6, temos a seguinte sequência metodológica: (a) aquisição e pré-processamento dos dados; (b, c) extração e seleção de características, (d) normalização; e (e) classificação de emoções com base no modelo valência-excitação. Estas etapas serão detalhadas a seguir.

Figura 6 - Fluxo de operações usadas no trabalho.



Fonte: O Autor

4.1 AQUISIÇÃO DOS DADOS

Neste trabalho, foi utilizada uma base de dados pública disponível gratuitamente na Internet para investigar as hipóteses de lateralização hemisférica no contexto de classificação de emoções. A base será descrita a seguir em detalhes.

4.2. GAMEEMO

A base de dados GAEMEMO (ALAKUS; GONEN; TURKOGLU, 2020) consiste em sinais de EEG coletados de 28 indivíduos diferentes com um dispositivo de EEG portátil denominado EMOTIV EPOC+, de 14 canais. Os participantes jogaram 4 jogos de computador diferentes que supostamente induziam emoções (alegria, calma, tristeza, raiva) por 5 minutos, enquanto os sinais de EEG eram coletados, resultando em sinais com 20 minutos no total. Os sujeitos avaliaram cada jogo com base na escala de excitação e valência, aplicando o formulário SAM (do inglês, *Self-Assessment Manikin*), que foi incluído na pesquisa pelos autores. O Self-Assessment Manikin (SAM), de

acordo com Bradley e Lang (1994), é uma técnica de avaliação pictórica não verbal que mede diretamente o prazer, a excitação e o domínio associados à reação afetiva de uma pessoa a uma ampla variedade de estímulos, o que justifica a escolha do método.

Os sinais de EEG foram coletados pelos autores usando 14 canais, o que resulta em um conjunto de dados com 1568 sinais de EEG (4 jogos × 14 canais × 28 sujeitos) disponíveis com duração de 20 minutos. Os sinais na base estão disponíveis em uma versão pré-processada, com eliminação de ruídos e artefatos, sendo estes os que foram selecionados para o processo de classificação usado neste trabalho.

As emoções correspondentes a cada jogo são: G1 - Raiva, G2 - Calma, G3 - Tristeza, G4 - Alegria. A seguir são apresentadas as descrições de cada jogo dada pelos autores e os motivos pelos quais foram utilizados para representar estas emoções.

- Train Sim World (G1): É um jogo de simulação, e faz com que os jogadores controlem um trem. Quase todos os participantes não entenderam o jogo e apenas apertaram alguns botões aleatoriamente no teclado.
- Unravel (G2): É um jogo relaxante, pois os tipos de música, sons e a atmosfera do jogo são lentos e aliviadores. Os sujeitos controlavam o fio que tenta consertar os laços rompidos das pessoas. Isso estimulou seu cérebro e eles pareciam relaxados.
- Slender – The Arrival (G3): Neste jogo, os jogadores descobrem uma casa e muitos quartos, e o objetivo é escapar do local. Os jogadores não têm nenhum material, exceto uma câmera que brilha nos lugares escuros. A atmosfera é bastante escura e os sons são muito perturbadores.
- Goat Simulator (G4): Neste jogo, os jogadores controlam uma cabra e realizam algumas tarefas consideradas engraçadas, incluindo atacar casas, lambear paredes, pular, entre outras. A atmosfera e os sons são muito charmosos, e foi observado que a maioria dos sujeitos tinha um sorriso no rosto enquanto jogava este jogo.

4.3. PRÉ-PROCESSAMENTO DOS SINAIS

Embora tenhamos usado uma versão pré-processada dos sinais de EEG disponibilizados, usamos o método *all-mean* para subtrair o valor médio de todos os 14 eletrodos dos valores de cada eletrodo de cada sinal por jogo. Este processo é denominado de re-referenciamento pela média e se justifica, pois a atividade registrada nos eletrodos próximos aos eletrodos de registro pode cancelar ou influenciar significativamente a atividade cerebral registrada pelo eletrodo em consideração.

Após o re-referenciamento pela média, os sinais de EEG foram segmentados em janelas de 12 segundos, sem sobreposição dos segmentos, resultando em 25 segmentos para cada sinal. Os sinais foram então salvos como um novo conjunto de dados para cada tamanho de janela. Como resultado dessa operação, o tamanho dos dados foi multiplicado pelo número de segmentos utilizados.

4.4. EXTRAÇÃO DE CARACTERÍSTICAS

A transformada wavelet discreta (DWT) foi empregada para extrair características de tempo-frequência. Cada fragmento resultante do janelamento foi decomposto a partir da transformada wavelet com cinco níveis de decomposição. O filtro de 2ª ordem Daubechies foi aplicado e coeficientes de detalhe D2, D3, D4 e D5 foram coletados, para posterior extração de características do domínio de tempo-frequência.

Já para extração de características do domínio do tempo, as bandas Alfa (4-8Hz), Beta (8-16Hz), Gama (16-32Hz) e Delta (32Hz-63.9Hz) foram extraídas através de filtros de Butterworth de 5ª ordem de cada fragmento resultante do janelamento. Há diversos estudos na literatura, como os trabalhos de LIU, Yong-Jin *et. al.* (2017), LI, Peiyang *et al.* (2019) e FRIEDMAN, Doron *et. al.* (2015), que associam mudanças nas bandas alfa, beta, gama e delta a detecção de emoções.

A extração de características é feita em quatro canais do hemisfério esquerdo (AF3, F3, P7, T7) ou hemisfério direito (AF4, F4, P8, T8) de forma independente, conforme esquema de lateralização cortical mostrado na Tabela 1. Tais canais pertencem às regiões do lobo frontal, lobo parietal, lobo occipital e lobo temporal. Existem diversos estudos que mostram que os lobos frontal, parietal e temporal são áreas comuns do cérebro que estão ativas durante o processamento de emoções (MSONDA; HE; LU, 2021; ZHANG *et. al.*, 2020; TOPIC *et. al.*, 2022).

Para a hipótese do hemisfério direito (R), considera-se que as emoções têm prevalência nos eletrodos relacionados ao hemisfério direito. Portanto, foram considerados apenas os eletrodos do hemisfério direito. Já a Hipótese de valência (V): afirma que o hemisfério direito é dominante para emoções negativas e o hemisfério esquerdo é dominante para emoções positivas. A Hipótese de aproximação-retirada (AP), por sua vez, afirma que as emoções que provocam comportamentos de aproximação (raiva, alegria) são lateralizadas para o hemisfério esquerdo, enquanto as emoções que provocam comportamentos de retirada (negativas) são lateralizadas para o hemisfério direito (tristeza, calma). Para as duas últimas hipóteses, foram considerados os eletrodos do hemisfério esquerdo e direito.

As características foram extraídas de cada canal de forma independente e depois foram fundidas, e rotuladas conforme Tabela 1, formando um único vetor de características com as dimensões destacadas na Tabela 3.

Tabela 1 - Extração de características por hemisfério, considerando os esquemas de lateralização avaliados: Hipótese de aproximação-retirada (AP); Hipótese do Hemisfério Direito (R), Hipótese de Valência (V), Todos os eletrodos (T)..

Extração de características por Hemisfério		
Esquema	Hemisfério esquerdo (AF3, F3, P7, T7)	Hemisfério Direito (AF4, F4, P8, T8)
R	-	G1, G2, G3, G4
V	G4, G2	G1, G3
AP	G1, G4	G2, G3
T	G1, G2, G3, G4	G1, G2, G3, G4

Fonte: O autor.

Tabela 2- Jogos e emoções correspondentes

Jogo (Rótulo)	Modelo Valência- Excitação	Emoção	Jogo
G4	Alta excitação Valência positiva	alegria	Goat Simulator
G3	Alta excitação valência negativa	tristeza	Slender – The Arrival
G1	Baixa excitação valência positiva	raiva	Train Sim World:
G2	Baixa excitação valência negativa	calma	Unravel

Fonte: AKUKU, adaptado.

A seguir, serão detalhadas as medidas, tanto no domínio temporal quanto no domínio tempo-frequência, utilizadas nos vetores de características.

4. 5. VETOR DE CARACTERÍSTICAS

A Tabela 3 mostra um resumo das características extraídas de quatro canais de cada hemisfério, conforme Figura 6 (b), das regiões do lobo frontal, lobo parietal, lobo occipital e lobo temporal, que foram usadas nos classificadores considerados, assim como as dimensões resultantes dos vetores de características. Tais características são amplamente utilizadas em detecção de emoções em sinais de eletroencefalograma, como mostram os trabalhos de Chen *et al.* (2020), Alakuş e Türkoğlu, (2019), e PANE *et. al.* (2019).

Tabela 3 - Características de domínio de tempo e domínio de tempo-frequência.

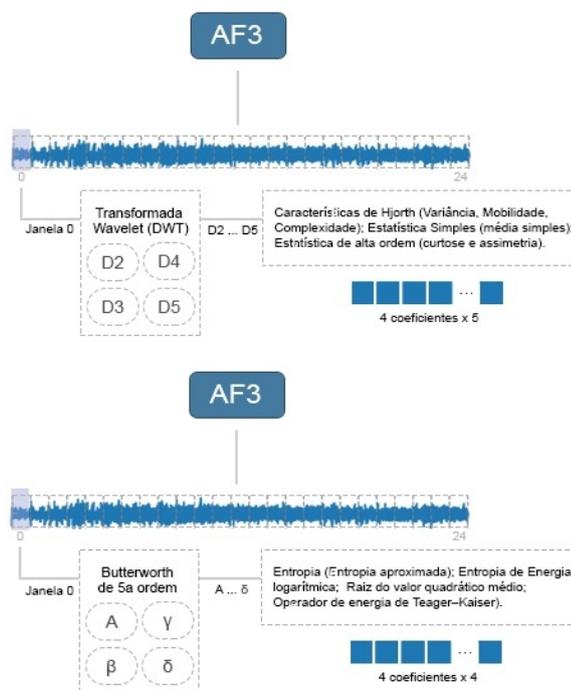
Tipos	Características	Dimensão do vetor de características
Domínio de tempo (6 características)	Características de Hjorth (Variância, Mobilidade, Complexidade); Estatística Simples (média simples); Estatística de alta ordem (curtose e assimetria).	2800 x 96
Domínio de tempo-frequência (4 características)	Entropia (Entropia aproximada); Entropia de Energia logarítmica; Raiz do valor quadrático médio; Operador de energia de Teager–Kaiser.	2800 x 80

Fonte: O autor.

Na Tabela 3, o vetor de características tem dimensão de 2800 amostras, sendo o número de amostras resultantes do processo de janelamento. As 96 características do domínio do tempo correspondem a 4 canais x 4 coeficientes wavelet x 6 características de domínio do tempo. Já as 80 características do domínio de tempo-frequência correspondem a 4 canais x 4 bandas (alfa, beta, gama, delta) x 5 características de domínio de tempo-frequência.

A Figura 7 mostra o processo de extração de características de um canal para cada esquema de lateralização, para cada janela das variáveis do domínio de tempo e de tempo-frequência, respectivamente, ilustrando desde o re-referenciamento pela média até a segmentação em janelas de 12 segundos, sem sobreposição dos segmentos, resultando em características dos 25 segmentos para cada sinal.

Figura 7 - Detalhamento do processo de obtenção das características para um dos canais considerados (AF3). O processo se repete para os demais canais.



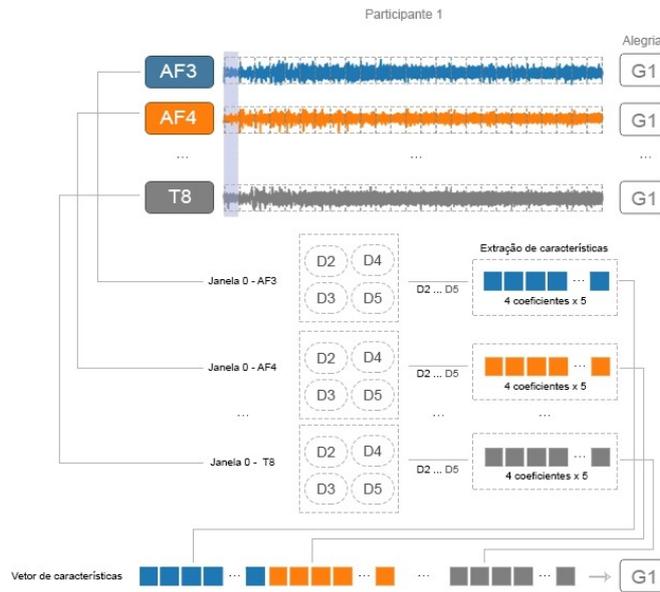
Fonte: O autor.

As características foram extraídas de cada canal, conforme Tabela 1, de forma independente e depois foram fundidas, formando um único vetor de características. A Figura 8 ilustra o processo de fusão de cada amostra do conjunto de dados. No esquema T, que envolve todos os eletrodos, os vetores de ambos os domínios são combinados para formar um único vetor, conforme Tabela 4. De acordo com Guodong e Yahan (2021), a fusão de característica vem sendo amplamente utilizada na literatura de reconhecimento de emoções.

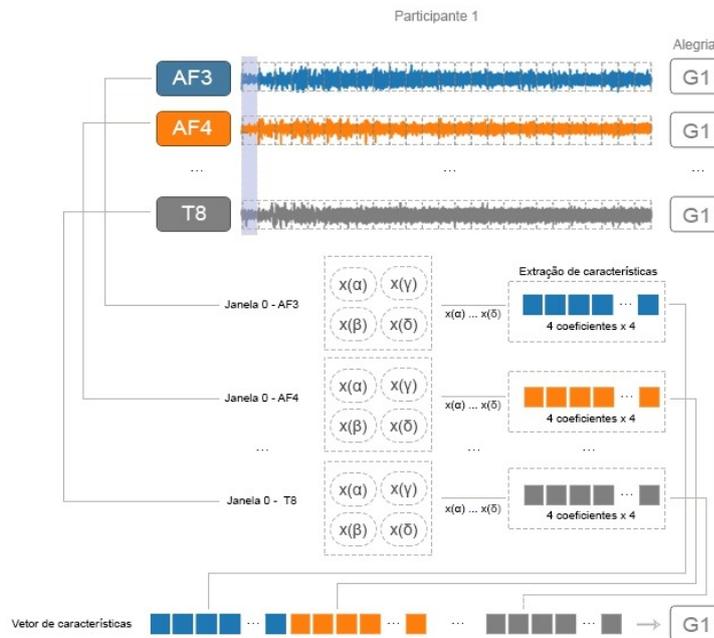
A fusão das características no esquema T se dá para normalizar os valores dos hiperparâmetros de cada classificador da dissertação, bem como para criar um cenário único que não envolve lateralização para comparação com os demais casos. A partir do uso dos hiperparâmetros de forma normalizada, foi possível identificar para qual domínio de características as hipóteses de lateralização tiveram mais peso na performance de cada classificador, uma vez que o teste de hipóteses de lateralização, na presente dissertação, se dá através de mudanças do vetor de características do esquema T. Por isso, consideramos apenas um domínio de cada vez para cada hipótese de lateralização, conforme Tabela 4.

Figura 8 - Detalhamento do processo de fusão de características em um único vetor: (a) domínio tempo-frequência; (b) domínio do tempo.

(a)



(b)



Fonte: O autor.

Tabela 4 - Vetor de características de cada esquema de canais

Esquema	Canais		Vetor de características	Domínios	
	Hemisfério Esquerdo	Hemisfério Direito		Tempo	Tempo-frequência
T	G1, G2, G3, G4	G1, G2, G3, G4	2800 x 352	X	X
R	-	G1, G2, G3, G4	2800 x 96	X	
			2800 x 80		X
V	G4, G2	G1, G3	2800 x 96	X	
			2800 x 80		X
AP	G1, G4	G2, G3	2800 x 96	X	
			2800 x 80		X

Fonte: o autor

4.6. CARACTERÍSTICAS DO DOMÍNIO DO TEMPO

4.6.1. Parâmetros de Hjorth

Os parâmetros de Hjorth são obtidos aplicando técnicas de processamento de sinal no domínio do tempo, dando uma visão das propriedades estatísticas do sinal. Os três parâmetros de Hjorth são: atividade, mobilidade e complexidade. Estes são descritas a seguir, de acordo com YUEN *et al.* (2013).

A atividade fornece uma medida da variância da amplitude de um sinal contínuo $x(t)$, indicando a superfície do espectro de potência no domínio da frequência. Ou seja, o valor da atividade é elevado se as componentes de frequência mais alta forem mais comuns e baixo, caso contrário. A atividade é representada pela equação:

$$\text{Atividade} = \text{var}(x(t)) \quad (3)$$

em que $\text{var}(\bullet)$ representa a variância de uma grandeza.

A mobilidade representa a frequência média ou a proporção do desvio padrão do espectro de potência. Isso é definido como a raiz quadrada da atividade da primeira derivada do sinal dividida pela atividade do sinal, dada por:

$$\text{Mobilidade} = \sqrt{\frac{\text{Atividade}(x'(t))}{\text{Atividade}(x(t))}} \quad (4)$$

A complexidade indica como a forma de um sinal é semelhante a uma onda senoidal pura e fornece uma estimativa da largura de banda do sinal. É definida como a razão entre a mobilidade da primeira derivada e a mobilidade do sinal:

$$\text{Complexidade} = \frac{\text{Mobilidade}(x'(t))}{\text{Mobilidade}(x(t))} \quad (5)$$

Para o presente projeto, estas grandezas foram adaptadas para serem usadas com sinais discretos.

4.6.2. Parâmetros estatísticos

A estatística de alta ordem dos sinais das sub-bandas permitem descobrir as características latentes encapsuladas nos sinais de EEG relacionadas a diferentes emoções (SHAHNAZ *et al.*, 2013).

A assimetria (*skewness*) mede o grau de assimetria de uma distribuição em torno de sua média e a curtose (*kurtosis*) é a medida do peso relativo da cauda de uma distribuição em relação à distribuição normal. Assumindo um sinal discreto X_n , $n = 1, 2, 3, \dots, n$, de média zero, a assimetria normalizada e curtose podem ser definidas pelas seguintes expressões, respectivamente (JERRITTA *et al.*, 2014):

$$\text{Assimetria} = \frac{\sum_{n=1}^N (X_n - \mu_x)^3}{(N-1)\sigma_x^3}, \quad (6)$$

$$\text{Curtose} = \frac{\sum_{n=1}^N (X_n - \mu_x)^4}{(N-1)\sigma_x^4} - 3 \quad (7)$$

Já a média simples é dada por:

$$\text{Média} = \frac{1}{N} \sum_{n=1}^N X_n \quad (8)$$

4.7. CARACTERÍSTICAS DO DOMÍNIO DE TEMPO-FREQUÊNCIA

4.7.1. Entropia aproximada

A entropia aproximada (ApEn) é uma medida que quantifica a complexidade ou irregularidade de uma série temporal. Um maior valor de ApEn significa mais complexidade e irregularidade do sinal. A estimativa robusta de ApEn pode ser obtida usando conjuntos de dados curtos e ruidosos. A obtenção desta grandeza seguiu a definição de (KUMAR; DEWAL; ANAND, 2012).

4.7.2. Entropia de energia logarítmica

De acordo com Harlalka *et al.* (2018), a aleatoriedade do sinal é medida pela entropia. Em outras palavras, ela reflete a quantidade de informação no sinal dado. A entropia de energia logarítmica é dada por:

$$H_{\log En}(x) = - \sum_{i=0}^{N-1} (\log_2(p_i(x)))^2 \quad (9)$$

onde $p_i(x)$ representa a probabilidade de ocorrência do i -ésimo estado de um sinal x .

4.7.3. Raiz do valor quadrático médio

A raiz do valor quadrático médio dos coeficientes wavelet foi calculado usando a equação (Abu Osman *et al.*, 2008).

$$RMS(j) = \sqrt{\frac{\sum_{i=1}^j \sum_{n_i} D_i[n]^2}{\sum_{i=1}^j n_i}} \quad (10)$$

onde D_i e n_i são os coeficientes de detalhe e o número de coeficientes de detalhe no nível de decomposição da transformada wavelet. O vetor de características é obtido a partir de $RMS(j)$, onde $j = 1, 2, 3, \dots, N$, e N é o nível mais profundo de decomposição.

4.7.4. Operador de energia de Teager–Kaiser

O operador de energia de Teager-Kaiser (TK), de acordo com Boudraa e Salzenstein (2018), enfatiza a importância de analisar os sinais do ponto de vista da energia do sistema necessária para produzi-los. Em sua forma contínua, o operador de energia TK, quando operando no sinal de tempo contínuo $x(t)$, é dado por:

$$\begin{aligned}\Psi_c[x(t)] &\triangleq \left(\frac{dx(t)}{dt}\right)^2 - x(t)\left(\frac{d^2x(t)}{dt^2}\right) \\ &= \dot{x}^2(t) - x(t)\ddot{x}(t)\end{aligned}\quad (11)$$

Usando, por exemplo, a aproximação inversa das derivadas de tempo, a mesma função em tempo discreto torna-se:

$$\Psi_d[x(n)] = \frac{x^2(n-1) - x(n)x(n-2)}{(\Delta t)^2} \quad (12)$$

A Equação (12) é redimensionada e centralizada, produzindo a característica usada neste trabalho, dada por:

$$\Psi_d[x(n)] = x^2(n) - x(n-1)x(n+1) \quad (13)$$

4.8. NORMALIZAÇÃO

Após a extração de características, para que não houvesse dominância em amplitude de nenhuma característica, os dados foram normalizados. Para isso, foi utilizado o método *MinMaxScaler*. Este estimador dimensiona e converte cada característica individualmente de modo que ela esteja em uma faixa de valores definida para o conjunto de treinamento, por exemplo, entre zero e um (SCIKIT-LEARN, 2020).

Esta transformação considera o valor mínimo (X_{min}) e o valor máximo (X_{max}) de cada variável X e o converte para o valor normalizado denominado $X_{escalado}$, obtido a partir das equações:

$$X_{std} = \frac{(X - X_{min})}{X_{max} - X_{min}} \quad (14)$$

$$X_{escalado} = X_{std} * (X_{max} - X_{min}) + X_{min} \quad (15)$$

A normalização de dados foi utilizada pelo fato de a mesma fazer com que as relações lineares entre as características fiquem mais expostas, preservando a forma da distribuição original do vetor de características. (SCIKIT-LEARN, 2020).

4.9. OTIMIZAÇÃO DE HIPERPARÂMETROS

Nas Tabelas 5, 6 e 7, são mostrados os hiperparâmetros (ou espaço de busca) de cada classificador considerado neste trabalho. O símbolo U significa uniformemente distribuído e log U significa uniformemente distribuído no domínio logarítmico. A configuração abaixo foi usada no processo de otimização bayesiana com 50 iterações para todos os classificadores dos esquema T, com diferentes grupos de características de tamanhos variados escolhidos de forma randômica usados como parâmetro para o processo de otimização, 10 vezes seguidas. Do conjunto de hiperparâmetros, aquele que apresentou um maior desempenho médio total dos três classificadores, são utilizados para todas as outras hipóteses testadas. O objetivo desse processo é encontrar os melhores hiperparâmetros para o esquema T de forma não exaustiva para fins de comparação. Nesse artigo, foi empregada a validação com 10 grupos como parâmetro do otimizador bayesiano.

Tabela 5 – Espaço de busca - Florestas Randômicas

Florestas Randômicas			
Parâmetro	Priori	Parâmetro	Priori
min_samples_leaf	log U(1e-6,0.5)	n_estimators	U(70,100)
min_samples_split	log U(1e-6,1)	max_features	auto, sqrt
bootstrap	True, False	max_depth	U(1,50)
criterion	gini, entropy	-	-

Fonte: O Autor.

Tabela 6 – Espaço de busca - KNN

KNN			
Parâmetro	Priori	Parâmetro	Priori
n_neighbors	U(1,51)	leaf_size	U(1,200)
metric	euclidean, manhattan, chebyshev, minkowski	-	-

Fonte: O Autor.

Tabela 7 – Espaço de busca - SVC

SVC			
Parâmetro	Priori	Parâmetro	Priori
C	log U(1e-6,100)	degree	U(1,20)
gamma	log U(1e-6,100)	kernel	rbf, poly

Fonte: O autor.

4.9. AVALIAÇÃO DE DESEMPENHO

Para avaliar o desempenho dos classificadores empregados e das técnicas empregadas, foi usada a medida *f1-score*, que é uma métrica usada para medir a acurácia de classificadores multi-classe (SAPUTRI; MAHENDRA; ADRIANI, 2018).

O *f1-score* foi empregado na validação cruzada, que é um procedimento usado para reamostrar os dados disponíveis para avaliar modelos de aprendizado de máquina. O número de grupos em que os dados são divididos é determinado pelo parâmetro *k*. Em seguida, ele divide todo o conjunto de dados em *k* grupos. Cada grupo é tomado como dados de teste, enquanto os outros grupos atuam como dados de treinamento. As pontuações de avaliação são armazenadas para cada grupo e resumidas no final para verificar o desempenho dos modelos (RANJAN; VERMA; RADHIKA, 2019).

Foi avaliada a confiabilidade dos classificadores usando a medida Kappa de Cohen. A métrica Kappa de Cohen é frequentemente usada para testar a confiabilidade entre observadores, que no caso, são as classes de emoção consideradas. A importância da confiabilidade do avaliador reside no fato de que ela representa o quanto os dados coletados no estudo são representações corretas das variáveis medidas. Cohen sugeriu que o resultado Kappa fosse interpretado da seguinte forma: valores ≤ 0 como indicando nenhuma concordância, 0,01–0,20 como nenhuma a leve, 0,21–0,40 como regular, 0,41–0,60 como moderado, 0,61–0,80 como substancial e 0,81–1,00 como quase acordo perfeito (MCHUGH, 2012).

O procedimento de validação cruzada é repetido por 30 vezes para cada conjunto de classificadores do domínio de tempo-frequência e do domínio de tempo, respectivamente, de forma a gerar uma amostra com tamanho suficiente para realização do teste-t entre o esquema T, que simboliza a ausência de lateralização, e as hipóteses lateralização de valência (V), dominância do hemisfério direito (R) e lateralização de aproximação-retirada (AP).

O teste-t quantifica a diferença entre as médias aritméticas de duas amostras. O valor-p quantifica a probabilidade de observar valores iguais ou mais extremos assumindo a hipótese nula, que as amostras são extraídas de populações com as mesmas médias populacionais, é verdadeira. Um valor-p maior que 5% indica que nossa observação não é tão improvável de ter ocorrido por acaso. Portanto, não rejeitamos a hipótese nula de médias populacionais iguais. Se o valor-p for menor que nosso limite de 5%, então temos evidências contra a hipótese nula de médias populacionais iguais (SCIPY, 2021).

Analisamos os resultados de cada amostra usando gráficos boxplots. As partes superior e inferior da caixa representam os percentis 75 e 25, respectivamente, uma linha horizontal na caixa identifica a mediana e os traços na parte superior ou inferior são os valores mais altos e mais baixos, excluindo valores atípicos (do inglês, *Outliers*). Tais valores são representados com losangos e são definidos como valores que se estendem de 1,5 a 3 comprimentos de caixa abaixo do 25º percentil ou acima do 75º percentil (HO, Francis *et. al.* 2008).

5. RESULTADOS

A seguir, serão apresentados os resultados obtidos aplicando a metodologia descrita. Serão mostrados os resultados da otimização bayesiana com validação cruzada de 10 grupos para a base de dados utilizada e para as três abordagens de lateralização hemisférica utilizadas em cada uma delas, na classificação dos quatro jogos da base de dados GAMEEMO.

5.1. DOMÍNIO DE TEMPO-FREQUÊNCIA

A Tabela 8 mostra a média dos valores de desempenho de 9 classificadores quando foram empregadas as características no domínio tempo-frequência para os três modelos de classificadores utilizados, sendo um modelo RF, SVC e KNN para cada um dos esquemas de lateralização cortical.

Na tabela, as características do domínio tempo-frequência extraídas dos canais do esquema de lateralização V (hipótese da valência) apresentaram a melhor acurácia em apenas um dos classificadores propostos. Os piores resultados de acurácia se deram usando-se os classificadores para o esquema de lateralização R, que apresentou uma grande discrepância de acurácia em relação aos demais. Observa-se também um índice de confiabilidade substancial.

Tabela 8 - Acurácias dos classificadores usando características no domínio tempo-frequência.

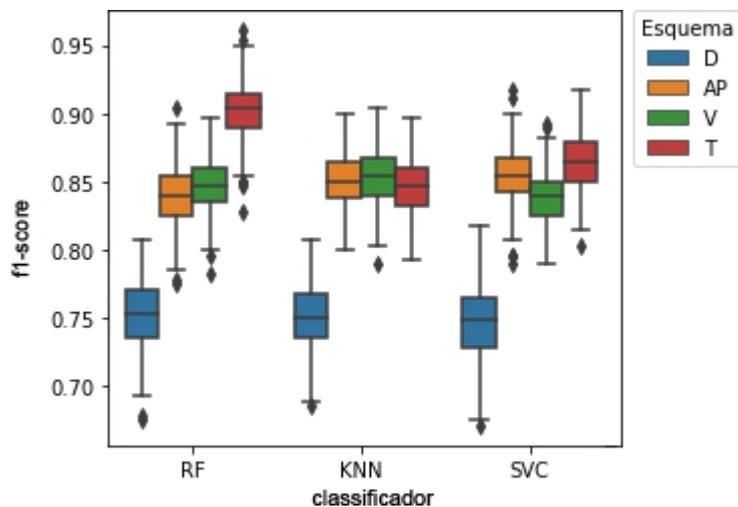
F1 Score \pm std (kappa, valor-p)			
<i>Esquema</i>	<i>RF</i>	<i>KNN</i>	<i>SVC</i>
R	75.3 \pm 0.024 (0.670, p<0.001)	75.0 \pm 0.025 (0.666 p<0.001)	74.7 \pm 0.026 (0.662, p<0.001)
V	85.3 \pm 0.020 (0.805, p<0.001)	85.3 \pm 0.805 (0.666 p<0.001)	83.9 \pm 0.019 (0.785, p<0.001)
AP	84.6 \pm 0.019 (0.795, p<0.001)	85.0 \pm 0.019 (0.800, p<0.05)	85.4 \pm 0.021 (0.806, p<0.001)
T	90.3 \pm 1.7% (0.871)	83.6 \pm 2.1% (0.782)	86.5 \pm 2.1% (0.820)

Fonte: O autor.

No gráfico boxplot correspondente aos resultados da Tabela 9, é possível perceber que não há uma variabilidade discrepante entre as amostras. Além disso, é possível perceber a presença de valores atípicos em quase todos os casos. Em parte dos dados, a mediana não está no centro da caixa, o que indica que a distribuição da maioria deles não é simétrica. Considerando todos os valores, incluindo os valores atípicos, não houve um

aumento de performance expressivo em relação ao esquema T, pois apenas em um dos classificadores houve um aumento perceptível.

Figura 9 - Gráfico boxplot - domínio de tempo-frequência



Fonte: O autor

A Tabela 9 apresenta os resultados de precisão por jogo (emoção), que é a média dos valores de precisão dos 10 grupos da validação cruzada resultantes da otimização bayesiana em cada classe. Na tabela, as melhores predições ficaram a cargo das características no domínio tempo-frequência e de tempo combinadas, extraídas dos canais do esquema T (sem lateralização).

Tabela 9 - Precisão dos classificadores para características no domínio de domínio tempo-frequência.

Precisão por classe					
Classificador		Jogo			
Modelo	Esquema	G1	G2	G3	G4
RF	R	80.1%	71.0%	73.5%	76.5%
KNN	R	76.9%	73.6%	74.5%	74.8%
SVC	R	79.2%	70.7%	74.1%	74.6%
RF	V	83.0%	85.3%	88.4%	81.8%
KNN	V	82.4%	88.0%	88.3%	82.7%
SVC	V	83.7%	85.4%	85.7%	80.7%
RF	AP	90.5%	78.5%	81.7%	85.1%
KNN	AP	90.4%	81.3%	83.2%	85.1%
SVC	AP	91.3%	80.9%	82.0%	87.6%
RF	T	93.1%	88.4%	89.9%	89.4%
KNN	T	87.1%	84.6%	81.2%	85.8%
SVC	T	88.3%	85.1%	84.0%	88.5%

Fonte: O autor

5.2. DOMÍNIO DO TEMPO

A Tabela 10 mostra os valores de desempenho de 9 classificadores quando foram empregadas as características no domínio do tempo para os três modelos de classificadores utilizados, sendo um modelo RF, SVM e KNN para cada um dos esquemas de lateralização cortical.

Pode-se observar da Tabela 10 que as características do domínio do tempo extraídas dos canais do esquema de lateralização AP (hipótese da aproximação-retirada) apresentaram a melhor acurácia nos classificadores SVM e KNN, perdendo apenas para o classificador RF com o esquema de lateralização V. Os piores resultados de acurácia ficaram com os classificadores do esquema de lateralização R, apresentando uma pequena discrepância de acurácia em relação aos demais. Com relação ao índice de confiabilidade, percebe-se uma variação de confiabilidade quase perfeito na maioria dos casos.

Tabela 10 - Acurácias dos classificadores para características no domínio de tempo.

F1 Score \pm std (kappa, p<p-valor)			
Esquema	RF	KNN	SVC
R	87.0 \pm 0.021 (0.827, p<0.001)	87.7 \pm 0.020% (0.869, p<0.001)	90.9 \pm 0.019% (0.878, p<0.001)
V	90.7 \pm 0.018 (0.876, p<0.001)	92.3 \pm 0.017% (0.897, p<0.001)	93.5 \pm 0.016% (0.914, p<0.001)
AP	92.2 \pm 0.016 (0.896, p<0.001)	93.3 \pm 0.015 (0.911, p<0.001)	94.3 \pm 0.016 (0.924, p<0.001)
T	90.2 \pm 0.020 (0.869)	84.7 \pm 0.021 (0.795)	86.5 \pm 0.021 (0.820)

Fonte: O autor.

A Tabela 11 mostra os resultados de precisão por jogo (emoção), que é a média dos valores de precisão dos 10 grupos da validação cruzada resultantes da otimização bayesiana. Percebe-se que as melhores predições ficaram a cargo das características do domínio de tempo extraídas dos canais do esquema de lateralização V (hipótese da aproximação-retirada),

para os jogos G1 e G3, e dos classificadores do esquema de lateralização AP (hipótese da valência), para os jogos G2 e G4.

Tabela 11 - Precisão dos classificadores para características no domínio do tempo.

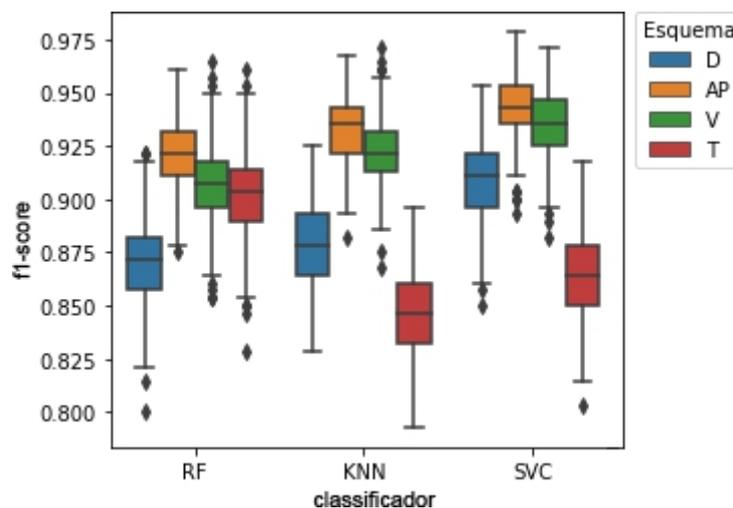
Precisão por classe					
Classificador		Jogo			
Modelo	Esquema	G1	G2	G3	G4
RF	R	87.1%	86.6%	86.9%	87.5%
KNN	R	87.6%	88.4%	86.1%	88.9%
SVC	R	91.3%	90.4%	91.2%	90.6%
RF	V	91.3%	90.6%	93.2%	87.7%
KNN	V	93.3%	92.3%	92.9%	90.6%
SVC	V	95.0%	93.5%	94.6%	91.0%
RF	AP	94.0%	91.2%	89.7%	94.0%
KNN	AP	94.2%	92.4%	91.2%	95.5%
SVC	AP	94.9%	94.3%	93.8%	94.3%
RF	T	93.1%	88.4%	89.9%	89.4%
KNN	T	87.1%	84.6%	81.2%	85.8%
SVC	T	88.3%	85.1%	84.0%	88.5%

Fonte: O autor.

No gráfico boxplot correspondente aos resultados da Tabela 11, é possível perceber que não há uma variabilidade discrepante entre as amostras. Além disso, é possível perceber a presença de valores atípicos em quase todos os casos. Em parte dos dados, a mediana não está no centro da caixa, o que indica que a distribuição da maioria deles não é simétrica.

Considerando todos os valores, incluindo os valores atípicos, houve um aumento de performance em relação ao esquema T em todos os classificadores e esquemas de lateralização, exceto da hipótese de hemisfério direito.

Figura 10 - Gráfico boxplot - domínio do tempo



Fonte: O autor.

6. DISCUSSÕES

A partir de uma análise comparativa entre os resultados obtidos neste trabalho, pode-se sugerir que as hipóteses da valência e a hipótese aproximação-retirada tiveram grande influência na acurácia dos classificadores propostos, que se utilizaram de quatro pares de canais assimétricos relacionados à emoção no cérebro (AF3-AF4, F3-F4, P7-P8, T7-T8). O resultado está corroborando com o resultado do estudo de PANE *et. al.* (2019), no qual as hipóteses da valência e de aproximação-retirada tiveram ganhos significativos de performance em relação às demais hipóteses.

O resultado também pode ser explicado pelos estudos dos autores Coan, Allen e Harmon-Jones (2002), os quais também mostraram que as emoções positivas estão associadas primordialmente a uma atividade cerebral frontal esquerda relativamente maior, enquanto as emoções negativas estão associadas a uma atividade cerebral frontal direita relativamente maior. Nesse, pode-se conjecturar que o uso de características

de eletrodos da parte frontal considerando um possível efeito de lateralização de emoções influenciou positivamente na acurácia dos classificadores.

Quanto à influência da valência e excitação nos resultados, Musha *et al.* (1997) mostraram que a valência da emoção está associada a assimetrias no lobo frontal, enquanto a excitação está associada à ativação generalizada dos lobos frontais direito e esquerdo. Logo, pode-se concluir que os classificadores foram mais eficientes em detectar características do banco de dados quando estas correspondiam a hemisférios diferentes, sugerindo que um efeito de lateralização de emoções pode ter ocorrido de forma dominante no banco de dados em diferentes intervalos de tempo.

Os resultados do presente estudo apresentaram suporte fraco à hipótese de hemisfério direito dominante, pois houve grande discrepância no quesito acurácia em relação às demais hipóteses na maioria dos classificadores testados. Logo, o resultado corrobora com o de Wager *et al.* (2003), pois os referidos autores não conseguiram comprovar a hipótese do hemisfério direito.

Para todos os casos, os resultados do esquema T (sem lateralização) e esquemas de lateralização foram distintos estatisticamente. Os resultados mostram que a mediana foi maior quando usada a lateralização, para todas as três hipóteses na maioria dos casos do domínio de tempo. Isto também se percebe quando se compara o melhor caso sem lateralização contra o melhor caso de cada hipótese.

Em comparação com os resultados de classificadores multi-classe dos criadores do banco de dados de GAMEEMO, Alakus, Gonen e Turkoglu (2020), a utilização de esquema de lateralização resultou em um ganho expressivo em performance, superando o melhor classificador dos autores, que teve 82% de acurácia. Em relação ao estudo dos autores Abdulrahman, Baykara e Alakus (2022), os classificadores considerados na presente dissertação superaram o valores de 90% obtido por eles em todos os classificadores testados no domínio do tempo, exceto o classificador de florestas randômicas. O melhor resultado obtido, 94.5% (KNN, Hipótese da aproximação-afastamento, domínio do tempo), aproxima-se do melhor

resultado do estado da arte para classificadores multi-classe, 98.44% que utiliza uma metodologia com base em aprendizado profundo criada pelos autores Abdulrahman e Baykara (2021), que é uma metodologia diferente de classificação usada no presente estudo.

Logo, pode-se afirmar que considerar modelos psicológicos, como as hipóteses de lateralização hemisférica, que influenciem na construção do vetor de características, é um caminho promissor para criação de novas técnicas de classificação de emoções, uma vez que proporciona um direcionamento mais preciso acerca da natureza dos sinais que desejamos classificar.

7. CONCLUSÃO

Neste estudo, apresentamos um novo método baseado na lateralização de emoções no cérebro para classificar emoções com base em sinais de EEG. Usamos um banco de dados que pode ser aplicado ao estudo de emoções usando sinais de EEG. Este banco é composto de sinais de 28 pessoas distintas sendo submetidos a estímulos de quatro jogos digitais distintos. Cada participante se revezou jogando vários jogos de computador e classificando sua reação emocional em termos de excitação e valência. Selecionamos quatro pares de canais assimétricos relacionados à emoção no cérebro (AF3-AF4, F3-F4, P7-P8, T7-T8) e três cenários de lateralização de emoção para testar nosso método.

Em comparação com os resultados de classificadores multi-classe dos criadores do banco de dados de GAMEEMO, Alakus, Gonen e Turkoglu (2020), a maioria dos classificadores superaram o melhor classificador dos autores, que teve 82% de acurácia. Nesse sentido, o método proposto, que usa cenários de lateralização se mostrou promissor no reconhecimento de emoções na classificação de emoções multiclasse deste conjunto de dados, pelo método de validação cruzada de 10 grupos.

Como trabalhos futuros, sugere-se aplicar os sinais da base de dados GAMEEMO a outras combinações de eletrodos, considerando os modelos de lateralização cortical propostos neste artigo. Outra sugestão seria utilizar

modelos baseados em aprendizagem profunda, como redes neurais convolucionais com extração de características multidimensionais, para identificar possíveis relações entre os hemisférios. É relevante também a utilização de outros jogos digitais, para verificar a generalização dos modelos usados.

REFERÊNCIAS

ABDULRAHMAN, Awf; BAYKARA, Muhammet. **Feature extraction approach based on statistical methods and wavelet packet decomposition for emotion recognition using EEG signals**. In: 2021 International Conference on INnovations in Intelligent SysTems and Applications (INISTA). IEEE, 2021. p. 1-7.

ABDULRAHMAN, Awf; BAYKARA, Muhammet; ALAKUS, Talha Burak. **A Novel Approach for Emotion Recognition Based on EEG Signal Using Deep Learning**. Applied Sciences, v. 12, n. 19, p. 10028, 2022.

ALAKUS, Talha Burak; GONEN, Murat; TURKOGLU, Ibrahim. **Database for an emotion recognition system based on eeg signals and various computer games–GAMEEMO**. Biomedical Signal Processing and Control, v. 60, p. 101951, 2020.

ALAKUŞ, Talha Burak; TÜRKOĞLU, İbrahim. **Feature selection with sequential forward selection algorithm from emotion estimation based on EEG signals**. Sakarya University Journal of Science, v. 23, n. 6, p. 1096-1105, 2019.

ALARCÃO, S. M.; FONSECA, M. J. Emotions Recognition Using EEG Signals: A Survey. **IEEE Transactions on Affective Computing**, vol. 10, no. 3, pp. 374-393, 1 Jul-Set, 2019

AL-MEJIBLI, Intisar Shadeed; ALWAN, Jwan K.; ABD DHAFAR, Hamed. The effect of gamma value on support vector machine performance with different kernels. **International Journal of Electrical and Computer Engineering**, v. 10, n. 5, p. 5497, 2020.

ALTURKI, Fahd A. et al. **EEG signal analysis for diagnosing neurological disorders using discrete wavelet transform and intelligent techniques**. Sensors, v. 20, n. 9, p. 2505, 2020.

BAJAJ, Nikesh. **Wavelets for EEG Analysis**. In: Wavelet Theory. IntechOpen, 2020.

BAYRAM, K. Sercan; KIZRAK, M. Ayyüce; BOLAT, Bülent. Classification of EEG signals by using support vector machines. In: **2013 IEEE INISTA**. IEEE, 2013. p. 1-3.

BINNIE, C. D., Rowan, A. J., & Gutter, T. (1982). **A manual of electroencephalographic technology**. Cambridge: Cambridge University Press.

BOUDRAA, Abdel-Ouahab; SALZENSTEIN, Fabien. Teager–Kaiser energy methods for signal and image analysis: A review. **Digital Signal Processing**, v. 78, p. 338-375, 2018.

BRADLEY, Margaret M.; LANG, Peter J. **Measuring emotion: the self-assessment manikin and the semantic differential**. Journal of behavior therapy and experimental psychiatry, v. 25, n. 1, p. 49-59, 1994.

CASSON, Alexander J. et al. **Electroencephalogram**. In: **Seamless healthcare monitoring**. Springer, Cham, 2018. p. 45-81.

CHANEL, Guillaume et al. **Emotion assessment from physiological signals for adaptation of game difficulty**. IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans, v. 41, n. 6, p. 1052-1063, 2011.

CHEN, Tian et al. **EEG emotion recognition model based on the LIBSVM classifier**. Measurement, v. 164, p. 108047, 2020.

CITRON, Francesca MM et al. Emotional valence and arousal affect reading in an interactive way: neuroimaging evidence for an approach-withdrawal framework. **Neuropsychologia**, v. 56, p. 79-89, 2014.

COAN, J.A.; ALLEN, J.J.B. AND HARMON-JONES E., “Voluntary facial expression and hemispheric asymmetry over the frontal cortex,” **Psychophysiology**, vol. 38, no. 06, pp. 912–925, 2002.

DE ALVARENGA JÚNIOR, Wagner José. **Métodos de otimização hiperparamétrica: um estudo comparativo utilizando árvores de decisão e florestas aleatórias na classificação binária**. 2018.

E HILGARD'S, Atkinson. Introdução à psicologia. São Paulo: **Cengage Learning**, 2009.

EDLA, Damodar Reddy et al. Classification of EEG data for human mental state analysis using Random Forest Classifier. **Procedia computer science**, v. 132, p. 1523-1532, 2018.

ELGELDAWI, Enas et al. Hyperparameter tuning for machine learning algorithms used for arabic sentiment analysis. In: **Informatics**. MDPI, 2021. p. 79.

FRIEDMAN, Doron et al. **A data-driven validation of frontal EEG asymmetry using a consumer device**. In: 2015 International Conference on Affective Computing and Intelligent Interaction (ACII). IEEE, 2015. p. 930-937.

GHOSH, L.; Saha, S.; Konar, A. Decoding emotional changes of android-gamers using a fused Type-2 fuzzy deep neural network. **Comput. Hum. Behav.** 2021, 116, 106640.

HARLALKA, Vasudha et al. Detection of Epileptic Seizure Using Wavelet Analysis based Shannon Entropy, Logarithmic Energy Entropy and Support Vector Machine. **International Journal of Engineering & Technology**, v. 7, n. 4.10, p. 935-939, 2018.

HO, Francis et al. **A reliability and validity study of the Palliative Performance Scale**. BMC palliative care, v. 7, n. 1, p. 1-10, 2008.

ISA, Nurul E.'zzati Md et al. The performance analysis of K-nearest neighbors (K-NN) algorithm for motor imagery classification based on EEG signal. In: **MATEC web of conferences**. EDP Sciences, 2017. p. 01024.

JERRITTA, S. et al. Emotion recognition from facial EMG signals using higher order statistics and principal component analysis. **Journal of the Chinese Institute of Engineers**, v. 37, n. 3, p. 385-394, 2014.

KUMAR, Yatindra; DEWAL, M. L.; ANAND, Radhey Shyam. Features extraction of EEG signals using approximate and sample entropy. In: 2012 **IEEE Students' Conference on Electrical, Electronics and Computer Science**. IEEE, 2012. p. 1-5.

LI, Peiyang et al. **EEG based emotion recognition by combining functional connectivity network and local activations**. *IEEE Transactions on Biomedical Engineering*, v. 66, n. 10, p. 2869-2881, 2019.

LIU, Yong-Jin et al. Real-time movie-induced discrete emotion recognition from EEG signals. **IEEE Transactions on Affective Computing**, v. 9, n. 4, p. 550-562, 2017.

MARÍN-MORALES, J.; Higuera-Trujillo, J.L.; Greco, A.; Guixeres, J.; Llinares, C.; Scilingo, E.P.; Alcañiz, M.; Valenza, G. Affective computing in virtual reality: Emotion recognition from brain and heartbeat dynamics using wearable sensors. **Sci. Rep.** **2018**, 8, 1–15.

MARTÍNEZ-TEJADA, Laura Alejandra et al. Exploring EEG Characteristics to Identify Emotional Reactions under Videogame Scenarios. **Brain Sciences**, v. 11, n. 3, p. 378, 2021.

MCHUGH, Mary L. Interrater reliability: the kappa statistic. **Biochemia medica**, v. 22, n. 3, p. 276-282, 2012.

MSONDA, J.R.; He, Z.; Lu, C. Feature Reconstruction Based Channel Selection for Emotion Recognition Using EEG. In **Proceedings of the IEEE Signal Processing in Medicine and Biology Symposium (SPMB)**, Philadelphia, PA, USA, 4 December 2021; pp. 1–7.

N.A. Abu Osman, F. Ibrahim, W.A.B. Wan Abas, H.S. Abd Rahman, H.N. Ting (Eds.): **Biomed 2008, Proceedings 21**, pp. 262–265, 2008.

PANE, Evi Septiana; WIBAWA, Adhi Dharma; PURNOMO, Mauridhi Hery. Improving the accuracy of EEG emotion recognition by combining valence lateralization and ensemble learning with tuning parameters. **Cognitive processing**, v. 20, n. 4, p. 405-417, 2019.

PEREIRA, Danielle M.; KHAN, Azizuddin. **Brain lateralization of emotional processing in depression**. **Depression**, v. 2, p. 25-36, 2017.

PEREIRA, Francisco; MITCHELL, Tom; BOTVINICK, Matthew. **Machine learning classifiers and fMRI: a tutorial overview**. *Neuroimage*, v. 45, n. 1, p. S199-S209, 2009.

RAMAYANTI, Desi; SALAMAH, Umniy. Text Classification on Dataset of Marine and Fisheries Sciences Domain using Random Forest Classifier. **Int. J. Comput. Tech**, v. 5, n. 5, p. 1-7, 2018.

RANJAN, G. S. K.; VERMA, Amar Kumar; RADHIKA, Sudha. K-nearest neighbors and grid search cv based real time fault monitoring system for industries. In: **2019 IEEE 5th international conference for convergence in technology (I2CT)**. IEEE, 2019. p. 1-5.

RAVAJA, N., TURPEINEN, M., SAARI, T., PUTTONEN, S., AND KELTIKANGAS-JARVINEN, L. (2008). The psychophysiology of James Bond: phasic emotional responses to violent video game events. **Emotion** 8, 114–120. doi: 10.1037/1528-3542.8.1.114.

ROY, Vandana. **Effective EEG Artifact Removal from EEG Signal**. 2022.

RUSSELL, James. A circumplex model of affect. *Journal of Personality and Social Psychology*, v. 39, n. 6, p.1161-1178, 1980. SANTOS, Renato Favarin dos; SILVEIRA, Ronie Aleksandro Teles da; GOMES, Carlos Falcão de Azevedo; STEIN, Lilian Milnitsky. **Normas de emocionalidade para a versão brasileira do paradigma Deese-Roediger-McDermott (DRM)**. *Psicologia: Teoria e Pesquisa*, v. 25, n. 3, p. 387-394, 2009.

SAPUTRI, Mei Silviana; MAHENDRA, Rahmad; ADRIANI, Mirna. Emotion classification on indonesian twitter dataset. In: **2018 International Conference on Asian Language Processing (IALP)**. IEEE, 2018. p. 90-95.

SCIKIT-LEARN, 2020. disponível em < <https://scikitlearn.org/stable/modules/generated/sklearn.preprocessing.MinMaxScaler.html> > Acesso em 30.08.2022.

SCIPY, 2021. disponível em <https://docs.scipy.org/doc/scipy/reference/generated/scipy.stats.ttest_ind.html> Acesso em 30.08.2022.

SHAHNAZ, Celia et al. Emotion recognition based on wavelet analysis of Empirical Mode Decomposed EEG signals responsive to music videos. In: **2016 IEEE Region 10 Conference (TENCON)**. IEEE, 2016. p. 424-427.

T.MUSHA, Y. TERASAKI, H.A. HAQUE, AND G.A. IVAMITSKY, “Feature extraction from EEGs associated with emotions,” **Artificial Life and Robotics**, vol. 1, pp. 15–19, 1997.

TOPIC, Ante et al. Emotion Recognition Using a Reduced Set of EEG Channels Based on Holographic Feature Maps. **Sensors**, v. 22, n. 9, p. 3248, 2022.

TYNG, C. M.; AMIN. H,U. SAAD, M.N.M.; MALIK, A.S (2017) The Influences of Emotion on Learning and Memory. **Front. Psychol.** 8:1454. doi: 10.3389/fpsyg.2017.01454.

WAGER, Tor D. et al. Valence, gender, and lateralization of functional brain anatomy in emotion: a meta-analysis of findings from neuroimaging. **Neuroimage**, v. 19, n. 3, p. 513-531, 2003.

WARD, D.-M. et al. Enhancement of deep epileptiform activity in the EEG via 3-D adaptive spatial filtering. **IEEE transactions on biomedical engineering**, v. 46, n. 6, p. 707-716, 1999.

YUEN, Chai Tong et al. Effectiveness of statistical features for human emotions classification using EEG biosensors. **Research Journal of Applied Sciences, Engineering and Technology**, v. 5, n. 21, p. 5083-5089, 2013.

ZHANG, Jianhua et al. Emotion recognition using multi-modal data and machine learning techniques: A tutorial and review. **Information Fusion**, v. 59, p. 103-126, 2020.

GUODONG, Guo; YAHAN, Gao. Multi feature fusion EEG emotion recognition. In: **2021 7th International Conference on Big Data and Information Analytics (BigDIA)**. IEEE, 2021. p. 280-284.