

UNIVERSIDADE FEDERAL DE PELOTAS
Centro de Desenvolvimento Tecnológico
Programa de Pós-Graduação em Computação



Dissertação

Um *pipeline* de aprendizado de máquina para reconhecimento de emoções com base em informações temporais e espaciais de mapas topográficos gerados a partir de sinais de eletroencefalograma

Bruno Cascaes Alves

Pelotas, 2024

Bruno Cascaes Alves

Um *pipeline* de aprendizado de máquina para reconhecimento de emoções com base em informações temporais e espaciais de mapas topográficos gerados a partir de sinais de eletroencefalograma

Dissertação apresentada ao Programa de Pós-Graduação em Computação do Centro de Desenvolvimento Tecnológico da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Mestre em Ciência da Computação.

Orientador: Prof. Dr. Marilton Sanchotene de Aguiar

Pelotas, 2024

Universidade Federal de Pelotas / Sistema de Bibliotecas
Catalogação da Publicação

A472p Alves, Bruno Cascaes

Um *pipeline* de aprendizado de máquina para reconhecimento de emoções com base em informações temporais e espaciais de mapas topográficos gerados a partir de sinais de eletroencefalograma [recurso eletrônico] / Bruno Cascaes Alves ; Marilton Sanchothene de Aguiar, orientador. — Pelotas, 2024.

82 f. : il.

Dissertação (Mestrado) — Programa de Pós-Graduação em Computação, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, 2024.

1. Aprendizado de máquina. 2. Eletroencefalograma. 3. Reconhecimento de emoção. 4. Mapa topográfico. I. Aguiar, Marilton Sanchothene de, orient. II. Título.

CDD 005

Bruno Cascaes Alves

Um *pipeline* de aprendizado de máquina para reconhecimento de emoções com base em informações temporais e espaciais de mapas topográficos gerados a partir de sinais de eletroencefalograma

Dissertação aprovada, como requisito parcial, para obtenção do grau de Mestre em Ciência da Computação, Programa de Pós-Graduação em Computação, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas.

Data da Defesa: 15 de abril de 2024

Banca Examinadora:

Prof. Dr. Marilton Sanchotene de Aguiar (orientador)

Doutor em Computação pela Universidade Federal do Rio Grande do Sul.

Prof. Dr. Cleo Zanella Billa

Doutor em Ciência da Computação pela Universidade Estadual de Campinas.

Profa. Dra. Diana Francisca Adamatti

Doutora em Engenharia Elétrica pela Universidade de São Paulo.

Profa. Dra. Larissa Astrogildo de Freitas

Doutora em Ciência da Computação pela Pontifícia Universidade Católica do Rio Grande do Sul.

AGRADECIMENTOS

Agradeço à minha mãe, Marisa, uma pessoa extremamente batalhadora que nunca poupou esforços para que eu conseguisse realizar minha formação acadêmica. Agradeço também a todos os membros da minha família, os quais me apoiaram durante esta trajetória. Aos meus amigos e colegas, agradeço pelas experiências de apoio e felicidade que me proporcionaram durante todo o percurso. Agradeço também a todos os professores que contribuíram de alguma forma para o meu desenvolvimento. Em especial, agradeço ao meu orientador Marilton, cujo apoio e orientação foram fundamentais para a construção desta Dissertação. Obrigado a todos por estarem ao meu lado.

RESUMO

ALVES, Bruno Cascaes. **Um *pipeline* de aprendizado de máquina para reconhecimento de emoções com base em informações temporais e espaciais de mapas topográficos gerados a partir de sinais de eletroencefalograma.** Orientador: Marilton Sanchotene de Aguiar. 2024. 82 f. Dissertação (Mestrado em Ciência da Computação) – Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, Pelotas, 2024.

O reconhecimento de emoções é uma área que está se tornando cada vez mais relevante devido sua implicação direta na vida da sociedade. A área busca por melhores formas de compreender como as emoções, de natureza subjetiva, influenciam o comportamento humano. Considerando que as emoções podem ser expressas de forma não verbal, a análise da atividade cerebral, a partir de sinais de eletroencefalograma, torna-se uma abordagem relevante para a identificação de emoções. O eletroencefalograma registra os sinais elétricos gerados pelo córtex cerebral por meio de eletrodos fixados sobre o couro cabeludo. Estes sinais possuem características complexas, nos domínios espacial, temporal e de frequência. Diante disto, o uso de um *pipeline* de predição mostra-se como uma alternativa para o reconhecimento de emoções. Consoante a literatura, destacam-se poucos estudos baseados no uso de imagens de mapas topográficos derivados de sinais cerebrais, sobretudo com as informações mapeadas para um formato estruturado. Neste contexto, este trabalho propõe a análise e a construção de modelos de aprendizado de máquina para o reconhecimento de emoções, com base em mapas topográficos do cérebro geradas a partir de sinais de eletroencefalograma na ferramenta EEGLAB. O estudo de caso se refere ao DEAP, um *dataset* amplamente reconhecido na área, construído por meio de experimentos de eletroencefalograma nos quais os sujeitos foram expostos a estímulos musicais e visuais, realizando autoavaliações em dimensões emocionais, como excitação, valência, dominância e preferência. Além da proposta do *pipeline*, as principais contribuições deste estudo incluem apresentar um *dataset* estruturado – construído com base no mapeamento de informações obtidas nos mapas topográficos, abrangendo dados de intensidade cerebral por região, com uso de janelas temporais, para amostras em três bandas de frequência: *Alpha*, *Beta* e *Gama*. Por fim, este estudo apresenta modelos preditivos para o reconhecimento de emoções, com destaque de acurácia de 85,46%, 85,05%, 85,92% e 84,49% para excitação, valência, dominância e preferência, respectivamente – obtida por meio do algoritmo *K-Nearest Neighbors* utilizando dados de todos os eletrodos.

Palavras-chave: aprendizado de máquina; eletroencefalograma; reconhecimento de emoção; mapa topográfico.

ABSTRACT

ALVES, Bruno Cascaes. **A Machine learning pipeline for emotion recognition based on temporal and spatial information from topographic maps generated from electroencephalogram signals.** Advisor: Marilton Sanchotene de Aguiar. 2024. 82 f. Dissertation (Masters in Computer Science) – Technology Development Center, Federal University of Pelotas, Pelotas, 2024.

Emotion recognition is an area that is becoming increasingly relevant due to its direct implication in society's daily life. The field seeks better ways to understand how subjective emotions influence human behavior. Given that emotions can manifest non-verbally, brain activity analysis through electroencephalogram signals becomes a relevant approach for emotion identification. The electroencephalogram records the electrical signals generated by the brain cortex through electrodes placed on the scalp. These signals exhibit complex characteristics in spatial, temporal, and frequency domains. Therefore, a prediction pipeline emerges as an alternative for emotion recognition. According to the literature, few studies focus on topographic map images derived from brain signals, especially with information mapped to a structured format. In this context, this work proposes the analysis and development of machine learning models for emotion recognition based on brain topographic maps generated from electroencephalogram signals using the EEGLAB tool. The case study refers to the DEAP, a widely recognized dataset in the area, constructed through electroencephalogram experiments where subjects were exposed to musical and visual stimuli, providing self-assessments on emotional dimensions such as arousal, valence, dominance, and preference. In addition to implementing the pipeline, the main contributions of this study include the presentation of a structured dataset — created based on the mapping of information obtained from topographic map images, containing brain intensity data per region using temporal windows for samples in three frequency bands: *Alpha*, *Beta*, and *Gama*. Finally, the study introduces predictive models for emotion recognition, achieving notable accuracies of 85.46%, 85.05%, 85.92%, and 84.49% for dimensions of arousal, valence, dominance, and preference, respectively. These results were obtained through the K-Nearest Neighbors algorithm using data from all electrodes.

Keywords: machine learning; electroencephalogram; emotion recognition; topographic map.

LISTA DE FIGURAS

Figura 1	Estrutura de um neurônio.	17
Figura 2	Visão lateral do córtex cerebral, incluindo os lobos Frontal (F), Occipital (O), Parietal (P) e Temporal (T).	18
Figura 3	Mapeamento dos eletrodos para EEG no Sistema Internacional 10-20 usando 32 eletrodos.	19
Figura 4	Sinal de EEG bruto com segmentação baseada em janela e sobreposição temporal.	19
Figura 5	Modelo circunplexo de emoções.	22
Figura 6	<i>K-Nearest Neighbors</i>	24
Figura 7	<i>Random Forest</i>	26
Figura 8	<i>Support Vector Machine</i>	27
Figura 9	Representação do espaço de cores a) RGB e b) HSV.	30
Figura 10	Segmentação de imagem baseada em cores: a) imagem original; b) filtro para captura de píxeis da cor verde; e, c) imagem segmentada.	32
Figura 11	Visão geral do <i>pipeline</i> para reconhecimento de emoções.	37
Figura 12	Imagens topográficas cerebrais geradas no EEGLAB para cinco amostras de frequência.	39
Figura 13	Etapas do filtro cerebral.	40
Figura 14	Etapas do filtro dos eletrodos.	40
Figura 15	Pré-processamento do <i>dataset</i> de imagens.	41
Figura 16	Representação de a) baixo, b) médio e c) alto nível de ativação cerebral.	42
Figura 17	Diagrama com as etapas da construção dos modelos preditores de emoção.	46
Figura 18	Distribuição dos dados referente aos alvos dos modelos.	46
Figura 19	Cenário 1: Acurácia dos modelos para a) excitação, b) valência, c) dominância e d) preferência.	51
Figura 20	Cenário 1: Matrizes de confusão de excitação na banda de frequência <i>Gama</i>	52
Figura 21	Cenário 1: Matrizes de confusão de valência na banda de frequência <i>Gama</i>	52
Figura 22	Cenário 1: Matrizes de confusão de dominância na banda de frequência <i>Gama</i>	53
Figura 23	Cenário 1: Matrizes de confusão de preferência na banda de frequência <i>Gama</i>	53

Figura 24	Cenário 2: Acurácia dos modelos de excitação na banda de frequência <i>Gama</i>	54
Figura 25	Cenário 2: Acurácia dos modelos de valência na banda de frequência <i>Gama</i>	55
Figura 26	Cenário 2: Acurácia dos modelos de dominância na banda de frequência <i>Gama</i>	55
Figura 27	Cenário 2: Acurácia dos modelos de preferência na banda de frequência <i>Gama</i>	56
Figura 28	Cenário 2: Matrizes de confusão, nos melhores casos, para: a) excitação com RF na banda de frequência <i>Gama</i> sobre a região F + FC; b) valência com SVM na banda de frequência <i>Gama</i> sobre a região F + FC; c) dominância com RF na banda de frequência <i>Beta</i> sobre a região P + CP; e, d) preferência com SVM na banda de frequência <i>Gama</i> sobre a região F + FC.	57
Figura 29	Cenário 3: Acurácia dos modelos de excitação na banda de frequência <i>Gama</i>	59
Figura 30	Cenário 3: Acurácia dos modelos de valência na banda de frequência <i>Gama</i>	59
Figura 31	Cenário 3: Acurácia dos modelos de dominância na banda de frequência <i>Gama</i>	59
Figura 32	Cenário 3: Acurácia dos modelos de preferência na banda de frequência <i>Gama</i>	60
Figura 33	Cenário 3: Matrizes de confusão de excitação com K-NN na banda de frequência <i>Gama</i> usando dados de todos os eletrodos.	60
Figura 34	Cenário 3: Matrizes de confusão de valência com K-NN na banda de frequência <i>Gama</i> usando dados de todos os eletrodos.	61
Figura 35	Cenário 3: Matrizes de confusão de dominância com K-NN na banda de frequência <i>Gama</i> usando dados de todos os eletrodos.	61
Figura 36	Cenário 3: Matrizes de confusão de preferência com K-NN na banda de frequência <i>Gama</i> usando dados de todos os eletrodos.	61
Figura 37	Cenário 1: Matrizes de confusão de excitação em <i>Alpha</i>	77
Figura 38	Cenário 1: Matrizes de confusão de excitação em <i>Beta</i>	77
Figura 39	Cenário 1: Matrizes de confusão de valência em <i>Alpha</i>	78
Figura 40	Cenário 1: Matrizes de confusão de valência em <i>Beta</i>	78
Figura 41	Cenário 1: Matrizes de confusão de dominância em <i>Alpha</i>	78
Figura 42	Cenário 1: Matrizes de confusão de dominância em <i>Beta</i>	79
Figura 43	Cenário 1: Matrizes de confusão de preferência em <i>Alpha</i>	79
Figura 44	Cenário 1: Matrizes de confusão de preferência em <i>Beta</i>	79
Figura 45	Cenário 3: Matrizes de confusão de excitação com K-NN em <i>Alpha</i>	80
Figura 46	Cenário 3: Matrizes de confusão de excitação com K-NN em <i>Beta</i>	80
Figura 47	Cenário 3: Matrizes de confusão de valência com K-NN em <i>Alpha</i>	80
Figura 48	Cenário 3: Matrizes de confusão de valência com K-NN em <i>Beta</i>	81
Figura 49	Cenário 3: Matrizes de confusão de dominância com K-NN em <i>Alpha</i>	81
Figura 50	Cenário 3: Matrizes de confusão de dominância com K-NN em <i>Beta</i>	81
Figura 51	Cenário 3: Matrizes de confusão de preferência com K-NN em <i>Alpha</i>	82
Figura 52	Cenário 3: Matrizes de confusão de preferência com K-NN em <i>Beta</i>	82

LISTA DE TABELAS

Tabela 1	Categorização das bandas cerebrais.	20
Tabela 2	Comparação entre os trabalhos relacionados.	35
Tabela 3	Amostras de autoavaliações realizadas pelos sujeitos durante os experimentos	38
Tabela 4	Exemplo do mapeamento de atividade cerebral em formato estruturado.	43
Tabela 5	Exemplo de distribuição dos dados para uma linha do <i>dataset</i> estruturado.	44
Tabela 6	Configuração do <i>dataset</i> quanto aos atributos.	45
Tabela 7	Divisão dos dados entre treino e teste para cada tipo de configuração do <i>dataset</i>	47
Tabela 8	Conjunto de hiperparâmetros de entrada.	48
Tabela 9	Cenário 1: Avaliação dos modelos preditores para melhor e pior caso.	53
Tabela 10	Cenário 2: Avaliação dos modelos preditores para melhor e pior caso.	56
Tabela 11	Cenário 3: Avaliação dos modelos preditores para melhor e pior caso.	62
Tabela 12	Acurácia dos modelos preditores de excitação por região cerebral. .	73
Tabela 13	Acurácia dos modelos preditores de valência por região cerebral. .	74
Tabela 14	Acurácia dos modelos preditores de dominância por região cerebral.	75
Tabela 15	Acurácia dos modelos preditores de preferência por região cerebral.	76

LISTA DE ABREVIATURAS E SIGLAS

AM	Aprendizado de Máquina
CART	<i>Classification and Regression Trees</i>
CNN	<i>Convolutional Neural Networks</i>
CWT	<i>Continuous Wavelet Transform</i>
DEAP	<i>Database for Emotion Analysis using Physiological Signals</i>
DT	<i>Decision Tree</i>
ECG	Eletrocardiograma
EEG	Eletroencefalograma
HCNN	<i>Hierarchical Convolutional Neural Networks</i>
K-NN	<i>K-Nearest Neighbors</i>
LSTM	<i>Long Short-Term Memory</i>
PDI	Processamento Digital de Imagens
RBF	<i>Radial Basis Function</i>
RF	<i>Random Forest</i>
SNC	Sistema Nervoso Central
SVM	<i>Support Vector Machine</i>
ToC	<i>Third-order Cumulants</i>

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Objetivos	14
1.2	Questões de Pesquisa	15
1.3	Organização do Texto	15
2	REFERENCIAL TEÓRICO E TECNOLÓGICO	16
2.1	Sinais de Eletroencefalograma	16
2.2	Teoria da Emoção	20
2.3	Aprendizado de Máquina	22
2.3.1	<i>K-Nearest Neighbors</i>	23
2.3.2	<i>Random Forest</i>	25
2.3.3	<i>Support Vector Machine</i>	26
2.3.4	Métricas de Avaliação	28
2.4	Processamento Digital de Imagens	29
2.4.1	Espaços de Cores	29
2.4.2	Segmentação de Imagens	31
2.5	Trabalhos Relacionados	32
3	ABORDAGEM PROPOSTA	37
3.1	Base de Dados	38
3.2	<i>Dataset</i> Estruturado	42
3.3	Preditores de Emoções	44
4	RESULTADOS E DISCUSSÕES	50
4.1	Cenário 1	50
4.2	Cenário 2	54
4.3	Cenário 3	58
5	CONCLUSÕES	63
	REFERÊNCIAS	66
	APÊNDICE A ACURÁCIA DOS MODELOS PREDITIVOS	72
	APÊNDICE B MATRIZES DE CONFUSÃO DE MODELOS USANDO DADOS DE TODOS OS ELETRODOS	77

1 INTRODUÇÃO

As emoções são condições complexas caracterizadas pelos estados mentais resultantes a determinados estímulos (Mauss; Robinson, 2009). Estes estados mentais direcionam o comportamento visando aumentar a resiliência no ambiente. Tendo em vista a importância das emoções na vida humana, a área do reconhecimento de emoções possui uma ampla gama de aplicações, em áreas como: medicina, neurociência e psicologia (Niedenthal; Ric, 2017).

Em relação à perspectiva, as emoções podem ser categorizadas de duas maneiras: discreta e dimensional. A perspectiva discreta define as emoções por meio de estados como, por exemplo, alegria e tristeza. Por outro lado, a perspectiva dimensional descreve as emoções com base em escalas. Excitação, valência e dominância são três dimensões emocionais relevantes que se relacionam com os graus de intensidade, prazer e controle, respectivamente (Hamann, 2012).

De acordo com Polzin (2000), as emoções podem ser expressas de maneira não verbal, por meio de indicadores como as atividades cardíacas e cerebrais. Portanto, a identificação das emoções pode ser obtida a partir de sinais fisiológicos captados por sensores, como eletrocardiograma (ECG) e eletroencefalograma (EEG). Em particular, o EEG é um procedimento não invasivo que analisa a atividade elétrica cerebral, captada por meio de eletrodos posicionados sobre o couro cabeludo. Assim, o EEG desempenha um papel essencial na neurociência ao possibilitar a investigação do cérebro humano em diversas condições e estados mentais (Sanei; Chambers, 2021).

Os sinais de EEG são complexos, sendo caracterizados como séries temporais não-estacionárias e altamente não-lineares, com características específicas nos domínios espacial, temporal e de frequência. O domínio espacial indica a região do córtex cerebral, o domínio temporal indica o instante do evento e o domínio da frequência indica a potência. Estas características, associadas à subjetividade das emoções, impõem diversos desafios de pesquisa (DEL POZO-BANOS et al., 2014).

Neste cenário, o Aprendizado de Máquina (AM) surge com abordagens que permitem representar sistemas reais por meio do uso de ferramentas computacionais. Modelos construídos por meio destas abordagens podem identificar padrões nos dados e utilizá-los para realizar previsões (Alpaydin, 2014). Especificamente no campo do reconhecimento de emoções, utilizando sinais de EEG, estes modelos demonstram um desempenho promissor (Li; Zhang; He, 2018).

Em termos gerais, os estudos relacionados na literatura dividem-se em processar diretamente os sinais cerebrais (Samavat et al., 2022) e processar imagens de mapas topográficos/espectrogramas (Sharma; Pachori; Sircar, 2020) para construção dos sistemas de predição de emoções. Especificamente, os mapas topográficos no contexto do EEG oferecem uma representação gráfica da distribuição espacial das variações de potencial elétrico cerebral. O espectro de potência de frequência é representado por cores, onde regiões com menor potência são coloridas em azul-escuro, enquanto regiões com maior potência são indicadas por vermelho-escuro. Esta abordagem proporciona uma melhor compreensão das relações entre as atividades cerebrais em diferentes regiões do córtex (Hooi; Nisar; Voon, 2015).

Este trabalho tem como foco de estudo o conjunto de dados DEAP (Koelstra et al., 2012), um dos *datasets* mais renomados na área de reconhecimento de emoções a partir de sinais de EEG (Garg; Verma; Singh, 2023). Os dados do DEAP compreendem sinais de EEG obtidos por meio de experimentos nos quais os participantes foram expostos a estímulos musicais e visuais. A partir destes sinais, juntamente com os dados de autoavaliações preenchidos pelos sujeitos em relação às dimensões emocionais, a análise é realizada considerando aspectos temporais, espaciais e de frequência.

Neste contexto, o presente estudo propõe um *pipeline* de aprendizado de máquina para classificação de emoções nas dimensões de excitação, valência, dominância e preferência, considerando perspectivas baixas ou altas destas dimensões. O *pipeline* proposto utiliza informações de um novo conjunto de dados estruturado, construído a partir do mapeamento dos níveis de ativação das regiões cerebrais em mapas topográficos, derivados de sinais de EEG e a partir da ferramenta EEGLAB (Delorme; Makeig, 2004).

1.1 Objetivos

O objetivo geral deste trabalho é a construção de modelos de aprendizado de máquina para reconhecimento de emoções, a partir de sinais de eletroencefalograma, sendo a análise dos dados realizada com base em imagens de sinais de atividade cerebrais, segmentadas conforme os grupos de eletrodos referentes às regiões do córtex cerebral e recorrendo a dados temporais.

Mais especificamente, esta Dissertação tem os seguintes objetivos:

1. Aquisição e armazenamento do *dataset* DEAP pré-processado e convertido em mapas topográficos através da ferramenta EEGLAB.
2. Construção de um *dataset* estruturado contendo o mapeamento das imagens topográficas por regiões cerebrais e suas respectivas intensidades de ativação.
3. Ajuste de modelos preditores com a obtenção de melhores hiperparâmetros para implementação, considerando variações nos algoritmos e nos domínios espacial, temporal e de frequência, para quatro tipos de dimensões emocionais (excitação, valência, dominância e preferência).

1.2 Questões de Pesquisa

O presente trabalho propõe-se a responder as seguintes questões de pesquisa:

1. Qual a melhoria do desempenho de modelos de predição de emoções quando há o uso de dados segmentados por grupos de eletrodos, referente às regiões do córtex cerebral, quando comparado ao uso de dados de todos os eletrodos?
2. Qual a melhoria do desempenho de modelos de predição de emoções quando há a combinação de sinais de EEG, baseado em janela temporal?

1.3 Organização do Texto

O texto desta Dissertação está organizado como segue. No Capítulo 2 é apresentado o referencial teórico e tecnológico sobre Sinais de Eletroencefalograma (Seção 2.1), Teoria da Emoção (Seção 2.2), Aprendizado de Máquina (Seção 2.3), Processamento Digital de Imagens (Seção 2.4) e Trabalhos Relacionados (Seção 2.5).

No Capítulo 3 é apresentada a arquitetura do *pipeline* proposto para classificação das dimensões emocionais, bem como a base de dados, a metodologia aplicada e a configuração dos hiperparâmetros para treinamento dos modelos. No Capítulo 4 são apresentados os cenários de experimentos e os respectivos resultados e discussões para cada dimensão emocional.

No Capítulo 5 são apresentadas as conclusões desta Dissertação. Por fim, no Apêndice A são apresentadas Tabelas contendo os valores de acurácia para os modelos construídos e no Apêndice B são apresentadas matrizes de confusão referentes aos modelos construídos com base em dados de todos os eletrodos.

2 REFERENCIAL TEÓRICO E TECNOLÓGICO

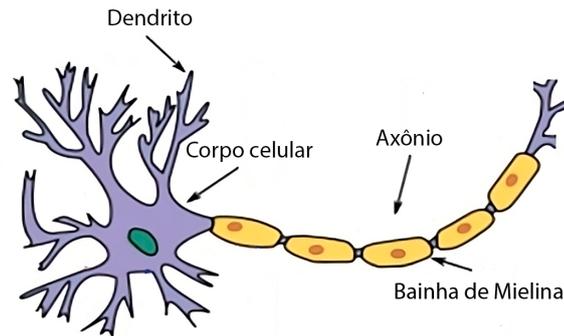
Neste Capítulo são apresentados os principais conceitos para o entendimento deste trabalho: Sinais de Eletroencefalograma, Teoria da Emoção, Aprendizado de Máquina e Processamento Digital de Imagens. Além disto, estão expostos os principais trabalhos relacionados.

2.1 Sinais de Eletroencefalograma

O EEG é um procedimento capaz de detectar e registrar os sinais elétricos gerados pelo córtex cerebral. Este exame é realizado por meio da aplicação de eletrodos sobre o couro cabeludo, os quais são conectados a dispositivos técnicos (Boutros et al., 2011). Os sinais de EEG, portanto, representam a atividade elétrica cerebral capturada por meio deste exame. Assim, estes sinais desempenham um papel essencial na área da neurociência, uma vez que o cérebro é uma das estruturas mais complexas e interessantes do corpo humano (Sanei; Chambers, 2021).

O estudo dos sinais de EEG tem sido fundamental para compreender o sistema nervoso e a mente humana, portanto, torna-se relevante entender o Sistema Nervoso Central (SNC). Deste modo, o SNC é responsável por receber e processar as informações do corpo humano, sendo composto pelo encéfalo e pela medula espinhal (Williams et al., 2020). O encéfalo, localizado no crânio, é a principal região de controle do SNC e possui três partes: i) o cérebro, que regula o movimento do corpo, armazena memória e coordena respostas emocionais; ii) o cerebelo, que modula a força e amplitude dos movimentos; e, iii) o tronco encefálico, que recebe dados sensoriais da pele e músculos da cabeça, e regula os níveis de alerta por meio de comunicação com a medula espinhal. Já a medula espinhal é uma estrutura que transmite sinais entre o cérebro e os membros, e controla reflexos motores (Kandel et al., 2013).

Figura 1 – Estrutura de um neurônio.



Fonte: adaptado de Sanej; Chambers (2021).

A transmissão, processamento e coordenação de informações realizadas no SNC ocorre por meio de redes de neurônios. A Figura 1 ilustra a estrutura de um neurônio, contendo os seus principais elementos. Cada neurônio é composto por um corpo celular que contém um núcleo, responsável por coordenar as funções celulares. Além disto, existem extensões ramificadas chamadas dendritos, que recebem sinais químicos de outros neurônios. Por fim, existe uma extensão chamada axônio, responsável por transmitir sinais elétricos para outros neurônios e partes do corpo, como os músculos. Deve ser destacado que em alguns neurônios existe a Bainha de Mielina no axônio, uma estrutura que atua como isolante elétrico, facilitando a rápida comunicação entre os neurônios (Squire et al., 2008).

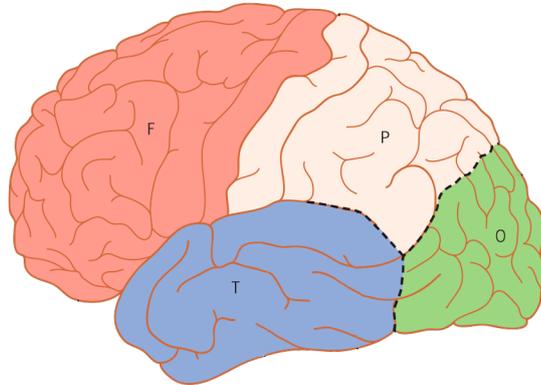
A comunicação entre um neurônio e outra célula ocorre em junções conhecidas como sinapses. Quando um sinal elétrico alcança a extremidade do axônio de um neurônio, ele libera neurotransmissores, os quais são substâncias químicas responsáveis por transmitir o sinal para os dendritos de outro neurônio, gerando uma sequência de eventos elétricos e químicos. Desta forma, com base nestes sinais, o SNC faz com seja possível perceber, interpretar e responder ao ambiente (Squire et al., 2008).

O córtex cerebral, uma camada densa de neurônios na superfície externa do cérebro, desempenha um papel importante na interpretação dos sinais de EEG (Malik; Amin, 2017). A Figura 2 ilustra a vista lateral das principais regiões do córtex cerebral e os sulcos, em tracejado, que auxiliam a delimitar e conectar estas áreas.

A partir da Figura 2, pode-se observar que o córtex cerebral é composto por regiões chamadas de lobos cerebrais, os quais atuam em conjunto para processar informações e desempenham papéis específicos no cérebro e, assim, na geração dos sinais de EEG. Os quatro principais lobos cerebrais são: Lobo Frontal (F), responsável por controle motor, tomada de decisões, raciocínio, personalidade e controle das emoções; Lobo Occipital (O), dedicado ao processamento visual; Lobo Parietal (P), responsável pelo processamento de informações sensoriais incluindo tato, temperatura e dor; e, por fim, o Lobo Temporal (T), relacionado à audição, processamento de

linguagem e memória (Tortora; Derrickson, 2018).

Figura 2 – Visão lateral do córtex cerebral, incluindo os lobos Frontal (F), Occipital (O), Parietal (P) e Temporal (T).



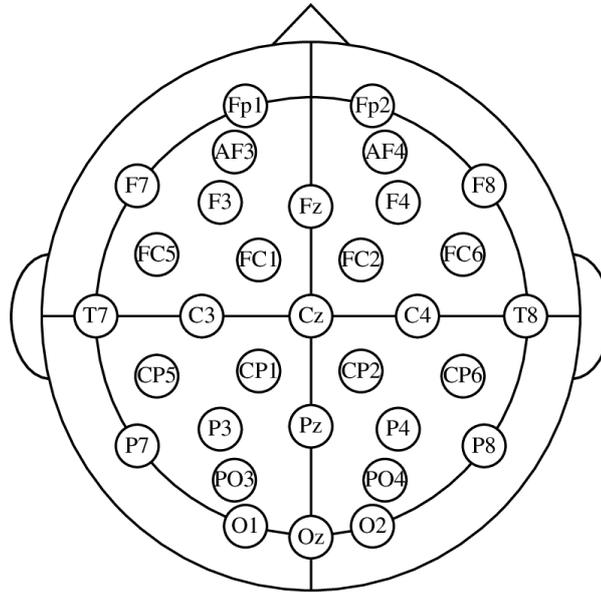
Fonte: adaptado de Williams et al. (2020).

Associado a este contexto, em que a atividade dos neurônios gera sinais elétricos e os lobos cerebrais têm funções especializadas, a coleta dos sinais de EEG é realizada com os eletrodos posicionados de maneira a possibilitar o mapeamento das áreas do córtex cerebral. Para garantir a padronização da coleta dos sinais de EEG, foram estabelecidos padrões de posicionamento dos eletrodos. No caso dos dados coletados utilizados neste estudo, por exemplo, utilizou-se o Sistema Internacional 10-20 (Herwig; Satrapi; Schonfeldt-lecuona, 2003), que define que a distância entre os eletrodos deve ser de 10% ou 20%. Assim, a proporção entre os eletrodos é mantida independentemente do tamanho da cabeça do indivíduo.

A Figura 3 ilustra o mapeamento dos eletrodos com base no Sistema Internacional 10-20 para 32 eletrodos. Neste sistema, os eletrodos ímpares são colocados na região esquerda da cabeça, os eletrodos pares são colocados na região direita, e os eletrodos identificados com o sufixo Z são centralizados, conforme pode ser observado na Figura. Os prefixos atribuídos aos eletrodos estão relacionados às áreas cerebrais, conforme discutido anteriormente. Desta forma, os prefixos incluem: F_p (pré-frontal), F (frontal), T (temporal), P (parietal), O (occipital) e C (central). Adicionalmente, outros prefixos, como AF (entre F_p e F), FC (entre F e C), CP (entre C e P), e PO (entre P e O), são usados para indicar posições intermediárias na cabeça.

É relevante destacar que não há um lobo cerebral central propriamente dito. Devido à sua localização, os eletrodos identificados como C podem refletir a atividade característica das áreas frontal, temporal e, em alguns casos, de zona parietal/occipital, dependendo de características individuais. Também é importante salientar que a área pré-frontal é considerada parte do lobo frontal (Williams et al., 2020).

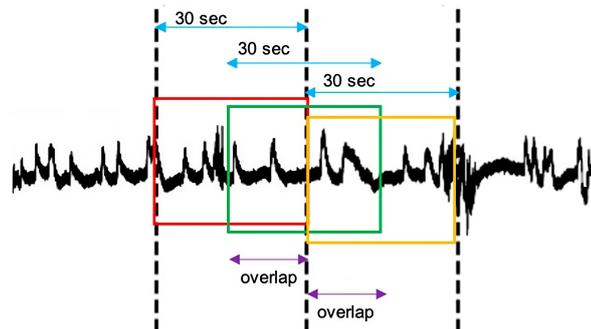
Figura 3 – Mapeamento dos eletrodos para EEG no Sistema Internacional 10-20 usando 32 eletrodos.



Fonte: Abdelaal; Alsayy; Hefny (2015).

Os sinais de EEG coletados apresentam características distintas, incluindo amplitude e frequência, que desempenham um papel fundamental na análise da atividade cerebral. A amplitude refere-se à magnitude das oscilações nos sinais, enquanto a frequência descreve quantas oscilações ocorrem por segundo. Estas características variam de acordo com diferentes estados mentais e padrões de atividade cerebral (Sanei; Chambers, 2021).

Figura 4 – Sinal de EEG bruto com segmentação baseada em janela e sobreposição temporal.



Fonte: adaptado de Casciola et al. (2021).

A Figura 4 ilustra um sinal de EEG bruto, sendo este sinal segmentado com o uso de técnica de janela e sobreposição, que servem para dividir o sinal em partes menores e permitir uma transição mais suave entre os segmentos, respectivamente. Esta Figura destaca um sinal de EEG de 60 segundos, segmentado por janela de 30

segundos com sobreposição de 50% de cada segmento adjacente. Deste modo, o primeiro segmento (janela) compreende o segundo 0 ao 30, a segunda janela considera o segundo 15 ao 45 e o terceiro segmento inclui o segundo 30 ao 60. Estas técnicas são importantes em análises de EEG devido às características dinâmicas do cérebro ao longo do tempo (Casciola et al., 2021).

Por fim, oscilações dos sinais de EEG refletem a comunicação entre neurônios por meio de sinais elétricos, conforme discutido, sendo representadas por ondas cerebrais. De acordo com Sanei; Chambers (2021), estas ondas podem ser categorizadas em cinco bandas de frequência: i) *Delta*, caracterizada por alta amplitude; ii) *Theta*, normalmente encontrada em crianças; iii) *Alpha*, caracterizada pela ausência de concentração; iv) *Beta*, normalmente encontrada em adultos; e, v) *Gama*, caracterizada por baixa amplitude. Cada banda possui um intervalo de frequência específico e está associada a estados mentais particulares, conforme apresentado na Tabela 1.

Tabela 1 – Categorização das bandas cerebrais.

Banda	Intervalo de Frequência	Estado Mental
<i>Delta</i> (δ)	0,5 – 4 Hz	Sono profundo, inconsciente
<i>Theta</i> (θ)	4 – 8 Hz	Sonolência, calma, reflexão
<i>Alpha</i> (α)	8 – 13 Hz	Relaxamento, desperto
<i>Beta</i> (β)	13 – 30 Hz	Atenção, concentração
<i>Gama</i> (γ)	Mais que 30 Hz	Hiperatividade

Fonte: Sanei; Chambers (2021).

Neste contexto, a análise da atividade cerebral por meio de sinais de EEG pode ser realizada considerando bandas de frequência, visão temporal e regiões específicas do cérebro. Com isto, os sinais de EEG podem ser utilizados na investigação e compreensão de diversos aspectos cerebrais, tais como estados emocionais, processos cognitivos, memória e sono.

2.2 Teoria da Emoção

De acordo com Niedenthal; Ric (2017), a emoção pode ser entendida como uma resposta a estímulos externos, pessoas e eventos, bem como aos nossos próprios pensamentos. É importante ressaltar que as emoções não se referem a distúrbios afetivos, temperamentos de personalidade ou estados de ânimo. Niedenthal; Ric (2017) também ressaltam que as emoções podem ter um propósito funcional, auxiliando as pessoas a atraírem experiências desejadas e a se protegerem de situações adversas.

Conforme Kandel et al. (2013), as emoções constituem um conjunto de respostas fisiológicas automáticas que ocorrem no encéfalo e no corpo, de maneira inconsciente, quando o encéfalo percebe um estímulo positivo ou negativo. Já os sentimentos

referem-se às experiências conscientes com significados que o encéfalo cria para representar fenômenos fisiológicos gerados pelo estado emocional.

De forma geral, as emoções podem ser classificadas como: i) primárias/básicas, que podem ser sentidas por todas as pessoas, tendo em vista que não dependem de fatores sociais e culturais como, por exemplo, alegria e tristeza; ii) secundárias/morais, aprendidas pela influência do contexto social e cultural, sendo elas: culpa, vergonha, orgulho; e, iii) emoções de fundo, que refletem os estados gerais de bem-estar ou mal-estar, de ansiedade ou apreensão, de calma ou tensão (Lent, 2010).

As emoções também podem ser classificadas com base na perspectiva, discreta ou dimensional, conforme discutido no Capítulo 1. Devido à subjetividade das emoções, pesquisadores buscaram criar formas para definir e categorizar as emoções. A Teoria de Ekman (1993), por exemplo, baseia-se principalmente na observação das manifestações faciais. O autor defende que as emoções fundamentais não são aprendidas, possuem intensidades diferentes, são independentes e não se misturam. Para Ekman (1993), as emoções são classificadas com base na perspectiva discreta, ou seja, por meio de um conjunto de estados. Deste modo, as emoções básicas listadas pelo autor são: medo, tristeza, alegria, raiva, nojo e surpresa.

Russell (1980) é responsável pela Teoria das dimensões das emoções, foco de estudo deste trabalho. O autor defende que é possível determinar emoções discretas a partir da perspectiva dimensional por meio de escalas. A abordagem mais conhecida no contexto dimensional é da representação bidimensional das emoções, a qual se baseia nos eixos de valência (do inglês, *valence*) e excitação (do inglês, *arousal*).

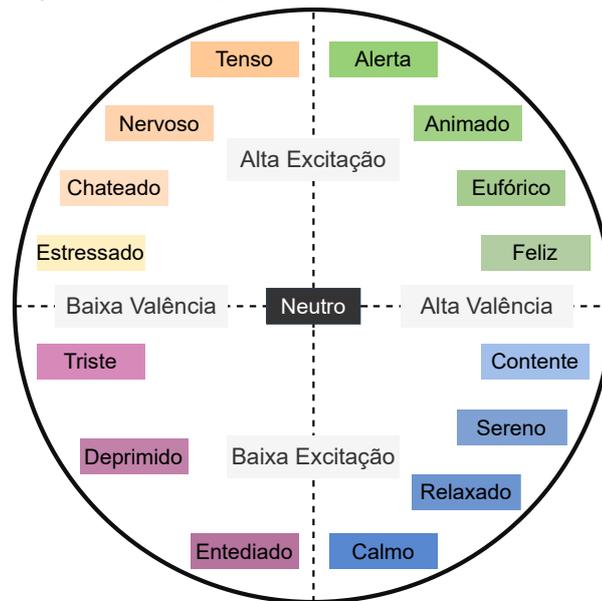
A valência se refere ao nível positivo ou negativo de uma emoção, onde uma emoção negativa tem baixa valência enquanto uma emoção positiva tem alta valência (Garg; Verma; Singh, 2023). Por exemplo, o estado feliz é uma emoção de alta valência, enquanto o estado entediado é uma emoção de baixa valência. A excitação, por sua vez, se refere ao nível de intensidade associado a uma emoção, variando de alto a baixo (Shu et al., 2018). Por exemplo, o estado calmo tem uma baixa excitação enquanto o estado tenso tem uma alta excitação.

A Figura 5 representa o modelo circumplexo de emoções proposto por Posner; Russell; Peterson (2005), onde são apresentadas as escalas de valência e excitação, além de emoções discretas distribuídas com base nos níveis de intensidade de cada dimensão. Através do circumplexo, pode-se observar que conforme se aumentam ou diminuem-se as escalas, as emoções variam. Assim, o circumplexo é útil porque fornece uma boa descrição de como as pessoas geralmente vivenciam seu estado emocional.

Além da representação bidimensional, outra abordagem envolve a representação tridimensional das emoções. Deste modo, no modelo também proposto por Russell (1980), além de valência e da excitação, inclui-se uma terceira dimensão chamada

dominância. A dominância se refere ao grau de controle que uma pessoa percebe ter sobre uma emoção, representando a força da emoção (Garg; Verma; Singh, 2023). De forma geral, as emoções dominantes são aquelas no qual a pessoa se sente no controle da situação, enquanto emoções não dominantes são aquelas onde a pessoa se sente dominada pela emoção.

Figura 5 – Modelo circumplexo de emoções.



Fonte: adaptado de Posner; Russell; Peterson (2005).

Associado a este contexto, em que as emoções dimensionais oferecem uma representação mais abrangente das emoções, pode-se categorizar e analisar as experiências emocionais humanas por meio de modelos construídos por Aprendizado de Máquina. Estes modelos, especialmente baseados em sinais de EEG, visam auxiliar a compreender melhor como as emoções são processadas no cérebro e como influenciam o comportamento humano.

2.3 Aprendizado de Máquina

O Aprendizado de Máquina (AM) é uma área da Inteligência Artificial que capacita os computadores a aprenderem com dados, tornando-os capazes de auxiliar na tomada de decisões. De acordo com Alpaydin (2014), o AM busca detectar padrões nos dados para realizar previsões com base em experiências passadas. Esta área é dividida conforme as características do problema a ser solucionado, destacando-se o aprendizado supervisionado e o aprendizado não-supervisionado.

No aprendizado de máquina supervisionado, durante o treinamento do algoritmo, é fornecido ao sistema um conjunto de dados no qual o resultado é conhecido. Com base nos atributos e nas informações de saída corretas, é possível construir um modelo que consiga aprender e gerar uma função ou hipótese para realizar previsões. Esse tipo de aprendizado é comumente utilizado para resolver problemas de classificação e regressão (Mohri; Rostamizadeh; Talwalkar, 2018).

O modelo de classificação é responsável por prever valores discretos, visando atribuir um registro a uma categoria (Faceli et al., 2021). Algoritmos de classificação podem ser aplicados em diversos contextos, como determinar se uma mensagem é *spam* ou legítima, avaliar se o risco de um empréstimo é alto ou baixo, ou ainda prever se o clima do dia será chuvoso ou não.

Por outro lado, o modelo de regressão possui a capacidade de prever valores contínuos, recorrendo a informações históricas (Mohri; Rostamizadeh; Talwalkar, 2018). Algoritmos de regressão podem ser aplicados em diversas situações, como prever a velocidade do vento, estimar a taxa de desemprego, ou prever a quantidade de chuva semanal.

No aprendizado de máquina não-supervisionado, não se dispõe de informações sobre a resposta desejada durante o treinamento. Isto significa que o modelo é construído apenas com base nos atributos disponíveis. Neste tipo de abordagem, os padrões são identificados por meio da análise automática dos dados (Shwartz; David, 2014). Uma das principais metodologias deste tipo de aprendizado é a clusterização, cujo objetivo é agrupar registros que possuem características em comum.

O aprendizado de máquina envolve o treinamento de uma variedade de algoritmos, os quais podem ser aplicados em diversos setores, como diagnóstico médico, visão computacional e processamento de língua natural (Alpaydin, 2014). Considerando o escopo deste trabalho, faz-se necessário implementar modelos de classificação, baseado em sinais de EEG, a fim de realizar previsões de emoções sob a perspectiva baixa ou alta. Portanto, três algoritmos de aprendizado supervisionado devem ser observados para compreensão deste estudo: *K-Nearest Neighbors*, *Random Forest* e *Support Vector Machine*. Estes algoritmos serão apresentados a seguir.

2.3.1 *K-Nearest Neighbors*

O algoritmo *K-Nearest Neighbors* (K-NN) é um método de AM utilizado para tarefas de classificação e regressão. A hipótese por trás deste algoritmo é de que dados similares tendem a estar concentrados em uma mesma região no espaço de entrada, o que implica que objetos do mesmo tipo são geralmente semelhantes entre si. Deste modo, a ideia central do K-NN é prever um novo ponto de dados com base na maioria dos exemplos de treinamento mais próximos a ele, que são chamados de vizinhos, em um espaço multidimensional (Alpaydin, 2014).

O espaço de entrada no K-NN é definido pelos atributos utilizados no treinamento. Assim, cada objeto representa um ponto no espaço definido pelos atributos. Para calcular a proximidade entre os pontos, utiliza-se uma métrica de distância, como a distância euclidiana (Richert; Coelho, 2013). Considerando a métrica euclidiana, calcula-se a distância entre dois pontos conforme a descrição da Equação 1:

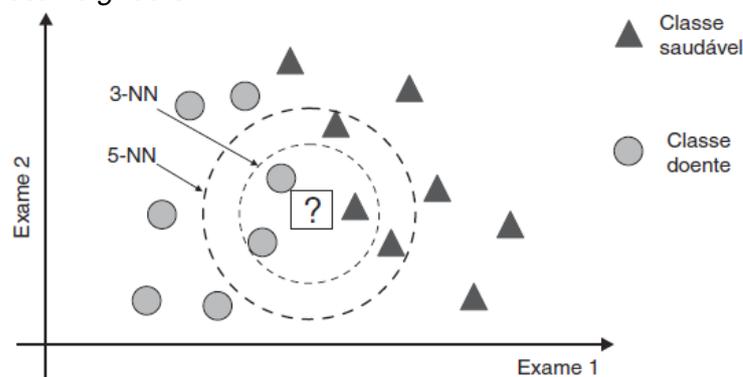
$$d(X_i, X_j) = \sqrt{\sum_{l=1}^d (x_i^l - x_j^l)^2} \quad (1)$$

onde X_i e X_j são objetos representados por vetores no espaço e x_i^l e x_j^l são elementos destes dois vetores, que correspondem aos valores dos atributos de coordenada l .

O número de vizinhos, conhecido como valor de K , é um dos hiperparâmetros mais importantes do algoritmo K-NN, por representar o número de objetos mais próximos que serão considerados ao realizar uma previsão. No caso da classificação, as classes de cada um dos vizinhos selecionados são agregadas para prever a classe do objeto de teste a partir de votação majoritária. De acordo com Faceli et al. (2021), na literatura, busca-se estimar K por meio de validação cruzada – técnica que será discutida no Capítulo 3, com preferência para valores ímpares a fim de desempate.

A Figura 6 ilustra um exemplo de aplicação do algoritmo K-NN, onde são considerados dois atributos referentes a exames e duas classes possíveis, saudável ou doente. Nesta Figura, observa-se que ao considerar o valor de K como três, temos dois vizinhos dos mais próximos da classe doente enquanto temos um vizinho da classe saudável, o que implica que o objeto de teste seria classificado como doente. Já ao considerar o valor de K como cinco, o objeto de teste seria classificado como saudável, pois teriam três exemplos próximos como saudável e dois como doente.

Figura 6 – *K-Nearest Neighbors*.



Fonte: Faceli et al. (2021).

Conforme as características do K-NN, destacam-se diversos aspectos. Apesar da simplicidade de treinamento, o algoritmo possui uma boa acurácia em diversos conjuntos de dados, o que faz com que sua aplicabilidade estenda-se a problemas de

alta complexidade. O algoritmo segue uma abordagem em que toda a computação é adiada até a fase de classificação, requerendo o cálculo de distância para todos os objetos de treinamento, tornando a predição mais custosa em *datasets* extensos. Além disto, o algoritmo pode ser afetado por atributos redundantes e irrelevantes, e pode enfrentar desafios com alta dimensionalidade, uma vez que o número de atributos define o número de dimensões no espaço (Faceli et al., 2021).

2.3.2 *Random Forest*

Random Forest (RF) é um algoritmo baseado na técnica de aprendizado em conjunto chamada *Ensemble Learning* (Geron, 2019). Isto significa que o algoritmo é construído por meio da combinação de vários modelos. No caso do *Random Forest* (Breiman, 2001) são considerados modelos de Árvore de Decisão (DT, acrônimo do termo em inglês *Decision Tree*), outro algoritmo no contexto de AM que será apresentado a seguir.

A árvore de decisão é um método que utiliza a estratégia de dividir um problema complexo em problemas mais simples. Deste modo, são criadas regras com base na relação entre a classe e os atributos envolvidos no processo. A construção deste algoritmo assemelha-se à estrutura de uma árvore invertida, onde os valores preditivos estão localizados nos nós terminais. Deve ser salientado que nem todos os atributos são necessariamente utilizados na construção da árvore (Alpaydin, 2014).

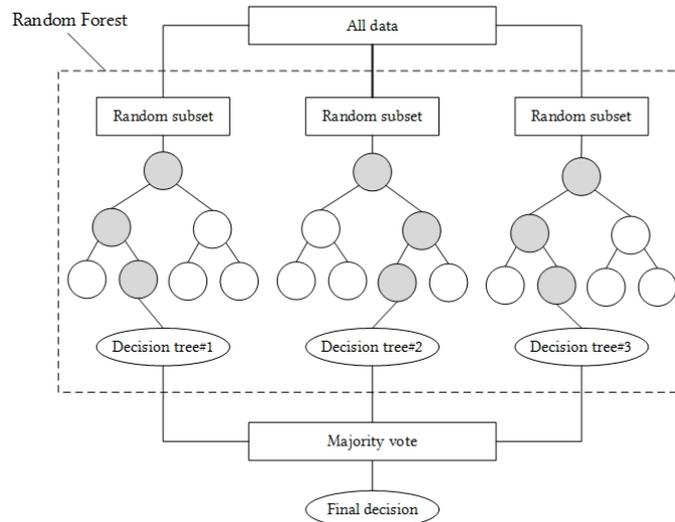
As árvores de decisão podem ser implementadas com base em diversos algoritmos, como CART (Breiman et al., 1984) e C4.5 (Quinlan, 1993). Para este trabalho, considerou-se a abordagem demonstrada pelo algoritmo CART (Árvores de Classificação e Regressão), sendo construídas árvores binárias, de tal forma que cada nó intermediário gere duas arestas de saída. As divisões e as variáveis de cada nó são selecionadas em acordo com o critério testado com as variáveis preditoras, mediante cálculos de erro. O processo de criação das divisões binárias é repetido até que não seja mais possível separar os nós ou por um critério de parada, realizando a poda na árvore, após a realização de todas as separações.

O *Random Forest* possibilita a definição do número de árvores de decisão a serem implementadas durante o processo de treinamento. Deste modo, cada árvore de decisão é treinada com base em uma subamostra aleatória dos dados de treino com um subconjunto aleatório de atributo, gerando modelos independentes e diversos. Por fim, a resposta do algoritmo é obtida por meio de votação majoritária considerando as previsões de todas as árvores. Segundo Alpaydin (2014), combinando diversas destas árvores é possível melhorar a precisão do modelo e obter melhores resultados.

A Figura 7 ilustra um exemplo de aplicação do algoritmo RF, onde a floresta é composta por três árvores de decisão. Considerando que todas as árvores seguem a mesma estrutura de decisão baseada nos atributos e cada um de seus nós terminais

refere-se a uma classe diferente, pode-se observar na Figura que a primeira e a última árvore de decisão geram o mesmo resultado, diferente da árvore central. Deste modo, ao realizar a votação majoritária, verifica-se que o resultado do algoritmo é o mesmo previsto pelas árvores laterais.

Figura 7 – *Random Forest*.



Fonte: Chapron et al. (2018).

Em termos gerais, umas das principais vantagens do RF é a sua capacidade de lidar com dados ruidosos e de alta dimensionalidade. Além disto, o algoritmo tende a generalizar bem para novos dados, sendo uma escolha popular para solucionar problemas reais. No entanto, o RF pode ser computacionalmente oneroso ao considerar um número alto de árvores de decisão na floresta. Deste modo, a execução do algoritmo pode precisar de uma quantidade significativa de recursos computacionais, como tempo de processamento, memória RAM ou processamento da CPU. Ainda, a interpretação das decisões do modelo pode ser complicada devido à sua natureza *ensemble* (Geron, 2019).

2.3.3 *Support Vector Machine*

O algoritmo *Support Vector Machine* (SVM) é um método de AM, particularmente eficaz em solucionar problemas de classificação. O princípio básico do SVM é encontrar o hiperplano que melhor separa os dados com base nas classes do problema. Este hiperplano é escolhido a fim de maximizar as margens, a qual é definida como a distância entre o hiperplano e os pontos de dados mais próximos de cada classes, os quais são chamados de vetores de suporte (Geron, 2019).

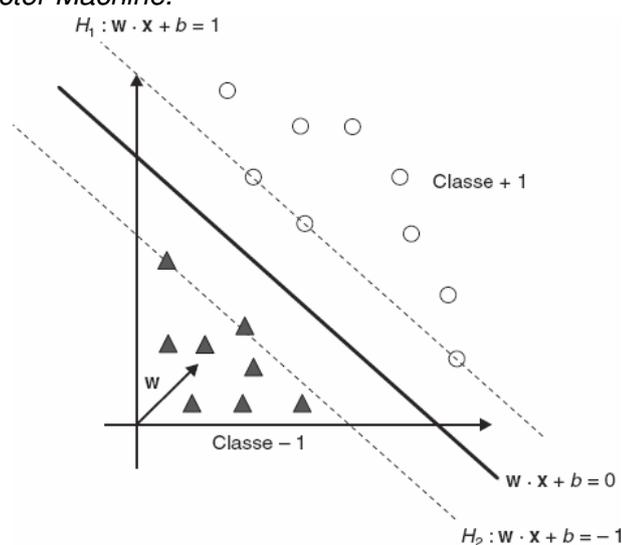
Considerando a resolução de problemas de classificação lineares, onde os dados podem ser separados por uma reta, plano ou hiperplano, calcula-se o hiperplano do SVM a partir da Equação 2:

$$y = w \cdot x + b \quad (2)$$

onde $w \cdot x$ representa o produto escalar entre os dois vetores, sendo w o vetor normal ao hiperplano e x o vetor de entrada, e b uma constante utilizada no cálculo da distância do hiperplano em relação à origem (Faceli et al., 2021). Com base nesta equação, pode-se dividir o espaço de entrada em duas regiões, $w \cdot x + b > 0$ e $w \cdot x + b < 0$.

A Figura 8 apresenta um gráfico onde é representado o SVM para um problema linear. A partir desta Figura é possível observar o hiperplano representado por meio da reta central, as margens por meio das retas tracejadas, os vetores de suporte por meio dos símbolos sobre as margens, além das duas classes representadas pelos símbolos de triângulo e círculo.

Figura 8 – *Support Vector Machine*.



Fonte: Faceli et al. (2021).

Em problemas reais, é incomum encontrar aplicações onde os dados sejam linearmente separáveis, seja pela presença de ruídos ou pela natureza do problema. Para lidar com esta questão, o SVM inclui durante o treinamento uma constante de regularização C , responsável por controlar a suavidade da margem. Em geral, valores mais altos de C tornam a margem mais estreita, fazendo com que o modelo se ajuste mais aos dados de treino. Por outro lado, valores mais baixos de C resultam em uma margem mais ampla, que permite mais violações, fazendo com que o modelo generalize melhor (Faceli et al., 2021).

Estas violações estão relacionadas às variáveis de folga ξ , que permitem alguns erros de classificação e que registros permaneçam entre as margens. Assim, o problema de otimização de SVM pode ser descrito conforme a Equação 3:

$$\min_{w,b,\xi} \frac{1}{2} \|w\|^2 + C \left(\sum_{i=1}^n \xi_i \right) \quad (3)$$

Para casos em que não é possível realizar uma divisão satisfatória dos dados de treinamento por um hiperplano, pode-se utilizar SVMs não-lineares. O SVM para classificação não-linear realiza o mapeamento dos dados para espaços de maior dimensão por meio de funções de *kernel*. O intuito da aplicação da função de *kernel* é fazer com que os dados sejam linearmente separáveis em uma dimensão mais alta. Deve ser salientado que a transformação da dimensão dos dados não pode ser linear e a dimensão entre o mapeamento dos dados entre o espaço original e o de maior dimensão deve ser suficientemente alta (Alpaydin, 2014).

Dentre os *kernels* mais populares estão o *kernel* polinomial e *kernel* de função base radial (RBF, acrônimo do termo em inglês *Radial Basis Function*). O *kernel* polinomial transforma os dados em um espaço de características de maior dimensão por meio de funções polinomiais, como o polinômio cúbico. Por outro lado, o RBF pode mapear os dados para dimensões muito superiores, sendo eficaz em problemas complexos (Geron, 2019).

De forma geral, o algoritmo SVM possui uma boa capacidade de generalização e é robusto para treinar problemas complexos. Entretanto, o algoritmo é lento quando são consideradas milhares de instâncias de treinamento. Outra limitação do algoritmo se refere a sensibilidade na escolha dos hiperparâmetros, além da dificuldade de interpretação do modelo gerado (Geron, 2019).

2.3.4 Métricas de Avaliação

O processo de avaliação de modelos de aprendizado de máquina é um passo importante para analisar seus desempenhos. No contexto deste trabalho, torna-se relevante considerar métricas específicas para modelos construídos por meio de algoritmos de classificação. As principais métricas estão elencadas a seguir:

Acurácia: Proporção entre as previsões corretas do modelo e o total de amostras classificadas. Esta métrica indica o desempenho geral do classificador (Faceli et al., 2021).

Precisão: Proporção de classificações positivas que foram de fato corretas. Esta métrica é importante em contextos em que a minimização de falsos positivos é crítica (Alpaydin, 2014).

Sensibilidade: Proporção de predições positivas que tinham como valor esperado a classe positiva. Esta métrica é importante em contextos em que a minimização de falsos negativos é crítica (Geron, 2019).

F1-Score: Média harmônica entre as métricas Precisão e Sensibilidade. Este cálculo possibilita observar apenas uma métrica ao invés de duas, servindo para criar *rankings* (Geron, 2019).

Além das métricas citadas, cabe destacar a Matriz de Confusão para avaliar modelos de classificação. Esta matriz refere-se a uma representação detalhada das previsões corretas e incorretas em cada classe (Faceli et al., 2021). No cenário de classe binária, a matriz possui valores de: classificação correta da classe positivo (verdadeiros positivos), classificação correta da classe negativo (verdadeiros negativos), classificação incorreta da classe negativo (falsos positivos) e classificação incorreta da classe positivo (falsos negativos). Deste modo, a matriz de confusão é uma ferramenta valiosa para entender o desempenho do modelo por classe.

2.4 Processamento Digital de Imagens

O Processamento Digital de Imagens (PDI) é uma área concentrada no processamento de imagens digitais por meio de um computador. Esta área envolve a manipulação de imagens visando realizar tarefas específicas, como reconhecimento de padrões, segmentação de objetos e restauração de imagens (Gonzales; Woods, 2019).

Uma imagem digital pode ser definida como uma representação discreta de dados contendo coordenadas espaciais e informações de intensidade, composta por um conjunto de elementos conhecidos como píxeis. Cada píxel é responsável por representar uma cor específica ou intensidade de luz em um local da imagem, geralmente expresso em linhas e colunas (Solomon; Breckon, 2010).

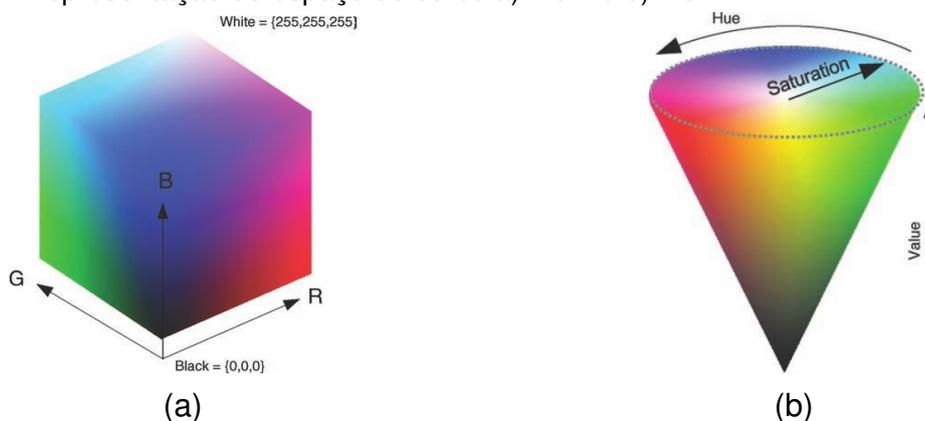
2.4.1 Espaços de Cores

As cores das imagens podem ser definidas por meio de um espaço de cores, um padrão que descreve como as cores são representadas, tendo pelo menos um canal que define a cor de cada píxel. No caso do espaço de cores de intensidade, que representa a escala de cinza, é utilizado apenas um canal. Já no caso de espaço de cores para imagens coloridas, onde são utilizados mais de um canal, a cor do píxel é obtida por meio da combinação de canais (Solomon; Breckon, 2010).

A Figura 9 ilustra dois tipos de espaço de cores para imagens coloridas, RGB e HSV, por meio de representações geométricas. O espaço de cores RGB possui três canais, baseado nas cores primárias vermelho (R, de *red*), verde (G, de *green*) e azul (B, de *blue*) (Bradski; Kaehler, 2008). Na representação do espaço RGB, apresen-

tado na Figura 9(a) por um cubo, é possível gerar diversas cores através das três dimensões referentes às cores primárias. Destaca-se que quando todos os três canais atingem o valor máximo da escala, gera-se o branco, enquanto todos atingem o valor mínimo, produz-se o preto. Apesar do espaço de cores RGB ser o mais utilizado na representação de imagens digitais, de acordo com Gonzales; Woods (2019), ele não é adequado para descrever as cores por meio da interpretação humana, tendo em vista que as pessoas não se referem à cor por meio da porcentagem de cada uma das primárias.

Figura 9 – Representação do espaço de cores a) RGB e b) HSV.



Fonte: Solomon; Breckon (2010).

O espaço de cores HSV, por sua vez, é um sistema que corresponde em termos práticos à percepção visual no qual os humanos interpretam as cores (Gonzales; Woods, 2019). Na representação do espaço HSV, apresentado na Figura 9(b) por um cone, é possível gerar as cores por meio de três canais:

M (Matiz): Atributo associado à “tonalidade” da cor, ou seja, ao comprimento de onda dominante da cor percebida pelos humanos. O matiz pode ser representado como um valor em graus, variando de 0 até 360, onde 0 corresponde ao vermelho, 120 ao verde e 240 ao azul.

S (Saturação): Componente associado à “pureza” da cor, ou seja, à quantidade de luz branca misturada com a tonalidade. A saturação é inversamente proporcional a quantidade de luz branca, e as cores do espectro puro estão totalmente saturadas.

V (Valor): Propriedade associada à “intensidade” ou ao “brilho” da cor. Valores mais altos indicam cores mais brilhantes, enquanto valores mais baixos resultam em cores mais escuras.

Considerando o escopo deste estudo, faz-se necessário aplicar técnicas de PDI, a fim de extrair informações úteis das imagens topográficas cerebrais baseadas em sinais de EEG. Deste modo, a seguir é realizada uma discussão sobre segmentação de imagens.

2.4.2 Segmentação de Imagens

A segmentação de imagens é o processo de dividir uma imagem em regiões ou objetos significativos (Gonzales; Woods, 2019). Esta área é dividida conforme as características específicas do problema a ser solucionado, destacando-se a limiarização, segmentação por bordas e segmentação baseada em cores.

A limiarização é uma técnica que gera uma imagem binária, em escala de cinza, com base em um valor limite. Na limiarização binária comum, os píxeis da imagem original de intensidade acima do limiar são tratados como parte do objeto, enquanto os demais píxeis são considerados partes do fundo. Por outro lado, na limiarização binária invertida, os píxeis de intensidade abaixo do limiar são tratados como parte do objeto e o restante como fundo (Bradski; Kaehler, 2008).

O processo de segmentação por bordas é um método que permite dividir uma imagem por meio da localização das bordas de objetos, baseado em mudança com grande variação de intensidade luminosa. Um dos algoritmos mais conhecidos para obter estas localizações é o *Canny Edge Detector*¹, capaz de encontrar bordas minimizando falsas detecções (Solomon; Breckon, 2010).

Por fim, a segmentação baseada em cores é uma técnica que permite segmentar partes de uma imagem por meio de informações das cores dos píxeis. Com esta segmentação, permite-se manter apenas os píxeis de determinadas cores. Nesta técnica, é necessário definir o espaço de cores apropriado para representar as cores com base nas características da imagem e da tarefa de segmentação (Gonzales; Woods, 2019).

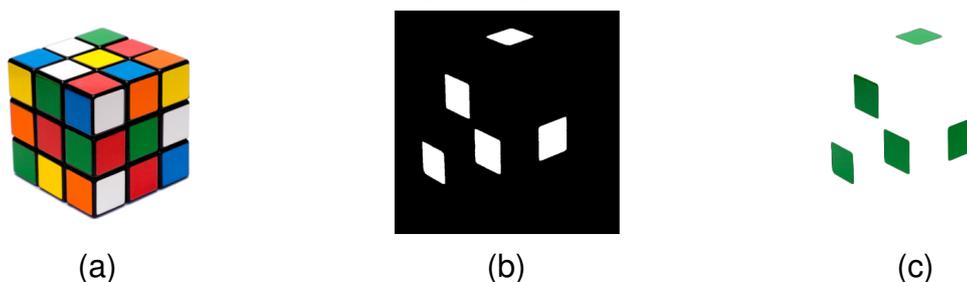
Para realizar o processo de segmentação, é comum obter uma imagem binária no qual os píxeis da região de interesse estão marcados como branco e os demais são marcados como preto (Bradski; Kaehler, 2008). A partir desta imagem, chamada de filtro ou máscara, é possível aplicar a segmentação de imagem, a fim de selecionar, ocultar ou destacar regiões de interesse de uma imagem com base em critérios pré-definidos. A Figura 10 ilustra a segmentação de uma imagem baseada em cores. Nesta Figura, observa-se a imagem original, a máscara criada para filtrar os elementos em verde e a imagem segmentada, após aplicação do filtro.

Em muitos casos, as técnicas de segmentação de imagens são combinadas com outras técnicas de PDI para obtenção de resultados melhores. Dentre estas técnicas, estão o desfoque e a dilatação. O desfoque, processo de suavização da imagem, é uma etapa utilizada frequentemente para reduzir o ruído ou a resolução de uma ima-

¹https://docs.opencv.org/4.x/da/d22/tutorial_py_canny.html

gem (Solomon; Breckon, 2010). Por fim, a dilatação é uma etapa em que se aumenta a área do objeto ao redor dos píxeis, com o intuito de reduzir ruído ou engrossar objetos. A dilatação é uma técnica de morfologia matemática, um conjunto de operações para extrair informações de imagens (Gonzales; Woods, 2019).

Figura 10 – Segmentação de imagem baseada em cores: a) imagem original; b) filtro para captura de píxeis da cor verde; e, c) imagem segmentada.



Fonte: Karlsson (2007).

2.5 Trabalhos Relacionados

No contexto do reconhecimento de emoções com o uso de sinais de EEG, existem trabalhos na literatura que propõem sistemas com base em diversos tipos de técnicas tendo como estudo de caso diferentes *datasets*. Os *datasets* utilizados na área deste trabalho são construídos com base em distintas características, como tipo de estímulo e abordagem para percepção da emoção.

O SEED (Zheng; Lu, 2015), por exemplo, diz respeito ao conjunto de sinais de EEG coletados de 15 indivíduos por meio de 62 canais de eletrodos conectados ao couro cabeludo. Para este *dataset*, cada indivíduo assistiu a 15 trechos de filmes. Os sujeitos classificaram os vídeos como positivo, negativo ou neutro. Já o DEAP (Koelstra et al., 2012), foi construído a partir da coleta de sinais de EEG de 32 participantes por meio de 32 canais de eletrodos. Os participantes classificaram as emoções sentidas enquanto assistiam aos vídeos ao nível de escalas. A seguir, serão discutidos os trabalhos relacionados considerando os *datasets* apresentados.

O estudo de Li; Zhang; He (2018) apresenta modelos para identificação de emoções como positivo, negativo e neutro. Os dados utilizados neste trabalho são do SEED, sendo realizado segmentação por segundo nos sinais de EEG. Além disto, calculou-se *Short-Term Fourier Transform* de 256 pontos com janela de *Hanning* não sobreposta. Para extração de recursos, calculou-se a Entropia Diferencial (ED) para as cinco bandas de frequência. Por fim, organizaram-se os recursos como mapas 2D e introduziu-se esparsidade, adicionando linhas e colunas nulas nas matrizes.

A abordagem proposta consiste em uma *Hierarchical Convolutional Neural Networks* (HCNN), com duas camadas de convolução e duas camadas de *Max-Pooling*, tendo um vetor 144D conectado a três nós de saída, onde cada nó corresponde a um rótulo emocional. Para os experimentos, considerou-se: valores iniciais das redes como aleatório, 1 para taxa de aprendizagem, 50 para tamanho de lote, 600 épocas de aprendizagem e função de ativação sigmoide. Considerando as cinco bandas de frequência, 75% de dados para treino e 25% para teste, criaram-se cinco modelos para cada sujeito. Os autores destacam que faixas de alta frequência são mais adequadas para reconhecimento de emoções, tendo 88,2% de acurácia para banda de frequência γ (Gama).

O trabalho proposto por Qing et al. (2019) consiste na identificação de emoções por polaridade, sendo utilizados dois *datasets*. Para o SEED, realizou-se: aplicação de filtro passa-banda usando os últimos 155 segundos; segmentação com janela de um segundo; extração de características por quatro recursos estatísticos diferenciais; e, uso do *Stacked Autoencoder* para extração de recursos. Para o DEAP, seguiu-se o fluxo: seleção dos últimos 60 segundos; segmentação com janela de tempo de dois segundos com sobreposição de um; aplicação de ED para as cinco bandas de frequência; e, conversão das emoções dimensionais para positivo, negativo e neutro.

Para classificação, os autores utilizaram um método de votação simples baseado em modelos construídos por *Árvore de Decisão* (DT), *K-Nearest Neighbors* (K-NN) e *Random Forest* (RF). Considerando os resultados de teste obtidos em uma validação cruzada de dez vezes, calcularam-se coeficientes de correlação e entropia para todas as amostras que pertenciam à mesma categoria. Conforme os coeficientes, gerou-se um coeficiente de peso, utilizado para obtenção da emoção final. Deste modo, para o modelo construído, destaca-se acurácia de 63,09% para o DEAP e de 75% para o SEED. Com isso, os autores verificam que as emoções são progressivamente ativadas e que houve uma melhora de desempenho comparado ao treino com dados brutos.

No estudo de Asghar et al. (2019), são apresentados modelos para reconhecimento de emoções positivo, negativo e neutro – com base no *dataset* SEED, e de combinações entre alta (H, de *High*) e baixa (L, de *Low*) com valência (V, de *valence*) e excitação (A, de *arousal*) – com base no *dataset* DEAP. A fim de gerar uma representação dos sinais de EEG no tempo-frequência, foram construídos espectrogramas em imagens 227×227 por meio de *Continuous Wavelet Transform* (CWT). Para extração de recursos dos espectrogramas, utilizou-se a rede neural profunda pré-treinada *AlexNet*, porém sem o uso da camada de classificação *softmax*.

Os autores criaram *Bag of Deep Features* para redução de recursos, onde características semelhantes de uma mesma classe são agrupadas em *clusters k-Means*. Foram usadas as dez características mais próximas do centroide de cada classe. Para classificação, os autores obtiveram melhores resultados com o *Support Vector Ma-*

chine (SVM), de *kernel* cúbico, a partir de validação cruzada de 20 vezes. A acurácia média obtida por sujeito foi de 93,8% para as classes ternárias do SEED e de 77,4% para as classes quaternárias do DEAP.

O trabalho de Sharma; Pachori; Sircar (2020) consegue classificar as emoções no formato quaternário, por meio de combinações entre alta e baixa para excitação e valência. O estudo de caso foi realizado com base no DEAP, sendo aplicado filtro passa-banda (4-45 Hz) e selecionado os últimos 30 segundos de cada sinal. Utilizou-se a técnica *Discrete Wavelet Transform* para decomposição do sinal em bandas de frequência. Além disto, considerou-se a técnica *Third-order Cumulants* (ToC) para extração de características através da decomposição dos sinais no espaço dimensional superior. Por fim, utilizou-se *Particle Swarm Optimization* para otimização da matriz de recursos e redução de dimensão, e normalização.

A técnica empregada para construção do modelo baseia-se em *Long Short-Term Memory* (LSTM), com função de ativação sigmoide. A arquitetura proposta possui as seguintes camadas: de sequência, LSTM bidirecional, totalmente conectada e *softmax*. Foram utilizadas 100 épocas para aprendizagem, taxa de aprendizado inicial de 0,001 e 50 como *minibatch size*. Os resultados do modelo mostram 82% de acurácia média por sujeito, considerando validação cruzada de dez vezes.

O trabalho de Demir et al. (2021) construiu modelos binários para classificação de alta/baixa excitação e alta/baixa valência, com o uso do DEAP. Foram consideradas as seguintes etapas de pré-processamento: aplicação de filtro passa-baixas para eliminação de ruído; decomposição do sinal em cinco bandas de frequência por *Wavelet Transform*; e, conversão dos sinais de EEG em imagens a partir de CWT. Para extração de recursos, foram realizados testes com cinco modelos pré-treinados de CNN: *AlexNet*, *VGG16*, *ResNet50*, *SqueezeNet* e *MobilNetv2*.

Os autores utilizaram SVM para classificação das emoções, tendo os parâmetros ajustados por *Grid Search*, com destaque para *kernel* RBF. A separação dos dados foi realizada de forma aleatória, sendo 75% para treinamento e o restante para treino. Como melhores resultados de classificação de alta/baixa *valence*, percebe-se acurácia de 91,07% considerando *AlexNet* e banda de frequência α (Alpha). Já como melhores resultados de alta/baixa *arousal*, destaca-se acurácia de 98,93%. Deve ser salientado que não foram utilizadas *arousal/valence* iguais a cinco, definidos como neutro pelos autores. Além disto, o estudo considerou os cinco canais com maiores pontuações e a média, tendo em vista que foi construído um modelo para cada sujeito.

Por fim, o estudo de Samavat et al. (2022) utiliza os *datasets* SEED e DEAP, sendo as classes deste último transformadas em positivo, negativo e neutro, conforme a escala de *valence*. Como pré-processamento, realizou-se a redução de ruídos por filtro passa-banda de 0,3-50 Hz e segmentação do sinal em dois segundos sem sobreposição. A abordagem proposta para extração de recursos consiste em Entropia

Diferencial – para β (Beta) e γ (Gama), e em duas *Convolutional Neural Networks* (CNNs) independentes – uma com filtro pequeno e outra com filtro grande, seguidas por camada de *Max-Pooling*. Para as CNNs, foi utilizado o otimizador ADAM, taxa de aprendizagem de 0,0005, aprendizagem para decaimento de 0,5, taxa de decaimento do primeiro e segundo momentos com beta de 0,9 e 0,999, respectivamente, e conjunto de treinamento com *minibatch size* de 120.

Deste modo, os autores buscam encontrar recursos variantes e reduzir a distribuição de peso em camadas. Para redução do espaço de características oriundos da concatenação das saídas das CNNs e vetor de ED, utiliza-se uma rede neural. Após, são fornecidas informações temporais com um bloco Bi-LSTM, sendo usada a função logística sigmoide. Por fim, a unidade de classificação rotula as emoções por polaridade, através do *softmax*. Em suma, o algoritmo de treinamento é desenvolvido com base em retropropagação iterativa para ajustar os pesos da rede, enquanto se aplica o método de regularização adaptativa sobre cada camada paralela de CNNs para considerar as informações espaciais dos eletrodos. Como resultados, destaca-se acurácia de 81,54% para o SEED e 72,38% para o DEAP, via validação cruzada de dez vezes.

Os estudos discutidos apresentam diferentes abordagens. A Tabela 2 sumariza os trabalhos relacionados e os compara, destacando: *datasets* utilizados, tipo de dados e frequências utilizadas durante a construção dos modelos, principais classificadores e os tipos de emoções avaliadas.

Tabela 2 – Comparação entre os trabalhos relacionados.

Artigo	Dataset	Tipo dos Dados	Frequências	Classificadores	Estados Emocionais
(Li; Zhang; He, 2018)	SEED	Mapa topográfico (Projeção Polar)	$\delta, \theta, \alpha, \beta, \gamma$	HCNN	Positivo, Negativo, Neutro
(Qing et al., 2019)	DEAP SEED	Matriz 2D	$\delta, \theta, \alpha, \beta, \gamma$ 0-75 Hz	AD, K-NN, RF	Positivo, Negativo, Neutro
(Asghar et al., 2019)	DEAP SEED	Espectrograma (CWT)	0-75 Hz	SVM	HAHV, HALV, LAHV, LALV Positivo, Negativo, Neutro
(Sharma; Pachori; Sircar, 2020)	DEAP	Mapa topográfico (ToC)	$\delta, \theta, \alpha, \beta, \gamma$	LSTM	HAHV, HALV, LAHV, LALV
(Demir et al., 2021)	DEAP	Espectrograma (CWT)	$\delta, \theta, \alpha, \beta, \gamma$	SVM	HA, LA; HV, LV
(Samavat et al., 2022)	DEAP SEED	Matriz 62D	β, γ	Bi-LSTM	Positivo, Negativo, Neutro
Este estudo	DEAP	Mapa topográfico (EEGLAB)	α, β, γ	K-NN, SVM, RF	HA, LA; HV, LV; HD, LD; HL, LL

Fonte: autoria própria.

Baseado na análise dos trabalhos relacionados na literatura, constata-se que os estudos dividem-se entre processar diretamente os sinais de EEG e processar imagens derivadas de sinais de EEG. Além disto, tratando-se da previsão de emoções dimensionais, os estudos focam apenas na excitação e valência. Tendo em vista as características complexas dos sinais de EEG, os estudos relacionados focam em sua maioria na decomposição de sinais e extração de recursos. De forma geral, os autores decompõem os sinais em cinco bandas de frequência. Entretanto, Samavat et al. (2022) utilizam apenas as duas faixas de frequências mais altas, pois, segundo eles, estas frequências são mais relevantes para identificação de emoções. Para extração de características há uma grande variedade e combinação de métodos focados em

técnicas, como: Entropia Diferencial e Aprendizado Profundo.

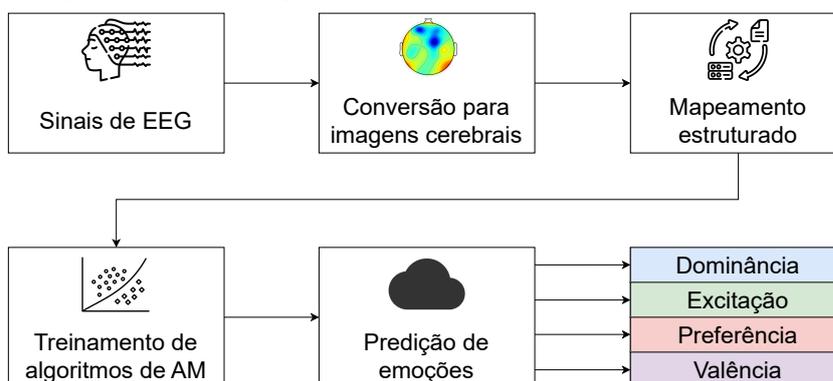
Em relação aos *datasets* utilizados para o desenvolvimento dos estudos, percebe-se uma maior utilização pela comunidade dos dados do DEAP e SEED. De acordo com Garg; Verma; Singh (2023), o DEAP é o *dataset* mais utilizado na literatura para reconhecimento de emoções com sinais de EEG. De forma geral, os trabalhos relacionados focam na classificação de emoções por polaridade e em combinações do nível da escala para dimensões de excitação e valência. Além disto, a grande maioria dos trabalhos constrói modelos dependentes dos sujeitos, ou seja, um modelo para cada sujeito. Em relação às técnicas de AM para reconhecimento de emoções, os estudos focam em técnicas de aprendizado profundo, como HCNN e LSTM, enquanto os demais focam em algoritmos de aprendizado raso, como SVM.

Neste contexto, este estudo propõe uma abordagem para o reconhecimento de emoções, utilizando imagens de mapas topográficos do cérebro gerados a partir de sinais de EEG no EEGLAB. O diferencial em relação aos trabalhos descritos reside na apresentação de um conjunto de dados estruturado que mapeia os níveis de ativação cerebral por regiões a partir das imagens, proporcionando um novo tipo de análise de sinais de EEG. Além disto, baseado no *dataset* construído, este trabalho apresenta modelos preditores para excitação, valência, dominância e preferência, incluindo análises espaciais, temporais e de frequência.

3 ABORDAGEM PROPOSTA

Neste Capítulo é apresentada a abordagem proposta por este trabalho, detalhado o *pipeline* para o reconhecimento de emoções dimensionais e as decisões metodológicas adotadas. O *pipeline* desenvolvido, ilustrado na Figura 11, foi implementado recorrendo à ferramenta EEGLAB (Delorme; Makeig, 2004), juntamente com as bibliotecas *OpenCV* (Bradski; Kaehler, 2008), *Pandas* (Mckinney et al., 2010) e *Scikit-Learn* (Pedregosa et al., 2011), em *Python* (Van rossum; Drake, 2009).

Figura 11 – Visão geral do *pipeline* para reconhecimento de emoções.



Fonte: autoria própria.

Conforme ilustrado na Figura 11, o início do *pipeline* consiste em um conjunto de sinais de EEG como entrada. Estes dados passam por um processo de conversão, que os transformam em imagens topográficas cerebrais. Em seguida, são aplicadas técnicas de processamento digital de imagens nestas imagens, a fim de segmentar as regiões de interesse. Com as imagens segmentadas pelas regiões dos eletrodos, realiza-se o mapeamento estruturado dos níveis de ativação das áreas do córtex cerebral por meio das cores dos píxeis. Este *dataset* estruturado é, então, utilizado para treinar algoritmos de AM. Por fim, o *pipeline* permite a realização de predições, utilizando os modelos de AM mais bem avaliados, para classificar emoções sob a perspectiva baixa ou alta em quatro tipos de dimensões: excitação, valência, dominância e preferência.

Neste cenário, a seguir serão apresentadas as seguintes etapas metodológicas: i) transformação dos sinais de EEG em mapas topográficos e processamento de imagens; ii) criação de *dataset* estruturado por meio do mapeamento dos níveis de ativação cerebral por eletrodo baseado nas cores dos píxeis dos mapas topográficos; e, iii) desenvolvimento de modelos preditores de emoções com aprendizado de máquina.

3.1 Base de Dados

O *dataset* DEAP (*Database for Emotion Analysis using Physiological Signals*) (Koelstra et al., 2012), foco deste estudo, é amplamente reconhecido e estudado no campo da análise de emoções humanas. Este conjunto de dados contém sinais de EEG coletados de 32 participantes por meio de 32 eletrodos. É importante ressaltar que, embora o *dataset* contenha outros dados fisiológicos, este estudo se concentra exclusivamente em experimentos com os sinais de EEG.

Para construção do DEAP, cada sujeito foi submetido a 40 trechos de vídeos musicais de um minuto de duração e atribuiu avaliações emocionais a estes vídeos em cinco dimensões: dominância, excitação, familiaridade, preferência e valência. Para a familiaridade, as avaliações foram discretas – variando de um a cinco, enquanto as demais dimensões foram avaliadas de forma contínua – variando de um a nove. Infelizmente, existem dados faltantes referentes à dimensão de familiaridade para os participantes 2, 15 e 23. Devido à ausência destes dados e à sua menor relevância no contexto de classificação de emoções, optou-se por não incluir estes dados.

A Tabela 3 apresenta exemplos de autoavaliações emocionais realizadas após os experimentos. Estas autoavaliações, presentes nos dados tabulares do DEAP¹ por meio do arquivo “participants_ratings”, servem de base para definição das classes para os modelos de predição de emoções.

Tabela 3 – Amostras de autoavaliações realizadas pelos sujeitos durante os experimentos

Sujeito	Experimento	Dominância	Excitação	Preferência	Valência
1	1	6,9	7,6	7,83	7,71
7	21	6,06	5,99	6,94	3,12
24	40	4,99	2,97	4,04	5
32	26	8,83	3,09	3,08	5,14

Fonte: autoria própria.

Conforme mencionado anteriormente, o foco deste trabalho é explorar o uso de mapas topográficos derivados de sinais de EEG. Tendo em vista a relevância do *dataset* DEAP na literatura, conforme citado na Seção 2.5, sua diversidade de estímulos e respostas, e possibilidade de utilizar seus dados para gerar imagens de mapas to-

¹<https://www.eecs.qmul.ac.uk/mmv/datasets/deap/>

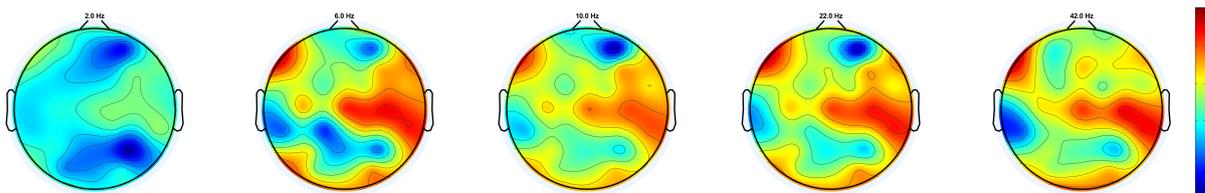
pográficos cerebrais, este conjunto de dados foi selecionado como base de dados do presente trabalho. Estes tipos de imagens, neste contexto, representam distribuições espaciais de atividades elétricas do cérebro por tempo e frequência (Xu et al., 2020).

Para atingir o propósito deste estudo, foram geradas imagens de mapas topográficos com base nos sinais de EEG contidos no DEAP. Estas imagens foram criadas usando um *script* desenvolvido por Cerri (2023) no contexto do grupo de pesquisa ao qual este trabalho está vinculado. Este *script* faz o uso do EEGLAB (Delorme; Makeig, 2004), uma das ferramentas mais utilizadas e poderosas disponíveis para explorar sinais de EEG, sendo amplamente adotado por pesquisadores e profissionais da área da neurociência.

O conjunto de dados resultante abrange um total de 396.800 imagens que capturam a atividade cerebral dos 32 participantes que assistiram aos 40 vídeos. As imagens de cada experimento foram geradas considerando 62 intervalos de tempo, definido como épocas, variando de 0 até 62 segundos, com intervalo de 1 segundo. Deste modo, cada imagem corresponde a uma época, e abrange uma das cinco diferentes bandas de frequência representada por uma amostra intermediária: *Delta* (2 Hz), *Theta* (6 Hz), *Alpha* (10 Hz), *Beta* (22 Hz) ou *Gama* (42 Hz). Nesta Dissertação, as referências às amostras de frequência serão realizadas utilizando as respectivas bandas associadas. Cabe ressaltar que foram utilizadas apenas amostras de frequência devido ao tempo elevado e a necessidade de armazenamento para processamento dos sinais e geração das imagens na ferramenta EEGLAB. O *dataset* de imagens possui cerca de 32 GB de dados.

A Figura 12 apresenta cinco imagens geradas durante um experimento, em uma determinada época, sendo que cada imagem corresponde a uma frequência cerebral distinta. Ao observar estas imagens, é possível identificar o nível de ativação das regiões cerebrais por meio de uma escala de cores. Píxeis de cores quentes, como o vermelho-escuro, representam regiões de alta atividade cerebral. Píxeis de cores intermediárias, como o amarelo, representam regiões de moderada atividade. E, píxeis de cores frias, como o azul-escuro, representam regiões de baixa atividade cerebral.

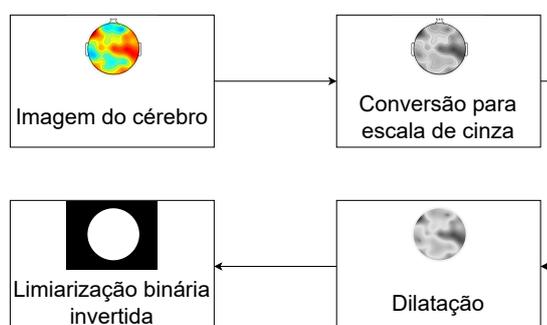
Figura 12 – Imagens topográficas cerebrais geradas no EEGLAB para cinco amostras de frequência.



Fonte: autoria própria.

Ao analisar os mapas cerebrais gerados, por meio dos exemplos ilustrados na Figura 12, é perceptível a presença de informações além da região cerebral de interesse, como as representações, nas laterais, das orelhas. Neste contexto, por meio do uso de técnicas de processamento digital de imagens, é possível segmentar as imagens visando remover áreas externas às zonas de interesse.

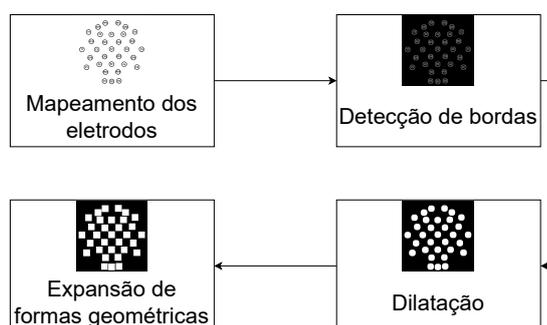
Figura 13 – Etapas do filtro cerebral.



Fonte: autoria própria.

Para este propósito, inicialmente criou-se um filtro, ilustrado na Figura 13, cujo objetivo é eliminar áreas externas ao círculo que representa o cérebro, incluindo as representações das orelhas, nariz e frequência amostrada. Posteriormente, criou-se um segundo filtro, ilustrado na Figura 14, para segmentar as áreas que correspondem ao posicionamento dos eletrodos nas imagens topográficas cerebrais. Este processo de segmentação de imagens é fundamental para viabilizar uma análise detalhada das diferentes regiões cerebrais.

Figura 14 – Etapas do filtro dos eletrodos.



Fonte: autoria própria.

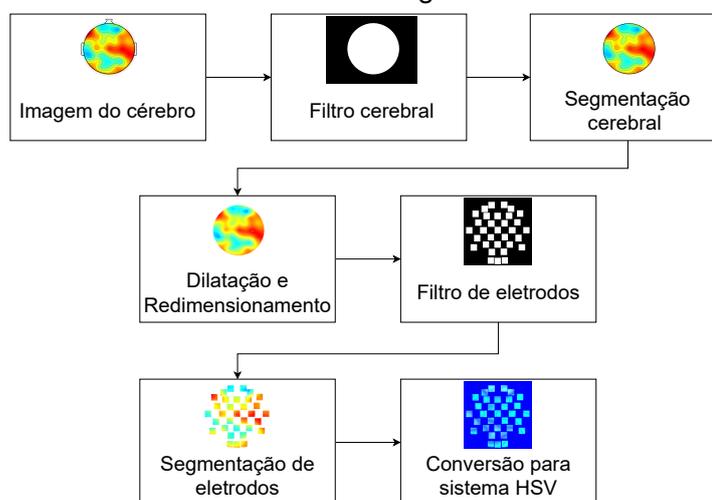
A Figura 13 apresenta o fluxo para a criação do filtro cerebral, compreendendo as seguintes etapas de PDI: conversão da imagem original para escala de cinza; aplicação de dilatação, com três iterações e *kernel* 3×3 , a fim de expandir a área do objeto ao redor dos píxeis, facilitando assim a subsequente segmentação; e, por fim,

utilização de limiarização binária invertida, resultando em um filtro no qual a área de interesse é representada por píxeis em branco, enquanto o restante é exibido em preto.

O processo de criação do filtro de eletrodos para segmentar os canais nas imagens topográficas cerebrais é detalhado na Figura 14. Para desenvolver este filtro, baseado em uma imagem que exibe os eletrodos dispostos no sistema internacional 10-20, utilizado na coleta dos dados do DEAP, aplicaram-se as seguintes técnicas de PDI: detecção das bordas de cada eletrodo com o uso do algoritmo *Canny Edge* e desfoque; aplicação de dilatação com uma iteração e *kernel* 9×9 , destinada a ampliar as áreas internas ao redor dos eletrodos; e, transformação das formas arredondadas em quadriláteros, com base nas informações de contorno, a fim de considerar informações adicionais das proximidades dos eletrodos. A escolha dos hiperparâmetros de ambos os filtros foi definida de forma heurística.

A Figura 15 ilustra o *pipeline* do pré-processamento realizado nas imagens geradas no EEGLAB, sendo utilizado a biblioteca *OpenCV*. Deste modo, o fluxo mostrado nesta Figura é realizado para cada uma das imagens do *dataset*, as quais têm dimensão de 875 de largura por 656 de altura cada. Além disto, estas imagens são representadas por um conjunto de píxeis no espaço de cores RGB.

Figura 15 – Pré-processamento do *dataset* de imagens.



Fonte: autoria própria.

Tendo em vista considerar apenas as informações relevantes, para cada imagem aplicou-se inicialmente um filtro cerebral circular que mantém as áreas de ativação cerebral, resultando em uma imagem segmentada. Em seguida, realizaram-se as operações de dilatação, com uma iteração e *kernel* 9×9 para remover linhas internas ao círculo representando o cérebro, e redimensionamento de imagem para 250×250 , mantendo as informações essenciais intactas. Posteriormente, aplicou-se um filtro de eletrodos sobre a imagem, como mencionado anteriormente, a fim de obter imagens

segmentadas por eletrodos.

Por fim, as imagens segmentadas do cérebro por eletrodo foram convertidas do espaço de cores RGB para o HSV. Após isto, os píxeis das imagens são descritos através das propriedades matiz, saturação e valor e não mais pela combinação das cores primárias. Esta conversão dispõe uma alternativa para representar as imagens coloridas de uma forma mais próxima à percepção e compreensão humana das cores.

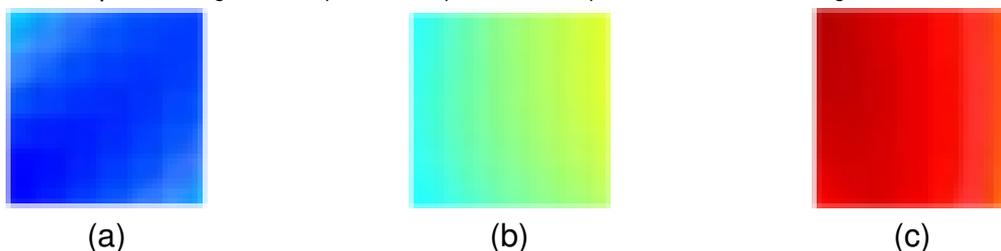
3.2 *Dataset* Estruturado

Na Seção anterior, foi apresentado um conjunto de imagens topográficas cerebrais pré-processadas, derivadas dos sinais de EEG do DEAP. Estas imagens foram segmentadas conforme os níveis de atividade cerebral e as áreas correspondentes aos eletrodos. A partir destas segmentações, possibilita-se construir um *dataset* estruturado que organiza o mapeamento destas informações.

Considerando que as cores das imagens geradas no EEGLAB correspondem aos níveis de atividade cerebral, conforme ilustrado na Figura 12, e os píxeis das imagens estão no espaço de cores HSV, pode-se estabelecer uma relação heurística entre as cores dos píxeis em níveis de atividade cerebral baixo, médio e alto.

Deste modo, para construção do *dataset* estruturado, mapearam-se os píxeis da seguinte maneira: i) píxeis de baixa atividade cerebral são identificados quando o matiz possui valores de 90 a 150 (cores frias); ii) píxeis de média atividade cerebral são reconhecidos quando o matiz tem valores de 30 a 90 (cores intermediárias); e, por fim, iii) píxeis de alta atividade cerebral são selecionados quando o matiz apresenta valores de 150 a 30 (cores quentes). Os limites para a saturação variam de 80 a 255, enquanto os limites para o valor variam de 40 a 255. A biblioteca *OpenCV* utiliza escalas para os canais HSV: 0 até 180 para matiz, e 0 até 255 para saturação e valor.

Figura 16 – Representação de a) baixo, b) médio e c) alto nível de ativação cerebral.



Fonte: autoria própria.

Ao categorizar os píxeis em diferentes níveis de atividade cerebral (baixo, médio e alto), com base na sua localização, pode-se determinar a porcentagem de píxeis associados a cada eletrodo em relação aos diferentes níveis de atividade cerebral. A Figura 16 ilustra as representações visuais para um experimento específico con-

siderando três eletrodos, sendo mostrado através da escala de cores que cada um apresenta 100% de nível de ativação cerebral baixo, médio e alto, respectivamente.

Há casos em que sobre um mesmo eletrodo existem representações de diferentes níveis de ativação cerebral. Por exemplo, supondo que existam 100 píxeis sobre um eletrodo e que 5 destes píxeis sejam de cores frias, 25 de cores intermediárias e 70 de cores quentes, pode-se interpretar que, respectivamente, 5% do eletrodo apresenta baixo nível de atividade cerebral, 25% apresenta nível médio e 70% apresenta alto nível de atividade cerebral. Assim, estes percentuais para cada eletrodo em diferentes níveis de atividade cerebral são obtidos através dos píxeis coloridos sobre a região de cada eletrodo nas imagens correspondentes aos segmentos de atividade do cérebro. A Tabela 4 ilustra o mapeamento estruturado da atividade percentual do cérebro para cinco eletrodos de um experimento de EEG.

Tabela 4 – Exemplo do mapeamento de atividade cerebral em formato estruturado.

Região do Cérebro	Nível de Atividade		
	Baixo	Médio	Alto
Frontal 3 (F3)	0%	49%	51%
Occipital 1 (O1)	0%	60%	40%
Parietal 8 (P8)	7%	93%	0%
Pré-Frontal 2 (Fp2)	100%	0%	0%
Temporal 7 (T7)	0%	100%	0%

Fonte: autoria própria.

A partir do mapeamento das intensidades cerebrais nos eletrodos, combinado com as informações sobre frequência e época utilizadas na geração das imagens brutas por meio do EEGLAB, e complementado pelos dados tabulares detalhados no DEAP, conforme exemplificado na Tabela 3, desenvolveu-se um *dataset* estruturado e unificado. Este conjunto de dados pode servir de base para diversos experimentos considerando vários cenários, os quais serão explorados posteriormente.

A Tabela 5 apresenta uma visão geral das entradas do *dataset* estruturado, por meio de uma linha do conjunto de dados construído, incluindo informações de identificação do sujeito e experimento, além de época e frequência de amostragem. Adicionalmente, incorporaram-se as autoavaliações dos sujeitos relacionadas a quatro escalas de emoção: dominância, excitação, preferência e valência.

Ainda representado por meio da Tabela 5, o *dataset* construído apresenta 32 colunas para cada um dos 32 canais de eletrodos relacionados à extração de sinais de EEG no DEAP, onde a entrada de cada uma destas colunas consiste em uma tupla que representa a porcentagem de ativação cerebral nos níveis baixo, médio e alto, respeitando esta ordem. Desta forma, o conjunto de dados completo consiste em 40 colunas e 238.080 registros, um para cada imagem de frequência 10, 22 e 42 Hz ge-

rada via EEGLAB. Caso cada um dos três elementos das tuplas seja mapeado para colunas individuais, o *dataset* passa a ser composto por 104 colunas. Cabe salientar que não foram incluídas neste *dataset* as frequências de 2 e 6 Hz, pois, conforme discutido na Seção 2.1, referem-se a estados mentais relacionados ao sono.

Tabela 5 – Exemplo de distribuição dos dados para uma linha do *dataset* estruturado.

Id	Sujeito	Experimento	Época	Frequência	Valência	Excitação	Dominância	Preferência
1	1	2	13	22	7,71	7,6	6,9	7,83

Id	OZ	O1	O2	PZ	P3	P4	P7	P8
1	(97,2 - 2,8 - 0)	(76,2 - 23,8 - 0)	(38,1 - 61,9 - 0)	(88,3 - 11,7 - 0)	(0 - 83,3 - 16,7)	(0 - 37,6 - 62,5)	(42,5 - 57,5 - 0)	(0 - 58,3 - 41,7)

Id	PO3	PO4	CP1	CP2	CP5	CP6	T7	T8
1	(99,5 - 0,5 - 0)	(39 - 61 - 0)	(0 - 89,8 - 10,2)	(0 - 94,5 - 5,5)	(97,9 - 2,1 - 0)	(0 - 0 - 100)	(40,6 - 51,2 - 8,2)	(0 - 0 - 100)

Id	FZ	F3	F4	F7	F8	CZ	C3	C4
1	(65,1 - 34,9 - 0)	(0 - 0,8 - 99,2)	(9,6 - 74,9 - 15,5)	(0 - 29,2 - 70,8)	(0 - 0,3 - 99,7)	(0 - 8,6 - 91,4)	(0 - 100 - 0)	(0 - 86,2 - 13,8)

Id	FC1	FC2	FC5	FC6	AF3	AF4	Fp1	Fp2
1	(0 - 79,5 - 20,5)	(86,6 - 13,4 - 0)	(48,2 - 51,7 - 0,1)	(0 - 89,9 - 10,1)	(0 - 0 - 100)	(0 - 54,9 - 45,1)	(0 - 31 - 69)	(0 - 100 - 0)

Fonte: autoria própria.

Neste contexto, o *dataset* estruturado construído provê um novo formato para análise de dados de EEG. Deste modo, pode-se realizar experimentos específicos a este formato alternativo, diferente dos dados brutos e de formato de imagem, os quais têm como pontos negativos a interpretabilidade dos dados e a necessidade de grande capacidade de armazenamento e processamento, especialmente neste último formato.

3.3 Preditores de Emoções

Os sinais de EEG foram divididos em segmentos correspondentes ao mapeamento de cada eletrodo, conforme detalhado na Seção 3.2 durante a explicação da construção do *dataset* estruturado. Cada eletrodo pode desempenhar um papel significativo no reconhecimento de emoções, uma vez que contém informações sobre os níveis percentuais de ativação, categorizados como baixo, médio e alto. Portanto, é possível estimar os níveis de emoção com base na intensidade da ativação cerebral, oferecendo percepções sobre as emoções por meio de dimensões.

Assim, com base no *dataset* estruturado exemplificado na Tabela 5, definiu-se a tarefa de criar modelos para prever quatro dimensões emocionais: dominância, excitação, preferência e valência. Considerando a possibilidade de explorar a importância das regiões cerebrais para predição de modelos, criaram-se 15 combinações entre regiões do cérebro a partir do mapeamento dos eletrodos durante o EEG.

A Tabela 6 apresenta a relação dos *datasets* utilizados durante os experimentos, contendo os eletrodos incluídos em cada configuração, além da quantidade total de atributos. Por exemplo, a região Temporal é composta pelos eletrodos com prefixo T, sendo T7 e T8, totalizando dois atributos. Assim, a partir da Tabela 6, pode-se observar que são gerados modelos baseados em no máximo 32 atributos/eletrodos, sendo cada eletrodo composto por uma tupla referente aos níveis percentuais de ativação cerebral baixo, médio e alto.

Tabela 6 – Configuração do *dataset* quanto aos atributos.

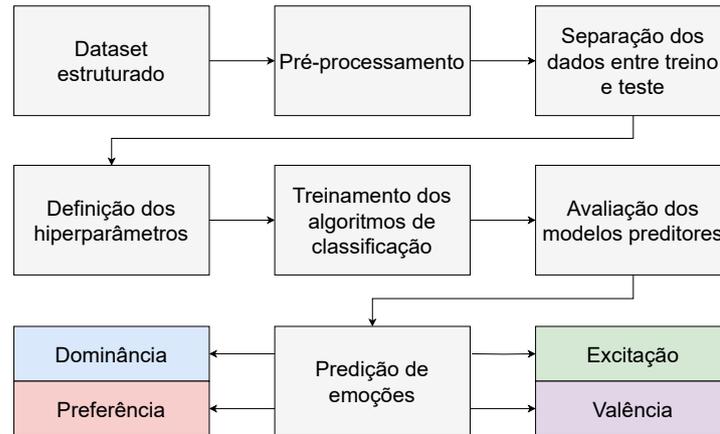
Dataset	Atributos	Total
All	AF3, AF4, CZ, C3, C4, CP1, CP2, CP5, CP6, FZ, F3, F4, F7, F8, FC1, FC2, FC5, FC6, Fp1, Fp2, PZ, P3, P4, P7, P8, PO3, PO4, OZ, O1, O2, T7, T8	32
AF	AF3, AF4	2
C	CZ, C3, C4	3
CP	CP1, CP2, CP5, CP6	4
F	FZ, F3, F4, F7, F8	5
FC	FC1, FC2, FC5, FC6	4
Fp	Fp1, Fp2	2
F+FC	FZ, F3, F4, FC1, FC2, FC5, FC6	9
Fp+AF	Fp1, Fp2, AF3, AF4	4
P	PZ, P3, P4, P7, P8	5
PO	PO3, PO4	2
P+CP	PZ, P3, P4, P7, P8, CP1, CP2, CP5, CP6	9
O	OZ, O1, O2	3
O+PO	OZ, O1, O2, PO3, PO4	5
T	T7, T8	2

Fonte: autoria própria.

A construção dos modelos seguiu o fluxo descrito em um diagrama, contendo as etapas a serem executadas, conforme mostra a Figura 17. A seguir, serão especificadas as etapas de pré-processamento dos dados tabulares para os alvos excitação, valência, dominância e preferência. Conforme apresentado anteriormente, os alvos estão em um formato de valores contínuos. Portanto, para viabilizar o treinamento de modelos, optou-se por transformar os alvos para um formato binário, permitindo que os modelos realizem previsões sob a perspectiva baixa (0) ou alta (1).

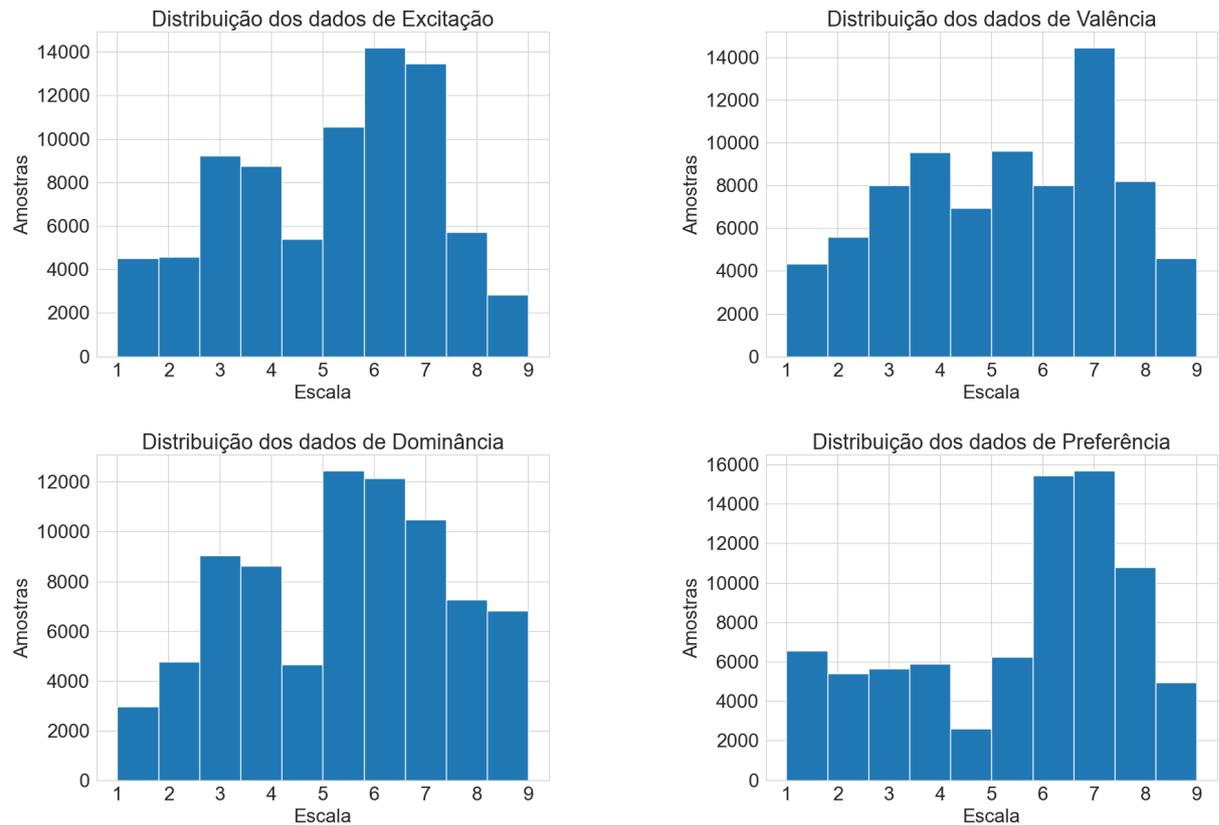
A Figura 18 fornece uma visão da distribuição dos dados por alvo. Esta distribuição é baseada nas autoavaliações dos participantes enquanto assistiam aos vídeos, com valores entre de 1 a 9. Neste contexto, o valor ideal para dividir as dimensões emocionais e transformá-las em classes deveria ser 5, representando a média na escala de avaliação.

Figura 17 – Diagrama com as etapas da construção dos modelos preditores de emoção.



Fonte: autoria própria.

Figura 18 – Distribuição dos dados referente aos alvos dos modelos.



Fonte: autoria própria.

No entanto, ao checar a mediana de cada dimensão emocional, verificou-se a necessidade de realizar uma operação para balancear os dados. Esta operação envolveu a definição de limiares específicos para cada dimensão, sendo 5,25 para excitação, 5,04 para valência, 5,235 para dominância e 6,05 para preferência, a fim de

utilizar o maior número de registros possível.

Adicionalmente, uma remoção aleatória de registros foi aplicada, a fim de corrigir desequilíbrios nas dimensões de valência e preferência. Para os dados de valência foram removidos 124 registros e no caso de preferência foram removidos 248. Tendo em vista a ausência de dados, os experimentos 12 e 24 do sujeito 11 não foram considerados na construção dos modelos. Desta forma, após o balanceamento, valores contínuos menores ou iguais ao limiar de cada classe foram convertidos em “0”, enquanto valores maiores que o limiar foram transformados em “1”. Este processo viabilizou a representação das dimensões emocionais por meio de classes binárias balanceadas.

Além de avaliar a variação de frequência em *Alpha*, *Beta* e *Gama*, e aspectos espaciais, conforme mostrado na Tabela 6, é possível explorar aspectos temporais por meio dos sinais de EEG. Para isto, foram consideradas janelas temporais de 1, 4, 10 e 20 segundos, sendo utilizado 50% de sobreposição para as janelas maiores que 1 segundo.

Com os dados devidamente ajustados, o próximo passo consistiu na divisão estratificada destes dados entre conjuntos de treinamento e teste. Neste processo, 80% dos dados foram alocados para o conjunto de treino, utilizados durante o processamento dos algoritmos de classificação, enquanto os 20% restantes foram alocados ao conjunto de teste, destinados para avaliar o desempenho dos modelos construídos.

Tabela 7 – Divisão dos dados entre treino e teste para cada tipo de configuração do *dataset*.

Dimensão	Configuração do <i>dataset</i>							
	1 segundo		4 segundos		10 segundos		20 segundos	
	Treino	Teste	Treino	Teste	Treino	Teste	Treino	Teste
Excitação	63.388	15.848	30.672	7.668	12.268	3.068	6.134	1.534
Valência	63.290	15.822	30.624	7.656	12.250	3.062	6.124	1.532
Dominância	63.388	15.848	30.672	7.668	12.268	3.068	6.134	1.534
Preferência	63.190	15.798	30.576	7.644	12.230	3.058	6.116	1.528

Fonte: autoria própria.

A Tabela 7 mostra as quantidades de registros para treino e teste para cada dimensão considerada neste trabalho e para cada tipo de configuração referente às janelas temporais.

Para a criação do sistema preditor de emoções, três algoritmos de classificação foram treinados e avaliados usando o *dataset* construído. Estes algoritmos – *K-Nearest Neighbors*², *Support Vector Machine*³ e *Random Forest*⁴ – estão no contexto do apren-

²<https://scikit-learn.org/stable/modules/generated/sklearn.neighbors.KNeighborsClassifier.html>

³<https://scikit-learn.org/stable/modules/generated/sklearn.svm.SVC.html>

⁴<https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html>

dizado supervisionado, conforme discutido na Seção 2.3. Portanto, pode ser criado um padrão para que novas entradas possam ser preditas corretamente.

Os hiperparâmetros dos algoritmos de AM foram determinados por meio de experimentos utilizando a técnica de *Grid Search* (Lavalle; Branicky; Lindemann, 2004). Esta técnica é utilizada para identificar a melhor combinação de hiperparâmetros para um determinado modelo. Para cada combinação de hiperparâmetros, a busca em grade realiza um processo de validação cruzada, um procedimento que envolve a divisão dos dados em subconjuntos de treinamento e teste em múltiplas iterações, a fim de avaliar a capacidade de generalização de modelos. Além disso, a busca em grade registra o desempenho de cada modelo para todas as combinações de hiperparâmetros, utilizando métricas específicas para determinar a configuração que produz os melhores resultados (Geron, 2019).

Tabela 8 – Conjunto de hiperparâmetros de entrada.

Algoritmo	Hiperparâmetros
<i>K-Nearest Neighbors</i>	{'n_neighbors': [1, 3, 5, 7, 9]}
<i>Random Forest</i>	{'n_estimators': [100, 200], 'max_depth': [10, None]}
<i>Support Vector Machine</i>	{'C': [0,1, 1, 2]}

Fonte: autoria própria.

A Tabela 8 detalha os conjuntos de hiperparâmetros de entrada testados com a aplicação de técnica de busca em grade, para cada um dos algoritmos do contexto deste trabalho. Destacam-se os hiperparâmetros referentes ao número de vizinhos mais próximos a serem considerados (*n_neighbors*) para o K-NN, número de estimadores (*n_estimators*) e a profundidade máxima (*max_depth*) de árvores para o RF, e a constante de regularização (*C*) para o SVM RBF. Os demais hiperparâmetros estão conforme o padrão da biblioteca *Scikit-Learn* (Pedregosa et al., 2011).

Durante estes experimentos, foram empregados os dados de treinamento previamente separados. O método de validação cruzada utilizada na busca em grade considerou a divisão dos dados em 5 grupos distintos, com 5 iterações. Isto significa que, a cada iteração, um dos grupos é utilizado como conjunto de validação, enquanto os demais são utilizados como conjunto de treinamento. O critério escolhido para determinar o melhor desempenho entre as diferentes configurações de hiperparâmetros foi o *F1-Score*, tendo em vista sua boa aplicabilidade para criar *rankings*. Em geral, os modelos com melhores desempenhos foram baseadas nos hiperparâmetros em negrito mostrados na Tabela 8.

É importante destacar que o pré-processamento foi realizado utilizando a biblioteca *Pandas* (Mckinney et al., 2010) e o treinamento e avaliação dos modelos preditores foi realizado com a biblioteca *Scikit-Learn* (Pedregosa et al., 2011). Considerando a execução da busca em grade para cada experimento, torna-se possível identificar a

combinação de hiperparâmetros mais eficaz, a qual pode resultar na construção de modelos mais eficientes para a tarefa em questão.

Neste contexto, geraram-se pelo menos 540 modelos por alvo, considerando três bandas de frequências (*Alpha*, *Beta* e *Gama*), 15 combinações de regiões do cérebro (Tabela 6), quatro configurações de janela temporal (Tabela 7) e três algoritmos de aprendizado de máquina (Tabela 8).

4 RESULTADOS E DISCUSSÕES

Neste Capítulo são apresentados os resultados deste estudo. Deste modo, são discutidos os resultados dos modelos construídos para predição de emoção, para as dimensões emocionais de excitação, valência, dominância e preferência. A avaliação de desempenho dos modelos preditivos tem como base quatro métricas apresentadas na Seção 2.3.4: acurácia, precisão, sensibilidade e *F1-Score*. De modo geral, valores mais elevados indicam resultados superiores.

Todas as informações detalhadas, incluindo os resultados completos das métricas de avaliação, matrizes de confusão e hiperparâmetros utilizados na construção dos modelos preditivos, estão disponíveis no seguinte repositório¹. Tendo em vista realizar uma análise específica sobre as intensidades cerebrais de eletrodos por regiões e o uso de janelas temporais, foram considerados três cenários com base no *dataset* estruturado construído:

Cenário 1: Considerando informações sobre todos os 32 eletrodos.

Cenário 2: Considerando dados de eletrodos agrupados por regiões específicas do córtex cerebral.

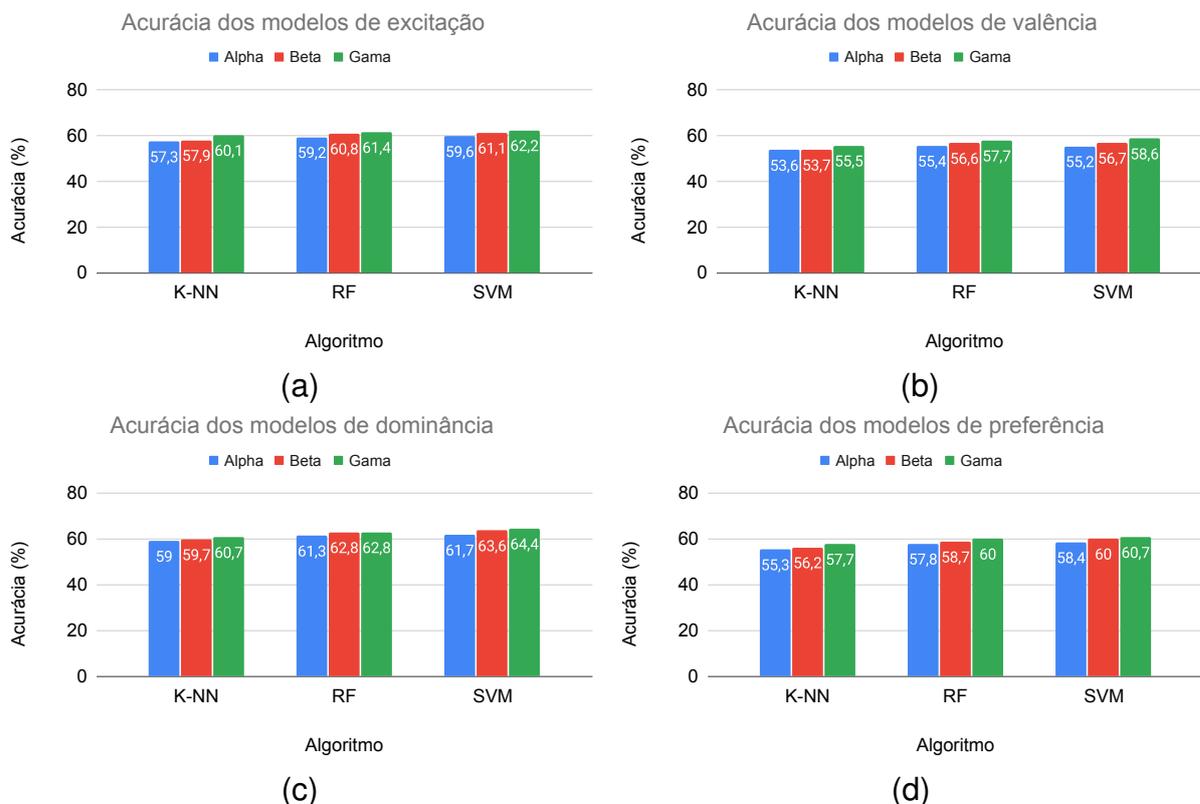
Cenário 3: Considerando registros combinados por janela temporal.

4.1 Cenário 1

Esta Seção aborda os resultados dos modelos de classificação desenvolvidos para prever o nível de emoção nas perspectivas baixa e alta para as dimensões excitação, valência, dominância e preferência. Neste Cenário 1, considera-se o *dataset* estruturado construído, composto de informações mapeadas das imagens segmentadas por eletrodos, considerando os níveis de ativação cerebral dos 32 eletrodos.

¹<https://github.com/brunocascaes/EEG-Emotion-Recognition>

Figura 19 – Cenário 1: Acurácia dos modelos para a) excitação, b) valência, c) dominância e d) preferência.



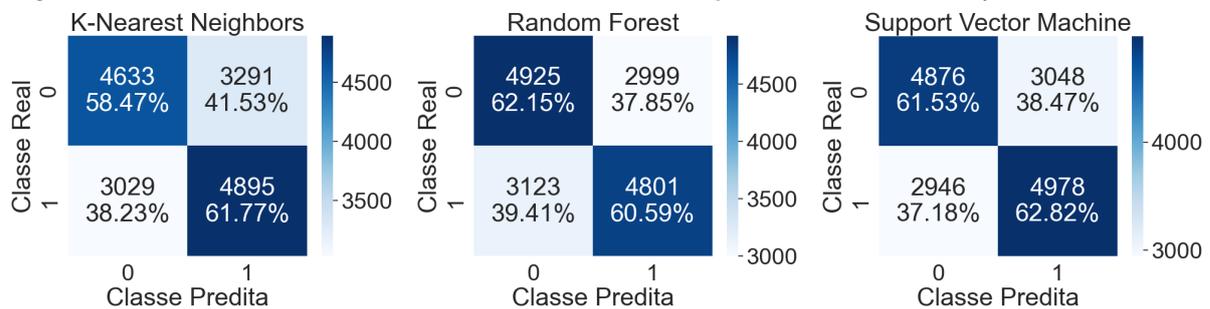
Fonte: autoria própria.

A Figura 19 exibe os gráficos contendo as comparações de desempenho, em termos de acurácia percentual, para os algoritmos K-NN, RF e SVM nas bandas de frequência de *Alpha*, *Beta* e *Gama*, para cada uma das quatro dimensões emocionais analisadas neste estudo. Ao observar os gráficos, verifica-se que, apesar de que os resultados sejam próximos, o aumento da frequência dos dados de EEG está associado a melhoria na acurácia. Deste modo, os resultados obtidos com frequência *Gama* superam os demais. Em relação aos algoritmos aplicados, percebe-se que, de forma geral, o algoritmo SVM apresentou melhores resultados, seguido pelo RF e K-NN. Destaca-se uma única exceção para dimensão de valência, na frequência *Alpha*, onde o algoritmo RF demonstrou um desempenho superior ao SVM.

As Figuras 20, 21, 22 e 23 proporcionam visões mais detalhadas sobre os desempenhos dos modelos por meio dos acertos e erros em cada classe, na banda de frequência *Gama*, para as dimensões emocionais de excitação, valência, dominância e preferência, respectivamente. As matrizes de confusão para as bandas de frequência *Alpha* e *Beta* podem ser visualizadas no Apêndice B.

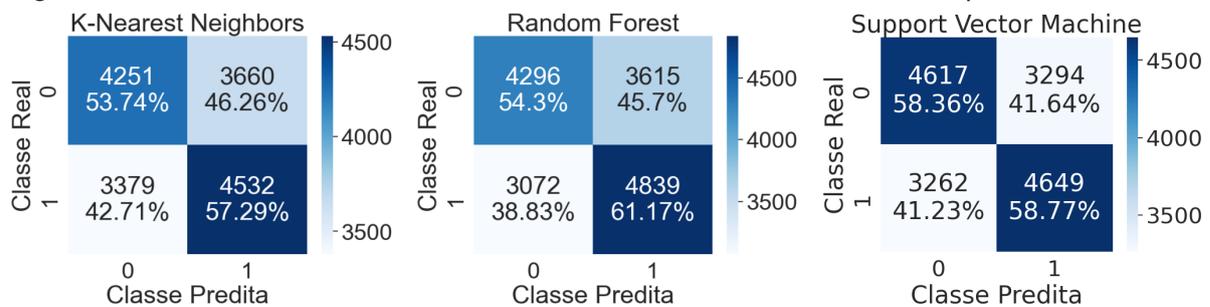
Ao analisar as matrizes de confusão de excitação, na banda de frequência *Gama*, observa-se mais acertos para classe baixa, representada pelo “0”, com o RF e uma maior facilidade em acertar registros do tipo alta, representada pelo “1”, com os demais algoritmos. Entretanto, para a dimensão de preferência, a tendência é oposta. No caso da valência, destaca-se uma maior dificuldade em acertar valores do tipo “0” em todas as situações. Já para dominância, percebe-se uma maior complexidade em acertar valores do tipo “1”. Em geral, não há uma diferença significativa entre as classificações corretas das classes “0” e “1”, exceto nos modelos construídos por K-NN e RF para a dimensão de valência.

Figura 20 – Cenário 1: Matrizes de confusão de excitação na banda de frequência *Gama*.



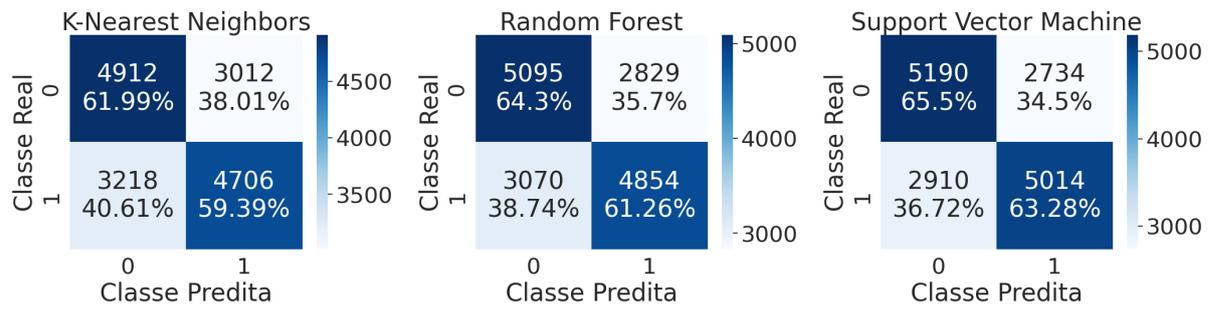
Fonte: autoria própria.

Figura 21 – Cenário 1: Matrizes de confusão de valência na banda de frequência *Gama*.

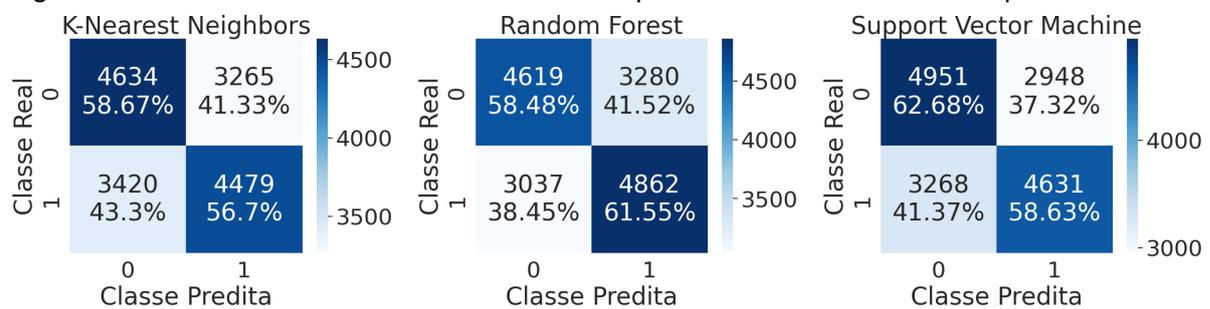


Fonte: autoria própria.

A Tabela 9 apresenta de maneira sumarizada os resultados das métricas de avaliação do Cenário 1, onde são destacados o melhor e pior caso de cada dimensão emocional. Conforme discutido anteriormente, o algoritmo SVM demonstrou ser a opção mais eficaz entre os algoritmos considerados para prever emoções, especialmente em *Gama*. O hiperparâmetro associado a este contexto de melhor caso é o valor 1 para constante de regularização. Por outro lado, os resultados menos favoráveis foram obtidos com K-NN, na frequência mais baixa analisada neste estudo.

Figura 22 – Cenário 1: Matrizes de confusão de dominância na banda de frequência *Gama*.

Fonte: autoria própria.

Figura 23 – Cenário 1: Matrizes de confusão de preferência na banda de frequência *Gama*.

Fonte: autoria própria.

Tabela 9 – Cenário 1: Avaliação dos modelos preditores para melhor e pior caso.

Modelo	Algoritmo	Frequência	Precisão (%)		Sensibilidade (%)		F1-Score (%)		Acurácia (%)
			Classe 0	Classe 1	Classe 0	Classe 1	Classe 0	Classe 1	
<i>Melhor caso</i>									
Excitação	SVM	<i>Gama</i>	62,34	62,02	61,53	62,82	61,93	62,42	62,18
Valência	SVM	<i>Gama</i>	58,6	58,53	58,36	58,77	58,48	58,65	58,56
Dominância	SVM	<i>Gama</i>	64,07	64,71	65,5	63,28	64,78	63,99	64,39
Preferência	SVM	<i>Gama</i>	60,24	61,1	62,68	58,63	61,43	59,84	60,65
<i>Pior caso</i>									
Excitação	K-NN	<i>Alpha</i>	57,47	57,17	56,31	58,33	56,88	57,75	57,32
Valência	K-NN	<i>Alpha</i>	53,61	53,49	52,72	54,38	53,16	53,93	53,55
Dominância	K-NN	<i>Alpha</i>	59,01	58,95	59,07	59,36	58,66	59,15	58,87
Preferência	K-NN	<i>Alpha</i>	55,26	55,13	55,4	56,56	53,96	55,84	54,67

Fonte: autoria própria.

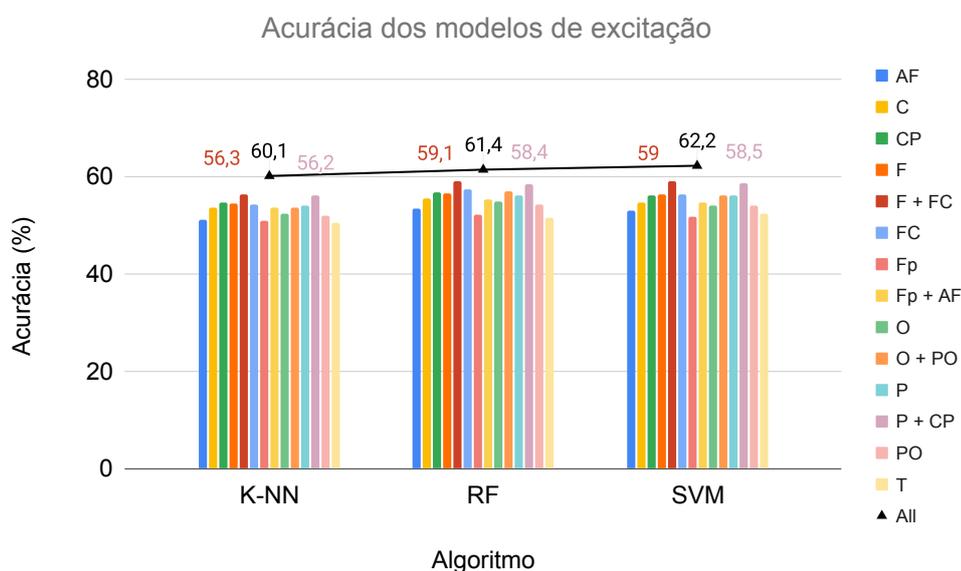
Por fim, ainda a partir da Tabela 9, observa-se que, de forma geral, para os melhores casos, os valores de precisão, sensibilidade e F1-score exibem resultados semelhantes ao analisar as classes “0” e “1”, sem uma preferência muito aparente por uma das classes. Os valores de acurácia, método frequentemente abordado na literatura, para todos os modelos construídos neste estudo estão detalhados por dimensão emocional no Apêndice A. No caso deste Cenário 1, em que todos os 32 eletrodos são considerados, a coluna a ser observada é a de nome *All*, considerando janela temporal de 1 segundo.

4.2 Cenário 2

Esta Seção aborda os resultados dos modelos desenvolvidos para realizar a previsão do nível de emoção nas perspectivas baixa e alta para as dimensões excitação, valência, dominância e preferência. Neste Cenário 2, considera-se o *dataset* estruturado construído, composto de informações mapeadas das imagens segmentadas por grupos de eletrodos referentes às regiões do cérebro. As variações utilizadas quanto aos atributos são as mesmas apresentadas na Tabela 6.

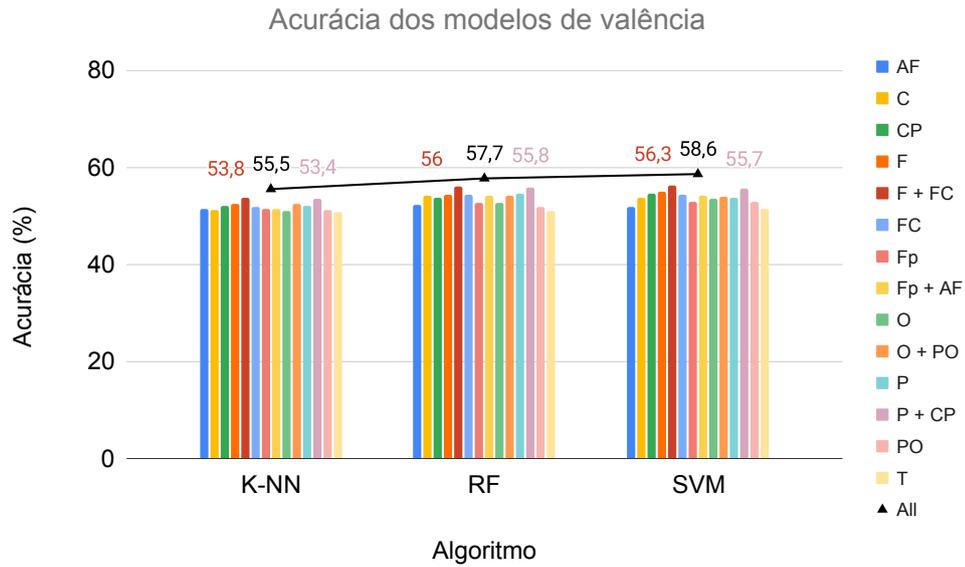
As Figuras 24, 25, 26 e 27 apresentam comparação da acurácia percentual para combinações de regiões cerebrais para excitação, valência, dominância e preferência, respectivamente. Ainda, nestas imagens, os símbolos sobre a linha preta destacam valores obtidos no Cenário 1, onde foram considerados todos (All) os eletrodos.

Figura 24 – Cenário 2: Acurácia dos modelos de excitação na banda de frequência *Gama*.

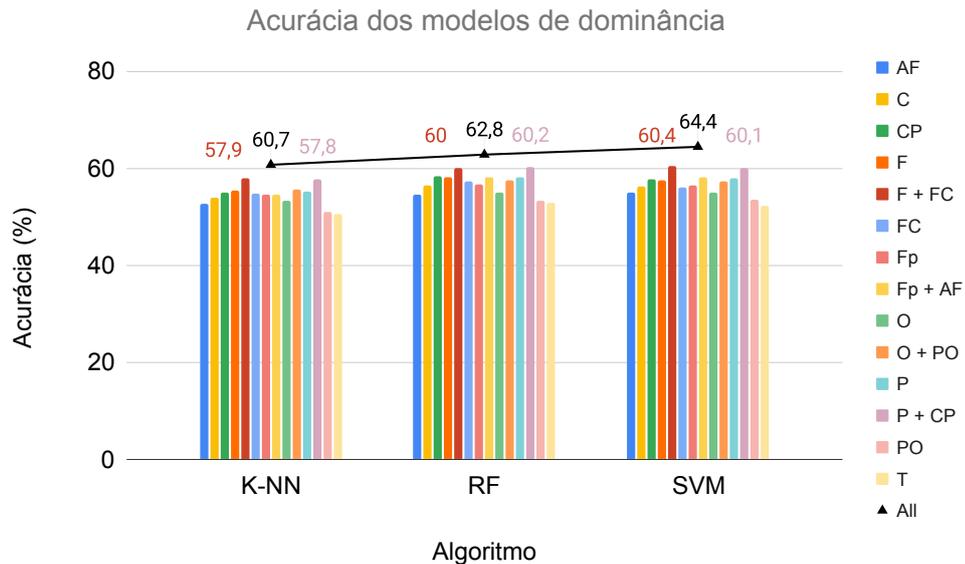


Fonte: autoria própria.

Através destes gráficos, percebe-se que, para todas as dimensões, não houve melhora de desempenho em termos de acurácia ao utilizar eletrodos referentes a regiões específicas do cérebro comparado ao uso de informações de todos os 32 eletrodos disponíveis (Cenário 1). No entanto, destaca-se de maneira positiva a combinação de regiões, como a zona frontal associada a zona intermediária frontal/central, representada nos gráficos por meio de F + FC, e da zona parietal associada a zona intermediária parietal/central, representada nos gráficos por meio de P + CP.

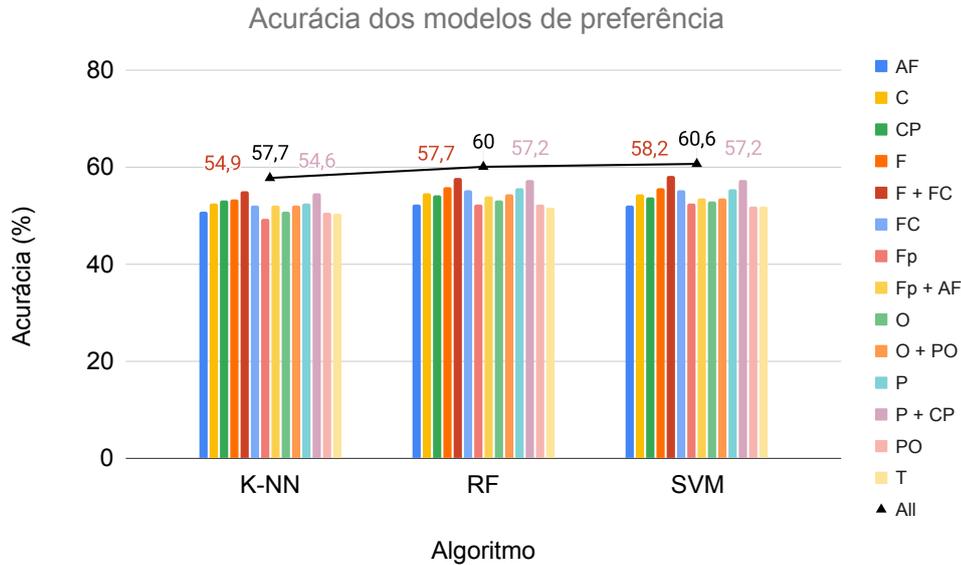
Figura 25 – Cenário 2: Acurácia dos modelos de valência na banda de frequência *Gama*.

Fonte: autoria própria.

Figura 26 – Cenário 2: Acurácia dos modelos de dominância na banda de frequência *Gama*.

Fonte: autoria própria.

Ao analisar estes gráficos na banda de frequência *Gama*, nota-se como destaques negativos tendo em vista menores acurácias os *datasets* compostos pela zona temporal T e F_p para a dimensão de excitação, T e zona intermediária Parietal/Ocipital PO para as demais dimensões. Uma explicação possível para essa ocorrência é que estas regiões possuem menos eletrodos, o que está alinhado com a informação de que os resultados foram melhores quando todos os 32 eletrodos foram utilizados.

Figura 27 – Cenário 2: Acurácia dos modelos de preferência na banda de frequência *Gama*.

Fonte: autoria própria.

A Tabela 10 sumariza os resultados das métricas de avaliação no Cenário 2, destacando o melhor e pior caso para cada dimensão. Em acordo com os gráficos apresentados anteriormente, observa-se que o algoritmo SVM mostrou-se eficaz para as dimensões de valência e preferência, na banda de frequência *Gama*. Por sua vez, o RF mostrou-se eficaz para excitação e dominância, nas bandas de frequência *Gama* e *Beta*, respectivamente. Vale ressaltar os hiperparâmetros dos melhores casos: 200 para número de árvores e 10 para a profundidade máxima no RF, e 1 e 2 para constante de regularização do SVM para valência e preferência, respectivamente. Os piores resultados, em geral, foram associados aos modelos gerados por K-NN na banda com frequências mais baixas, de *Alpha*.

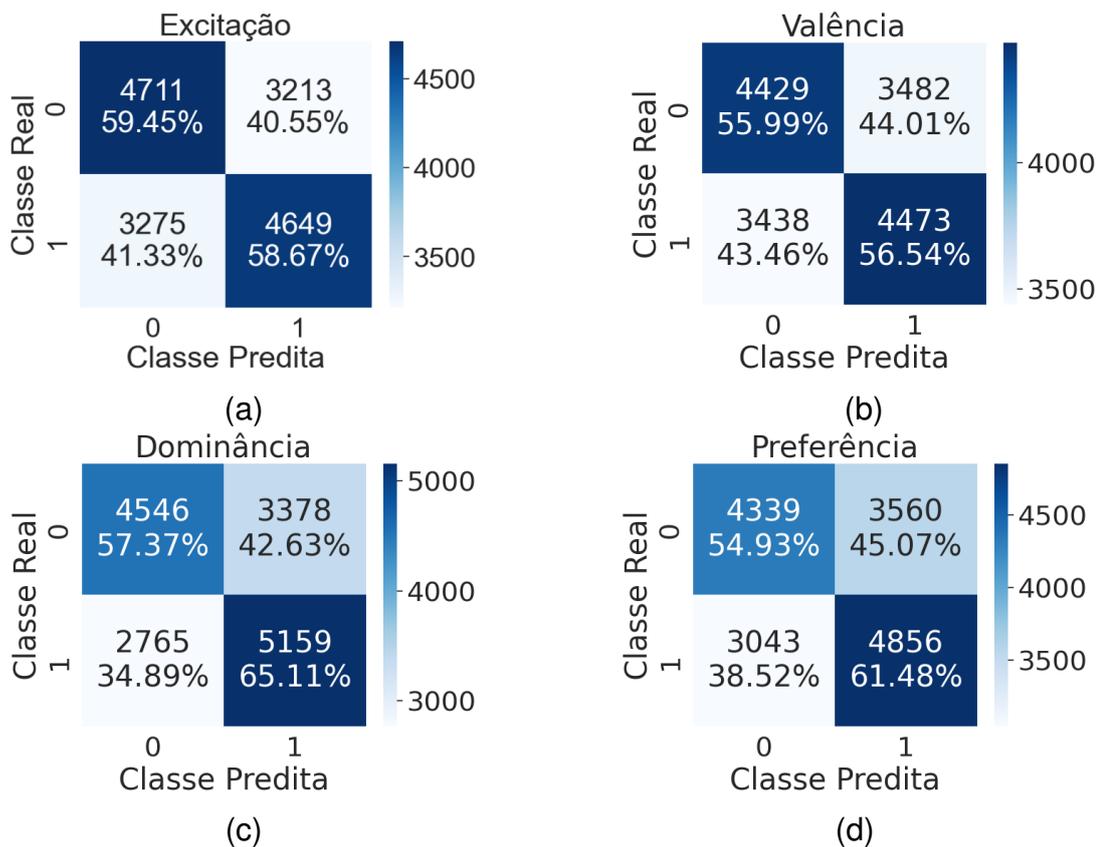
Tabela 10 – Cenário 2: Avaliação dos modelos preditores para melhor e pior caso.

Dimensão	Algoritmo	Frequência	Região	Precisão (%)		Sensibilidade (%)		F1-Score (%)		Acurácia (%)
				Classe 0	Classe 1	Classe 0	Classe 1	Classe 0	Classe 1	
<i>Melhor caso</i>										
Excitação	RF	<i>Gama</i>	F + FC	58,99	59,13	59,45	58,67	59,22	58,9	59,06
Valência	SVM	<i>Gama</i>	F + FC	56,3	56,23	55,99	56,54	56,14	56,38	56,26
Dominância	RF	<i>Beta</i>	P + CP	62,18	60,43	57,37	65,11	59,68	62,68	61,24
Preferência	SVM	<i>Gama</i>	F + FC	58,78	57,7	54,93	61,48	56,79	59,53	58,2
<i>Pior caso</i>										
Excitação	K-NN	<i>Alpha</i>	Fp	49,82	49,84	47,73	51,93	48,75	50,86	49,83
Valência	RF	<i>Alpha</i>	T	49,92	49,93	46,38	53,47	48,08	51,64	49,92
Dominância	K-NN	<i>Alpha</i>	Fp	48,47	48,63	45,77	51,34	47,08	49,95	48,56
Preferência	K-NN	<i>Gama</i>	Fp	49,16	49,26	46,04	52,37	47,55	50,77	49,21

Fonte: autoria própria.

De forma geral, os modelos construídos com sinais da frequência *Alpha* não geraram bons resultados, assim como no Cenário 1. Cabe lembrar que, conforme discutido na Seção 2.1, as frequências da banda *Alpha*, a qual a frequência 10 Hz está inclusa, refere-se ao estado mental de relaxamento. Por outro lado, as bandas de frequência *Beta* e *Gama* produziram resultados similares, apesar de baixos, com leve vantagem geral para frequência mais superior. Vale salientar que dentre as dimensões analisadas neste estudo, a valência apresentou menor diferença entre resultados por região comparado ao uso de todos eletrodos. Os valores de acurácia dos demais modelos gerados neste Cenário 2 encontram-se detalhados por dimensão emocional no Apêndice A. No caso deste Cenário, deve-se considerar a janela temporal de 1 segundo.

Figura 28 – Cenário 2: Matrizes de confusão, nos melhores casos, para: a) excitação com RF na banda de frequência *Gama* sobre a região F + FC; b) valência com SVM na banda de frequência *Gama* sobre a região F + FC; c) dominância com RF na banda de frequência *Beta* sobre a região P + CP; e, d) preferência com SVM na banda de frequência *Gama* sobre a região F + FC.



Fonte: autoria própria.

Por fim, as matrizes de confusão da Figura 28 ilustram a avaliação de desempenho dos melhores modelos gerados para excitação, valência, dominância e preferência. Ao observar as Figuras 28(a) e 28(b), verifica-se que existe um valor próximo de acertos para ambas as classes, sem uma preferência muito aparente. Já ao analisar as Figu-

ras 28(c) e 28(d), percebe-se que as dimensões de dominância e preferência, neste cenário, têm uma maior dificuldade em acertar valores pertencentes a classe “0”.

Neste contexto, observa-se que a segmentação por regiões de eletrodos, comparado ao uso de todos os eletrodos, não melhorou o desempenho dos modelos de aprendizado de máquina para predição de emoções por meio de dimensões.

4.3 Cenário 3

Esta Seção aborda os resultados dos modelos construídos para prever o nível de emoção nas dimensões de excitação, valência, dominância e preferência. Neste terceiro e último cenário, analisa-se o *dataset* estruturado considerando combinações relacionadas ao uso de janelas temporais e sobreposição de sinais. Além da discussão geral, serão apresentados os gráficos e matrizes de confusão na frequência de 42 Hz (*Gama*), tendo em vista que os modelos construídos utilizando esta frequência produziram os melhores resultados.

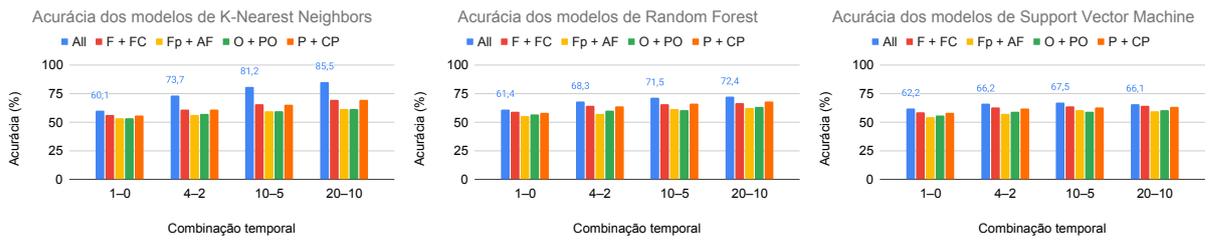
As variações do formato do *dataset* são as mesmas apresentadas na Tabela 7. Nos Cenários 1 e 2 foram utilizadas janelas temporais de 1 segundo sem sobreposição, sendo esta representada por 1–0. No caso do Cenário 3, são realizados experimentos com as janelas temporais de tamanho 4, 10 e 20, com 50% de sobreposição, sendo estas representadas por 4–2, 10–5, 20–10, respectivamente. Estas combinações de janela e deslocamento temporal são aplicadas diretamente aos dados do *dataset* estruturado por meio do uso da média. Por exemplo, ao considerar uma janela temporal de 4 segundos com um deslocamento de 50%, os níveis de ativação por região cerebral são combinados da seguinte forma: os atributos preditivos entre 0 e 4 segundos são combinados em um único registro, os registros entre 2 e 4 segundos em outro, entre 4 e 8 segundos em outro e, assim por diante.

As Figuras 29, 30, 31 e 32 apresentam gráficos comparativos dos resultados de acurácia para as dimensões de excitação, valência, dominância e preferência, respectivamente. Nestes gráficos estão indicados três tipos de janela temporal com sobreposição de sinal, além da janela de 1 segundo utilizada em outros cenários para fins de comparação. Além disto, estão indicados gráficos para os três algoritmos utilizados neste estudo. Estes gráficos destacam apenas as combinações entre regiões de eletrodos que apresentam os melhores desempenhos, incluindo o uso da região composta por todos os 32 eletrodos. Cabe lembrar que o marcador *All* refere-se aos experimentos com o uso de todos os 32 eletrodos.

Ao analisar estes gráficos, em geral, observa-se uma melhora significativa na acurácia dos modelos, já ao utilizar a combinação de janela temporal com sobreposição de 4–2, especialmente com o uso do K-NN. Deste modo, destacam-se as acurácias percentuais, na frequência *Gama* com este algoritmo, de 73,7% para excitação, 71,5%

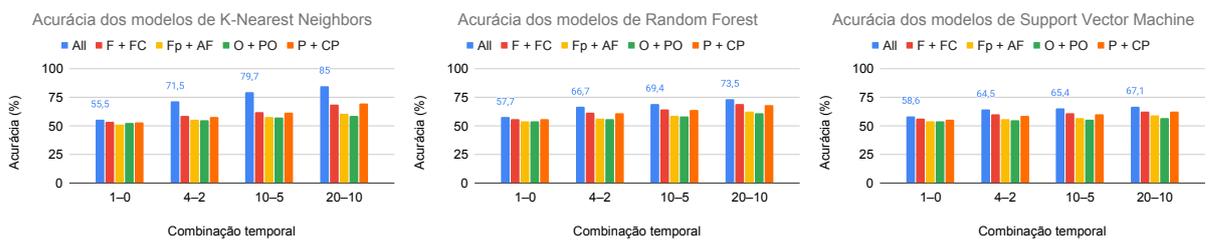
para valência, 74,7% para dominância e 72,7% para preferência. Isto indica que ao permitir uma transição mais suave entre os segmentos de imagens, houve uma melhora no desempenho. Considerando que o K-NN baseia-se na busca por registros semelhantes para realizar previsões, o algoritmo se beneficia do processo de suavização de segmentos. Para as combinações de 10–5 e 20–10, observa-se uma melhora de desempenho para K-NN e RF, enquanto o desempenho de SVM permanece praticamente inalterado comparado a combinação 4–2.

Figura 29 – Cenário 3: Acurácia dos modelos de excitação na banda de frequência *Gama*.



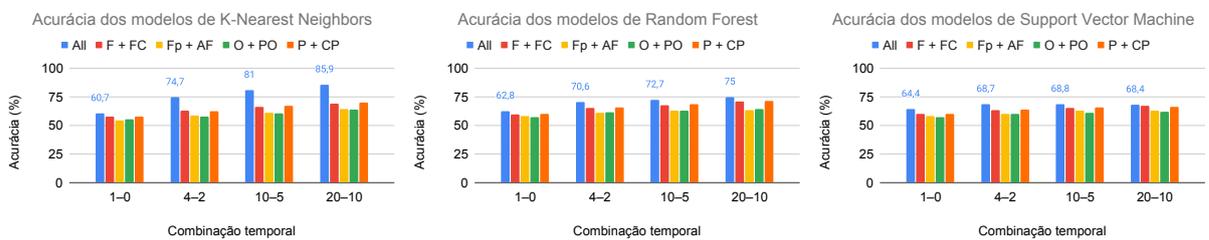
Fonte: autoria própria.

Figura 30 – Cenário 3: Acurácia dos modelos de valência na banda de frequência *Gama*.



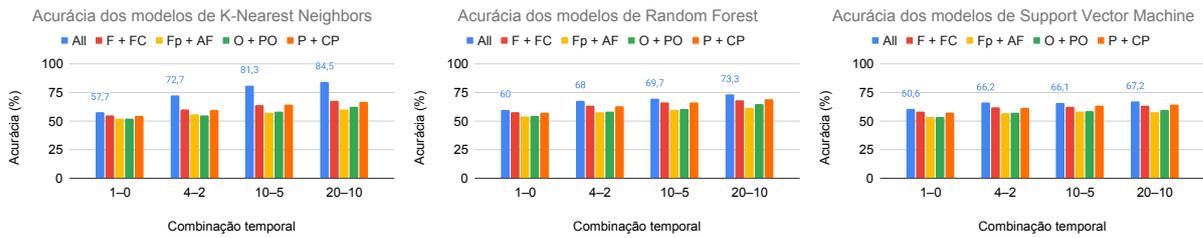
Fonte: autoria própria.

Figura 31 – Cenário 3: Acurácia dos modelos de dominância na banda de frequência *Gama*.



Fonte: autoria própria.

Figura 32 – Cenário 3: Acurácia dos modelos de preferência na banda de frequência *Gama*.

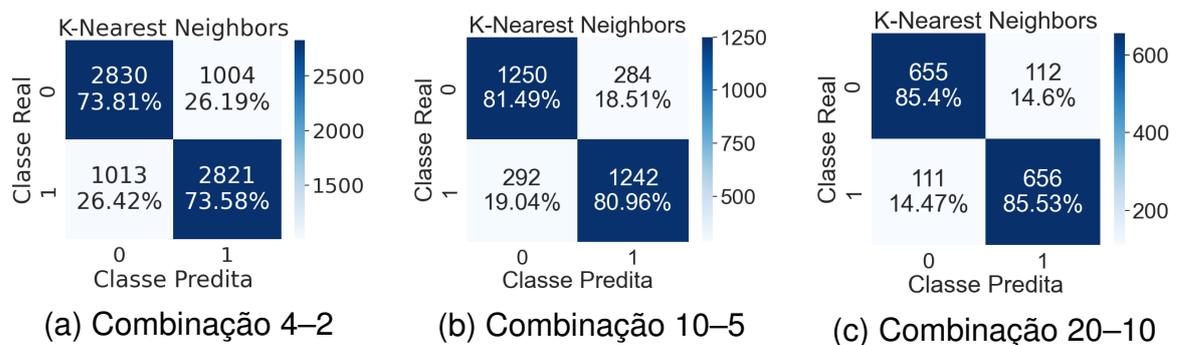


Fonte: autoria própria.

Em todos os casos mostrados nos gráficos, os modelos apresentaram melhor desempenho quando todos os eletrodos foram utilizados. Apesar disto, merecem destaque os modelos compostos pelas combinações F + FC e P + CP, os quais também registraram melhora de desempenho. Ao verificar o número de atributos, percebe-se que as configurações com maior quantidade de eletrodos obtiveram melhores resultados. Especificamente, no que diz respeito à região frontal do córtex cerebral, destaca-se que está consoante à literatura, uma vez que esta região está associada à regulação emocional, conforme discutido na Seção 2.1.

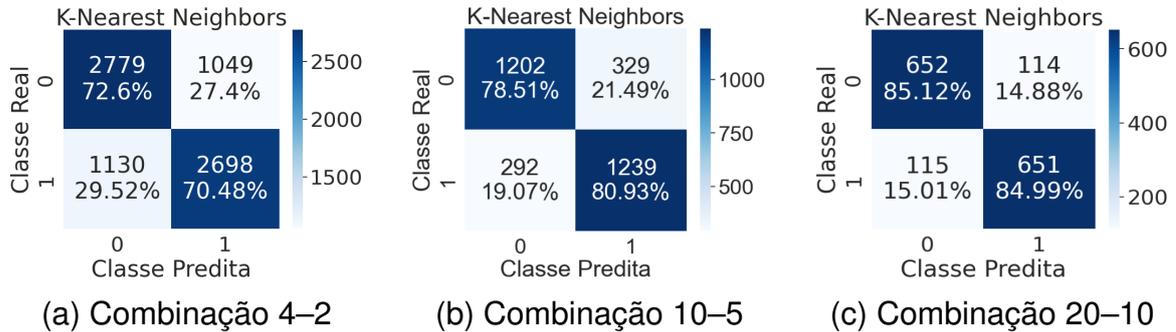
As Figuras 33, 34, 35 e 36 ilustram as matrizes de confusão, na banda de frequência *Gama* com o uso do K-NN, a fim de proporcionar mais detalhes sobre os desempenhos dos melhores modelos por meio dos acertos e erros em cada classe, para as dimensões emocionais de excitação, valência, dominância e preferência, respectivamente. Estas matrizes referem-se ao caso em que todos os 32 eletrodos são considerados, tendo em vista que proporcionaram os melhores resultados. Cada Figura exibe três matrizes de confusão correspondentes a janelas de 4, 10 e 20 segundos, com uma sobreposição de 50%. Em todos os casos, não se observam disparidades nos acertos e erros entre as classes. Entretanto, destaca-se que, em geral, os modelos de excitação demonstraram uma maior eficiência em reconhecer a classe "0".

Figura 33 – Cenário 3: Matrizes de confusão de excitação com K-NN na banda de frequência *Gama* usando dados de todos os eletrodos.



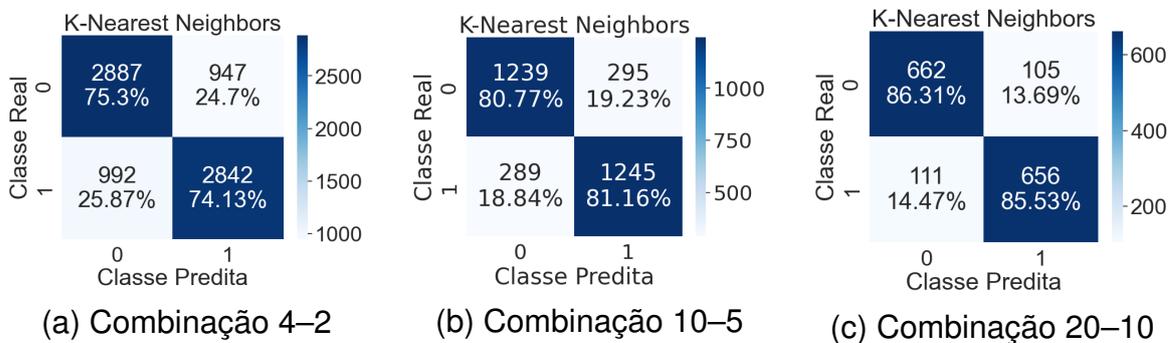
Fonte: autoria própria.

Figura 34 – Cenário 3: Matrizes de confusão de valência com K-NN na banda de frequência *Gama* usando dados de todos os eletrodos.



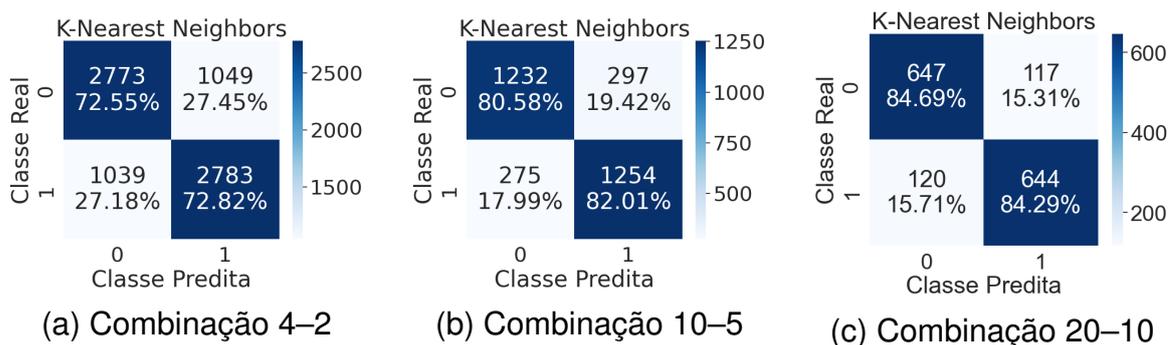
Fonte: autoria própria.

Figura 35 – Cenário 3: Matrizes de confusão de dominância com K-NN na banda de frequência *Gama* usando dados de todos os eletrodos.



Fonte: autoria própria.

Figura 36 – Cenário 3: Matrizes de confusão de preferência com K-NN na banda de frequência *Gama* usando dados de todos os eletrodos.



Fonte: autoria própria.

As matrizes de confusão dos modelos construídos com K-NN para as bandas de frequência *Alpha* e *Beta* podem ser visualizadas no Apêndice B. As demais matrizes de confusão – de outras combinações de algoritmo, frequência, janela e deslocamento de sinal, e região do cérebro – estão disponíveis no repositório do GitHub.

Por fim, a Tabela 11 sumariza os resultados dos melhores e piores modelos, considerando as métricas deste estudo. No geral, tanto os modelos mais eficazes quanto os menos eficazes foram construídos com base no K-NN. Nos casos de melhor desempenho, as frequências mais altas têm um impacto mais positivo, especialmente quando todos os 32 eletrodos foram utilizados. Por outro lado, os casos menos eficazes aparecem com a combinação 4–2, devido ao menor intervalo de janela. Para estes casos menos eficazes, os valores das métricas ficam em torno de 50%. Assim como discutido no Cenário 2, os grupos de eletrodos com menos atributos tiveram os piores desempenhos, como o grupo composto exclusivamente pelos eletrodos da região temporal.

Tabela 11 – Cenário 3: Avaliação dos modelos preditores para melhor e pior caso.

Dimensão	Combinação	Algoritmo	Frequência	Região	Precisão (%)		Sensibilidade (%)		F1-Score (%)		Acurácia (%)
					Classe 0	Classe 1	Classe 0	Classe 1	Classe 0	Classe 1	
<i>Melhor caso</i>											
Excitação	20–10	K-NN	<i>Gama</i>	All	85,51	85,42	85,4	85,53	85,45	85,47	85,46
Valência	20–10	K-NN	<i>Gama</i>	All	85,01	85,1	85,12	84,99	85,06	85,04	85,05
Dominância	20–10	K-NN	<i>Gama</i>	All	85,64	86,2	86,31	85,53	85,97	85,86	85,92
Preferência	20–10	K-NN	<i>Gama</i>	All	84,35	84,63	84,69	84,29	84,52	84,46	84,49
<i>Pior caso</i>											
Excitação	4–2	K-NN	<i>Gama</i>	Fp	51,56	51,33	47,47	55,4	49,43	53,29	51,43
Valência	10–5	K-NN	<i>Alpha</i>	AF	49,54	49,54	49,31	49,77	49,43	49,66	49,54
Dominância	4–2	K-NN	<i>Alpha</i>	T	51,17	51,13	50,18	52,11	50,67	51,61	51,15
Preferência	4–2	K-NN	<i>Alpha</i>	PO	49,68	49,67	50,39	48,95	50,03	49,31	49,67

Fonte: autoria própria.

Ao comparar com os resultados dos cenários anteriores, observa-se que o uso de janelas temporais com sobreposição, visando reforçar atividades recorrentes e, portanto, reduzindo a variabilidade nos sinais, teve um impacto positivo na construção dos modelos, com melhorias já evidentes com uma janela temporal de 4 segundos. Em termos gerais, os estudos na literatura geralmente baseiam-se na construção de modelos específicos para cada indivíduo, o que pode resultar em desempenho superior. No entanto, neste trabalho, optou-se por criar modelos treinados com dados de vários sujeitos. Assim, pode-se observar que os resultados foram promissores, considerando a complexidade da área, seja pela natureza complexa dos sinais de EEG ou pela subjetividade das emoções.

5 CONCLUSÕES

Neste trabalho foi proposto um *pipeline* para reconhecimento de emoções, baseado em imagens topográficas cerebrais geradas a partir de sinais de eletroencefalograma, considerando a importância desta área de estudo para investigação do funcionamento do cérebro humano em diversas condições e estados mentais.

Dentro deste contexto, este trabalho utilizou como estudo de caso o *dataset* DEAP, que contém informações sobre as respostas de sujeitos enquanto eram expostos a estímulos musicais e visuais, em quatro dimensões emocionais: excitação, valência, dominância e preferência. Com foco neste tema de estudo, os principais objetivos centraram-se na construção de um *dataset* estruturado, a partir de mapas topográficos de EEG, incluindo o mapeamento das regiões cerebrais e suas respectivas intensidades de ativação, e na análise e desenvolvimento de modelos preditivos de emoções.

O *dataset* construído neste estudo proporciona uma abordagem alternativa para análise dos dados, exigindo uma menor capacidade de armazenamento e processamento em comparação com os registros no formato de imagens. Salienta-se que o *dataset* está disponível em um repositório GitHub¹, servindo como recurso para tarefas de reconhecimento de emoções, com dados de EEG em um formato estruturado.

Os modelos preditivos foram desenvolvidos com o uso de técnicas de aprendizado de máquina, sendo utilizados nos experimentos até cerca de 238 mil registros provenientes do *dataset* estruturado construído. Deste modo, foram treinados três algoritmos – K-NN, RF e SVM, cada um com diferentes fundamentos matemáticos, para cada experimento. No que se refere às frequências consideradas neste estudo, destacam-se três amostras pertencentes às bandas de frequência *Alpha*, *Beta* e *Gama*.

Durante o processo de treinamento, foram realizados diversos experimentos para analisar configurações dos modelos, as quais são apresentadas neste estudo por meio de três cenários. O primeiro cenário visou avaliar o desempenho dos modelos ao utilizar as informações oriundas dos 32 eletrodos considerados nos experimentos de coleta de sinais de EEG. O segundo cenário avaliou o desempenho dos modelos considerando configurações específicas dos atributos do *dataset* segmentados por regiões

¹<https://github.com/brunocascaes/EEG-Emotion-Recognition/tree/main/dataset>

do cérebro. Por sua vez, o terceiro cenário teve como foco avaliar o desempenho dos modelos mediante o uso de janelas e sobreposição temporal nos sinais de EEG. Deste modo, enquanto os cenários 1 e 2 utilizam janelas temporais de 1 segundo, o terceiro cenário avaliou janelas de 4, 10 e 20 segundos, com sobreposição de 50% destas janelas.

Com base nos resultados obtidos, pode-se responder às questões de pesquisa deste estudo. Observa-se que o Cenário 1 proporcionou resultados superiores em comparação ao Cenário 2. Logo, o uso de todos os eletrodos contribuiu positivamente para o desempenho dos modelos em comparação com a utilização de segmentos de regiões específicas do córtex cerebral. Ao comparar com o cenário 3, nota-se uma melhora no desempenho dos modelos com o uso de janelas temporais mais extensas, as quais promovem uma suavização nos dados.

De forma geral, observou-se que os modelos construídos com dados de frequência da banda *Alpha* não resultaram em desempenhos satisfatórios, enquanto as frequências da banda *Beta* e *Gama* proporcionaram modelos de melhor desempenho, com destaque para os construídos na frequência 42 Hz. Ao considerar a avaliação segmentada por região, destacaram-se positivamente as localizações compostas pelas zonas frontal (F + FC) – para excitação, valência e preferência – e parietal (P + CP) – para dimensão de dominância. Entre os pontos negativos, evidenciou-se que regiões com menor influência de eletrodos, como as áreas temporal (T) e zona intermediária entre a região pré-frontal e frontal (AF), apresentaram resultados menos expressivos. O uso de janelas temporais revelou-se eficaz, com resultados consistentes já com janelas de 4 segundos, considerando a complexidade dos dados. Neste contexto, destaca-se que os algoritmos K-NN e SVM demonstraram respostas mais satisfatórias na tarefa de predição de emoções, principalmente quando utilizadas janelas temporais com e sem sobreposição, respectivamente.

Os resultados obtidos foram promissores mesmo com o uso de algoritmos convencionais de aprendizado de máquina. Utilizando janelas temporais de 4 segundos, na frequência *Gama* com K-NN, foram alcançados acurácia de 73,7%, 71,54%, 74,71% e 72,68% para as dimensões de excitação, valência, dominância e preferência, respectivamente. Já com uma janela de 20 segundos, na frequência *Gama* com K-NN, obteve-se acurácia de 85,46%, 85,05%, 85,92% e 84,49% para as dimensões de excitação, valência, dominância e preferência, respectivamente.

Como trabalhos futuros, pretende-se explorar e desenvolver novos modelos para reconhecimento de emoções, considerando diferentes amostras de frequência e janelas temporais. Além disto, planeja-se conduzir experimentos adicionais com o *dataset* estruturado construído, explorando diversas combinações das regiões cerebrais. Outra linha de pesquisa envolverá a realização de experimentos utilizando o *dataset* de mapas topográficos com as regiões do cérebro segmentadas, empregando algoritmos

de aprendizado profundo.

No contexto do reconhecimento de emoções por meio de sinais de EEG, transformados em imagens e mapeados em um *dataset* estruturado, esta pesquisa representa um relevante tópico de estudo. A abordagem estruturada para análise e construção de modelos permite um formato alternativo para analisar o comportamento e funcionamento do cérebro humano através do reconhecimento de emoções, sendo interessante para o campo da neurociência.

REFERÊNCIAS

ABDELAAL, M.; ALSAWY, A.; HEFNY, H. On Emotion Recognition using EEG. In: ANNUAL CONFERENCE ON STATISTICS, COMPUTER SCIENCES AND OPERATIONS RESEARCH, 50., 2015, EGY. **Proceedings...** Cairo University, 2015. p.35–49.

ALPAYDIN, E. **Introduction to Machine Learning**. 3.ed. Cambridge, MA, USA: MIT Press, 2014.

ASGHAR, M. A.; KHAN, M. J.; FAWAD; AMIN, Y.; RIZWAN, M.; RAHMAN, M.; BADNAVA, S.; MIRJAVADI, S. S. EEG-Based Multi-Modal Emotion Recognition using Bag of Deep Features: An Optimal Feature Selection Approach. **Sensors**, Switzerland, v.19, n.23, 2019.

BOUTROS, N.; GALDERISI, S.; POGARELL, O.; RIGGIO, S. **Standard Electroencephalography in Clinical Psychiatry**. 1st.ed. New Jersey, USA: Wiley, 2011.

BRADSKI, G.; KAEHLER, A. **Learning OpenCV: Computer vision with the OpenCV library**. Sebastopol, CA, USA: O'Reilly Media, Inc., 2008.

BREIMAN, L. Random Forests. **Mach. Learn.**, USA, v.45, n.1, p.5–32, Oct. 2001.

BREIMAN, L.; FRIEDMAN, J. H.; OLSHEN, R. A.; STONE, C. J. **Classification and Regression Trees**. Monterey, CA: Wadsworth and Brooks, 1984.

CASCIOLA, A.; CARLUCCI, S.; KENT, B.; PUNCH, A.; MUSZYNSKI, M.; ZHOU, D.; KAZEMI, A.; MIRIAN, M.; VALERIO, J.; MCKEOWN, M.; NYGAARD, H. A Deep Learning Strategy for Automatic Sleep Staging Based on Two-Channel EEG Headband Data. **Sensors**, Switzerland, v.21, p.3316, 05 2021.

CERRI, A. M. **Aplicação de Redes Neurais Convolucionais na Análise de Mapas Topográficos de EEG para Classificação de Estados Emocionais**. Disponível em: <https://pergamum.ufpel.edu.br/pergamumweb/vinculos/000105/000105e2.pdf>. Acesso em: 4 dez. 2023.

CHAPRON, K.; PLANTEVIN, V.; THULLIER, F.; BOUCHARD, K.; DUCHESNE, E.; GABOURY, S. A More Efficient Transportable and Scalable System for Real-Time Activities and Exercises Recognition. **Sensors**, Switzerland, v.18, 01 2018.

DEL POZO-BANOS, M.; ALONSO, J. B.; TICAY-RIVAS, J. R.; TRAVIESO, C. M. Electroencephalogram subject identification: A review. **Expert Systems with Applications**, USA, v.41, n.15, p.6537–6554, 2014.

DELORME, A.; MAKEIG, S. EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis. **Journal of Neuroscience Methods**, London, England, v.134, n.1, p.9–21, 2004.

DEMIR, F.; SOBAHI, N.; SIJLY, S.; SENGUR, A. Exploring Deep Learning Features for Automatic Classification of Human Emotion Using EEG Rhythms. **IEEE Sensors Journal**, USA, v.21, n.13, p.14923–14930, 2021.

EKMAN, P. Facial expression and emotion. **The American psychologist**, USA, v.48 4, p.384–92, 1993.

FACELI, K.; LORENA, A. C.; GAMA, J.; ALMEIDA, T. A. de; CARVALHO, A. C. P. d. L. F. d. **Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina**. 2.ed. Rio de Janeiro, RJ, BR: LTC, 2021.

GARG, D.; VERMA, G.; SINGH, A. A review of Deep Learning based methods for Affect Analysis using Physiological Signals. **Multimedia Tools and Applications**, Netherlands, v.82, p.46, 01 2023.

GERON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. 2nd.ed. Sebastopol, CA, USA: O'Reilly Media, Inc., 2019.

GONZALES, R.; WOODS, R. **Digital Image Processing**. 4.ed. New York, USA: Pearson, 2019.

HAMANN, S. Mapping discrete and dimensional emotions onto the brain: controversies and consensus. **Trends in Cognitive Sciences**, Cambridge, MA, USA, v.16, n.9, p.458–466, 2012.

HERWIG, U.; SATRAPI, P.; SCHONFELDT-LECUONA, C. Using the International 10-20 EEG System for Positioning of Transcranial Magnetic Stimulation. **Brain topography**, USA, v.16, p.95–99, 2003.

HOOI, L. S.; NISAR, H.; VOON, Y. V. Tracking of EEG activity using topographic maps. In: IEEE INTERNATIONAL CONFERENCE ON SIGNAL AND IMAGE PROCESSING

APPLICATIONS (ICSIPA), 2015., 2015, MY. **Proceedings...** IEEE, 2015. v.1, p.287–291.

KANDEL, E. R.; SCHWARTZ, J. H.; JESSELL, T. M.; SIEGELBAUM, S. A.; HUDSPETH, A. J. **Principles of Neural Science**. 5th.ed. New York, NY: McGraw-Hill Education, 2013.

KARLSSON, L. **Rubik's cube**. Disponível em: <https://t.ly/beW6o>. Acesso em: 17 out. 2023.

KOELSTRA, S.; MUHL, C.; SOLEYMANI, M.; LEE, J.-S.; YAZDANI, A.; EBRAHIMI, T.; PUN, T.; NIJHOLT, A.; PATRAS, I. DEAP: A Database for Emotion Analysis using Physiological Signals. **IEEE Transactions on Affective Computing**, USA, v.3, n.1, p.18–31, 2012.

LAVALLE, S. M.; BRANICKY, M. S.; LINDEMANN, S. R. On the relationship between classical grid search and probabilistic roadmaps. **The International Journal of Robotics Research**, USA, v.23, n.7-8, p.673–692, 2004.

LENT, R. **Cem bilhões de neurônios: conceitos fundamentais de neurociência**. Second Edition.ed. São Paulo, SP: Atheneu, 2010.

LI, J.; ZHANG, Z.; HE, H. Hierarchical Convolutional Neural Networks for EEG-Based Emotion Recognition. **Cognitive Computation**, USA, v.10, 04 2018.

MALIK, A.; AMIN, H. **Designing EEG Experiments for Studying the Brain**. 1st.ed. Massachusetts, USA: Academic Press, 2017.

MAUSS, I. B.; ROBINSON, M. D. Measures of emotion: A review. **Cognition and Emotion**, United Kingdom, v.23, n.2, p.209–237, 2009. PMID: 19809584.

MCKINNEY, W. et al. Data structures for statistical computing in python. In: PYTHON IN SCIENCE CONFERENCE, 9., 2010, USA. **Proceedings...** SciPy, 2010. v.445, p.51–56.

MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. **Foundations of Machine Learning**. 2nd.ed. Cambridge, MA, USA: The MIT Press, 2018.

NIEDENTHAL, P. M.; RIC, F. **Psychology of emotion**. New York, USA: Psychology Press, 2017.

PEDREGOSA, F.; VAROQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B.; GRISSEL, O.; BLONDEL, M.; PRETTENHOFER, P.; WEISS, R.; DUBOURG, V. et al. Scikit-learn: Machine learning in Python. **Journal of machine learning research**, USA, v.12, n.Oct, p.2825–2830, 2011.

POLZIN, T. Verbal and non-verbal cues in the communication of emotions. In: IEEE INTERNATIONAL CONFERENCE ON ACOUSTICS, SPEECH, AND SIGNAL PROCESSING., 2000., 2000, TUR. **Proceedings...** IEEE, 2000. v.4, p.2429–2432.

POSNER, J.; RUSSELL, J. A.; PETERSON, B. S. The circumplex model of affect: An integrative approach to affective neuroscience, cognitive development, and psychopathology. **Development and Psychopathology**, UK, v.17, p.715 – 734, 2005.

QING, C.; QIAO, R.; XU, X.; CHENG, Y. Interpretable Emotion Recognition Using EEG Signals. **IEEE Access**, USA, v.7, p.94160–94170, 2019.

QUINLAN, J. R. **C4.5: Programs for Machine Learning**. USA: Morgan Kaufmann Publishers Inc., 1993.

RICHERT, W.; COELHO, L. P. **Building Machine Learning Systems with Python**. 1.ed. Birmingham, UK: Packt Publishing, 2013.

RUSSELL, J. A Circumplex Model of Affect. **Journal of Personality and Social Psychology**, USA, v.39, p.1161–1178, 12 1980.

SAMAVAT, A.; KHALILI, E.; AYATI, B.; AYATI, M. Deep Learning Model With Adaptive Regularization for EEG-Based Emotion Recognition Using Temporal and Frequency Features. **IEEE Access**, USA, v.10, p.24520–24527, 2022.

SANEI, S.; CHAMBERS, J. **EEG Signal Processing and Machine Learning**. 2nd.ed. New Jersey, USA: Wiley, 2021.

SHARMA, R.; PACHORI, R. B.; SIRCAR, P. Automated emotion recognition based on higher order statistics and deep learning algorithm. **Biomedical Signal Processing and Control**, United Kingdom, v.58, p.101867, 2020.

SHU, L.; XIE, J.; YANG, M.; LI, Z.; LI, Z.; LIAO, D.; XU, X.; YANG, X. A Review of Emotion Recognition Using Physiological Signals. **Sensors**, Switzerland, v.18, p.2074, 06 2018.

SHWARTZ, S. S.; DAVID, S. B. **Understanding Machine Learning: From Theory to Algorithms**. USA: Cambridge University Press, 2014.

SOLOMON, C.; BRECKON, T. **Fundamentals of Digital Image Processing: A Practical Approach with Examples in Matlab**. New Jersey, USA: Wiley-Blackwell, 2010.

SQUIRE, L.; BERG, D.; BLOOM, F. E.; DU LAC, S.; GHOSH, A.; SPITZER, N. C. **Fundamental Neuroscience**. 3rd.ed. Massachusetts, USA: Academic Press, 2008.

TORTORA, G.; DERRICKSON, B. **Introduction to the Human Body**. 11th.ed. New Jersey, USA: Wiley, 2018.

VAN ROSSUM, G.; DRAKE, F. L. **Python 3 Reference Manual**. Scotts Valley, CA: CreateSpace, 2009.

WILLIAMS, P. L.; BANNISTER, L. H.; BERRY, M. M.; COLLINS, P.; DYSON, M.; DUSSEK, J. E.; FERGUSON, M. W. et al. **Gray's Anatomy**. 41st.ed. London, England: Elsevier, 2020.

XU, M.; YAO, J.; ZHANG, Z.; LI, R.; YANG, B.; LI, C.; LI, J.; ZHANG, J. Learning EEG topographical representation for classification via convolutional neural network. **Pattern Recognition**, USA, v.105, p.107390, 2020.

ZHENG, W.-L.; LU, B.-L. Investigating Critical Frequency Bands and Channels for EEG-Based Emotion Recognition with Deep Neural Networks. **IEEE Transactions on Autonomous Mental Development**, USA, v.7, n.3, p.162–175, 2015.

Apêndices

APÊNDICE A – Acurácia dos modelos preditivos

Tabela 12 – Acurácia dos modelos preditores de excitação por região cerebral.

Algoritmo	Banda de Frequência		Janela (s)		Sobreposição (s)		Acurácia por região cerebral													
	AF	All	C	CP	F	F + FC	FC	Fp	Fp + AF	O	O + PO	P	P + CP	PO	T					
K-NN	Alpha	1	0,518	0,5732	0,5192	0,5308	0,5305	0,5488	0,529	0,4983	0,5218	0,5105	0,5277	0,5259	0,5143	0,5009				
		4	0,5278	0,7113	0,5325	0,5573	0,5576	0,5926	0,558	0,5168	0,5403	0,515	0,5434	0,5543	0,5205	0,5218				
		10	0,5394	0,7816	0,544	0,5668	0,5949	0,6301	0,5867	0,5228	0,5769	0,5486	0,5681	0,5955	0,6372	0,5267	0,5147			
		20	0,5671	0,839	0,5724	0,5997	0,633	0,6734	0,6108	0,5332	0,586	0,5711	0,5841	0,6226	0,6545	0,5241	0,5267			
	Beta	1	0,5052	0,5786	0,5187	0,5368	0,5374	0,5568	0,5334	0,5064	0,525	0,5227	0,5281	0,5381	0,5594	0,5077	0,5052			
		4	0,5279	0,7263	0,5543	0,5636	0,5625	0,5999	0,5642	0,5145	0,582	0,5278	0,5706	0,5692	0,5986	0,5282	0,5146			
		10	0,5525	0,7956	0,5717	0,6079	0,6085	0,6529	0,601	0,544	0,5997	0,5538	0,6037	0,6085	0,6545	0,5479	0,5215			
		20	0,5352	0,837	0,605	0,6095	0,6362	0,6917	0,603	0,5398	0,6147	0,5756	0,6265	0,6213	0,6721	0,5535	0,5665			
		1	0,5111	0,6012	0,5357	0,5455	0,5439	0,5626	0,5422	0,509	0,5362	0,5243	0,5372	0,5409	0,562	0,52	0,5048			
		2	0,5286	0,737	0,5516	0,5788	0,5809	0,6115	0,5777	0,5143	0,5629	0,5355	0,5722	0,5827	0,611	0,5348	0,5268			
RF	Gamma	10	0,546	0,8123	0,5776	0,6066	0,6157	0,6587	0,605	0,5515	0,5958	0,561	0,5971	0,6173	0,6561	0,5362				
		20	0,5535	0,8546	0,6102	0,6252	0,6291	0,6949	0,5939	0,5684	0,6167	0,5756	0,6167	0,6219	0,6988	0,545				
		1	0,5382	0,5916	0,55	0,5492	0,5512	0,5713	0,5534	0,5073	0,5569	0,5302	0,5521	0,5459	0,5591	0,5358	0,5176			
		4	0,5526	0,6451	0,5651	0,5788	0,5832	0,6174	0,5789	0,5467	0,5747	0,545	0,5582	0,5758	0,6022	0,5443	0,5376			
	Alpha	10	0,5795	0,6737	0,574	0,5851	0,6092	0,6366	0,5893	0,559	0,6072	0,5714	0,6033	0,6059	0,6411	0,5613	0,5381			
		20	0,575	0,721	0,5834	0,605	0,6525	0,661	0,6258	0,5561	0,6056	0,5795	0,6167	0,6389	0,6506	0,5372	0,5528			
		1	0,5322	0,6057	0,5528	0,5634	0,554	0,5808	0,559	0,5184	0,5515	0,5446	0,5886	0,5569	0,5736	0,5388	0,517			
		4	0,5479	0,6714	0,5703	0,5867	0,5879	0,6286	0,5885	0,5374	0,5797	0,56	0,5875	0,5892	0,6309	0,5561	0,5344			
		10	0,5717	0,6972	0,5867	0,6327	0,6199	0,6653	0,6141	0,5732	0,617	0,5769	0,6154	0,6274	0,6656	0,5593	0,5535			
		20	0,5632	0,7164	0,6128	0,6291	0,6571	0,6793	0,6284	0,5704	0,6102	0,5815	0,6428	0,6434	0,6695	0,5626	0,5847			
SVM	Gamma	1	0,5338	0,6137	0,5536	0,567	0,5652	0,5906	0,573	0,5208	0,5526	0,549	0,5689	0,5617	0,5839	0,5428	0,516			
		4	0,5533	0,6827	0,5815	0,5939	0,6079	0,6428	0,6058	0,5412	0,5749	0,5704	0,6021	0,6011	0,6405	0,5609	0,536			
		10	0,5551	0,7151	0,6079	0,6271	0,6375	0,6607	0,6199	0,5701	0,6186	0,5988	0,6076	0,6219	0,6646	0,574	0,5701			
		20	0,5841	0,7243	0,6063	0,648	0,6551	0,6695	0,6278	0,5776	0,6245	0,5919	0,6362	0,6473	0,6832	0,5887	0,5561			
	Alpha	1	0,54	0,5961	0,5441	0,5493	0,5455	0,5731	0,5543	0,5106	0,5512	0,5272	0,5481	0,549	0,5671	0,5355	0,5093			
		4	0,5503	0,6458	0,5643	0,5771	0,5797	0,6166	0,5754	0,5366	0,5699	0,5428	0,5612	0,5756	0,5974	0,543	0,5321			
		10	0,5922	0,6571	0,5786	0,588	0,6098	0,6265	0,5909	0,5724	0,6102	0,5629	0,5883	0,5965	0,6203	0,5671	0,5284			
		20	0,5756	0,6695	0,5808	0,5919	0,6167	0,6467	0,5913	0,5776	0,586	0,5658	0,59	0,6121	0,6369	0,5528	0,5495			
		1	0,5433	0,6112	0,5498	0,5644	0,5478	0,5774	0,5586	0,5193	0,553	0,5468	0,5615	0,5524	0,5773	0,5417	0,5207			
		4	0,5407	0,6608	0,5644	0,5803	0,588	0,6188	0,5841	0,525	0,5655	0,5588	0,5904	0,5922	0,6132	0,5566	0,5318			
Gamma	10	0,561	0,6669	0,5893	0,605	0,6206	0,6437	0,6066	0,5675	0,5991	0,5649	0,6056	0,6092	0,6317	0,5636	0,5489				
	20	0,5619	0,6636	0,6069	0,6186	0,6265	0,6213	0,5971	0,6076	0,5815	0,5815	0,6193	0,6186	0,6193	0,5522	0,5489				
	1	0,5286	0,6218	0,5471	0,5613	0,5636	0,5896	0,5641	0,5173	0,5473	0,5399	0,5602	0,5625	0,585	0,5411	0,5231				
	4	0,545	0,6621	0,5712	0,5921	0,5986	0,6332	0,6005	0,543	0,572	0,5579	0,5932	0,5975	0,6209	0,5529	0,5335				
	10	0,561	0,675	0,5893	0,6082	0,6121	0,6395	0,6131	0,5805	0,605	0,5792	0,5949	0,6046	0,631	0,5512	0,5593				
	20	0,5554	0,661	0,5945	0,5841	0,6239	0,6441	0,6173	0,5743	0,5965	0,5919	0,6089	0,6199	0,6343	0,5495	0,543				

Fonte: autoria própria.

Tabela 13 – Acurácia dos modelos preditores de valência por região cerebral.

Algoritmo	Banda de Frequência	Janela (s)	Sobreposição (s)	Acurácia por região cerebral															
				AF	All	C	CP	F	F + FC	FC	Fp	Fp + AF	O	O + PO	P	P + CP	PO	T	
K-NN	Alpha	1	0	0,5027	0,5355	0,4999	0,5016	0,5146	0,519	0,5124	0,5154	0,5091	0,5047	0,5114	0,5089	0,5121	0,5047	0,5058	
		4	2	0,5033	0,6985	0,5138	0,5274	0,5291	0,562	0,5165	0,5099	0,5195	0,521	0,5304	0,5272	0,5573	0,5144	0,5112	
		10	5	0,4954	0,7874	0,5245	0,5639	0,5542	0,5918	0,549	0,5147	0,5304	0,518	0,5398	0,5451	0,6032	0,5127	0,517	0,5339
		20	10	0,5509	0,8094	0,5574	0,5672	0,5894	0,6567	0,5875	0,5339	0,5646	0,5294	0,5764	0,5705	0,6456	0,5111	0,5339	0,5015
	Beta	1	0	0,5041	0,537	0,5084	0,5111	0,5186	0,5219	0,5134	0,5101	0,515	0,5067	0,5198	0,5126	0,5242	0,5047	0,5015	
		4	2	0,515	0,7051	0,5239	0,5324	0,544	0,5688	0,5448	0,5222	0,531	0,5161	0,5385	0,5317	0,5657	0,5199	0,5112	
		10	5	0,516	0,7864	0,5405	0,5585	0,5689	0,6221	0,5552	0,547	0,5656	0,5242	0,5565	0,5607	0,6097	0,5157	0,5062	
		20	10	0,5242	0,8466	0,5679	0,5692	0,5914	0,6586	0,5888	0,5405	0,594	0,5529	0,5914	0,6201	0,6651	0,5326	0,5261	
		1	0	0,5135	0,5551	0,5121	0,52	0,5254	0,5377	0,5183	0,5145	0,5137	0,5086	0,5248	0,5212	0,5344	0,5117	0,5066	
		4	2	0,5191	0,7154	0,5508	0,5487	0,5529	0,5867	0,5453	0,5103	0,5559	0,5195	0,549	0,5586	0,5811	0,5214	0,5016	
RF	Gamma	10	5	0,5385	0,7972	0,5575	0,5728	0,5957	0,6228	0,5937	0,5418	0,5803	0,5327	0,5764	0,5895	0,6192	0,5199	0,5062	
		20	10	0,5666	0,8505	0,5836	0,6051	0,6142	0,6899	0,6084	0,5659	0,6051	0,5627	0,5901	0,6188	0,6978	0,517	0,5405	
		1	0	0,509	0,5537	0,5204	0,5188	0,5296	0,5356	0,5282	0,5193	0,522	0,5232	0,532	0,5319	0,5309	0,5111	0,4992	
		4	2	0,5137	0,6237	0,5251	0,5445	0,5517	0,5824	0,5503	0,5272	0,5387	0,5404	0,5443	0,5432	0,584	0,534	0,5191	
	Beta	10	5	0,5212	0,66	0,5317	0,5585	0,5738	0,6163	0,5699	0,5431	0,5353	0,5598	0,5516	0,6029	0,5284	0,5225	0,5284	
		20	10	0,5587	0,6886	0,5679	0,5881	0,6012	0,6514	0,609	0,5313	0,5809	0,5405	0,5725	0,5842	0,6253	0,5163	0,5379	
		1	0	0,5169	0,566	0,5231	0,5365	0,5322	0,5376	0,5238	0,5271	0,5313	0,5288	0,5412	0,5326	0,5442	0,5207	0,5113	
		4	2	0,5287	0,6506	0,5406	0,5445	0,5645	0,6002	0,5489	0,5549	0,5568	0,5376	0,5584	0,5504	0,5917	0,5313	0,523	
		10	5	0,5281	0,6786	0,549	0,566	0,6055	0,6212	0,5506	0,5447	0,5754	0,5529	0,5614	0,5767	0,6176	0,5428	0,5245	
		20	10	0,5496	0,7141	0,5614	0,611	0,6129	0,6345	0,609	0,5829	0,6038	0,5711	0,592	0,6168	0,643	0,549	0,5568	
SVM	Gamma	1	0	0,5228	0,5774	0,5413	0,5368	0,543	0,56	0,5439	0,5264	0,5424	0,5262	0,5415	0,545	0,5575	0,5178	0,5102	
		4	2	0,5421	0,6672	0,576	0,5735	0,5767	0,6157	0,5721	0,5435	0,5669	0,5519	0,5607	0,5775	0,6117	0,5323	0,5346	
		10	5	0,5578	0,694	0,5686	0,6055	0,6218	0,645	0,596	0,5614	0,5892	0,5565	0,5623	0,615	0,6411	0,5333	0,5503	
		20	10	0,5764	0,735	0,5966	0,6188	0,643	0,6913	0,6175	0,5777	0,626	0,5614	0,6123	0,6456	0,6815	0,5424	0,5542	
	Alpha	1	0	0,5147	0,5523	0,5158	0,5236	0,532	0,5379	0,5318	0,5188	0,5188	0,5188	0,5234	0,53	0,5304	0,5324	0,5167	0,5096
		4	2	0,5132	0,6084	0,5213	0,538	0,5553	0,572	0,5517	0,5187	0,5274	0,5367	0,5507	0,5421	0,5692	0,5302	0,5166	
		10	5	0,5366	0,6212	0,5343	0,5411	0,5663	0,5872	0,5722	0,5408	0,5411	0,5372	0,5434	0,5402	0,5634	0,532	0,5317	
		20	10	0,5307	0,626	0,5496	0,5444	0,5803	0,5979	0,5666	0,5235	0,5653	0,5281	0,5366	0,5692	0,577	0,5352	0,5313	
		1	0	0,5216	0,5674	0,524	0,5276	0,5277	0,5387	0,5216	0,5296	0,5317	0,5355	0,541	0,5264	0,5492	0,5243	0,5181	
		4	2	0,5219	0,626	0,5427	0,5449	0,5605	0,5772	0,5367	0,544	0,5481	0,5391	0,5559	0,5547	0,5678	0,5283	0,5265	
Beta	10	5	0,5261	0,6205	0,5415	0,5405	0,5663	0,581	0,5376	0,5621	0,565	0,5415	0,5624	0,5666	0,5722	0,5314	0,5323		
	20	10	0,5189	0,6279	0,5535	0,564	0,5653	0,5751	0,5542	0,562	0,5555	0,5333	0,5398	0,5542	0,5744	0,5411	0,5228		
	1	0	0,5178	0,5856	0,5382	0,5447	0,5503	0,5626	0,543	0,5288	0,542	0,5344	0,5396	0,538	0,5572	0,5277	0,5141		
	4	2	0,5381	0,6454	0,5678	0,5713	0,578	0,6021	0,5694	0,5423	0,5592	0,5426	0,5492	0,5733	0,5874	0,5265	0,534		
	10	5	0,5555	0,6541	0,5617	0,5653	0,5924	0,6143	0,5738	0,5428	0,5679	0,5405	0,5562	0,5862	0,6035	0,5343	0,5343		
	20	10	0,5594	0,671	0,5796	0,5836	0,5927	0,6253	0,6064	0,5463	0,5927	0,5352	0,5679	0,6025	0,624	0,5372	0,5339		

Fonte: autoria própria.

Tabela 14 – Acurácia dos modelos preditores de dominância por região cerebral.

Algoritmo	Banda de Frequência		Janela (s)		Sobreposição (s)		Acurácia por região cerebral												
	AF	All	C	CP	F	F + FC	FC	Fp	Fp + AF	O	O + PO	P	P + CP	PO	T				
K-NN	Alpha	1	0,5191	0,5901	0,5226	0,5382	0,5433	0,5283	0,4856	0,5322	0,5235	0,5318	0,5312	0,5635	0,4957	0,5175			
		4	0,5203	0,7363	0,5582	0,5687	0,5722	0,6028	0,5673	0,5322	0,5576	0,5271	0,5485	0,614	0,5325	0,5115			
		10	0,5293	0,7872	0,5844	0,5922	0,6105	0,6447	0,5825	0,5398	0,586	0,5306	0,5662	0,6102	0,6219	0,531	0,5424		
		20	0,5411	0,8572	0,5847	0,6389	0,6395	0,6741	0,6089	0,5795	0,6121	0,56	0,6167	0,6369	0,6721	0,5541	0,5587		
	Beta	1	0,5114	0,5974	0,5289	0,5425	0,5444	0,5646	0,5389	0,5387	0,5428	0,53	0,5586	0,5685	0,5125	0,5003			
		4	0,5361	0,741	0,5766	0,5758	0,5866	0,6266	0,5687	0,5432	0,5472	0,5957	0,5901	0,6304	0,5395	0,5343			
		10	0,5466	0,8035	0,5962	0,6115	0,6271	0,6568	0,6128	0,5564	0,5893	0,5802	0,6001	0,6226	0,6568	0,5492			
		20	0,5756	0,8546	0,6186	0,6395	0,6447	0,678	0,6506	0,5867	0,6291	0,5926	0,6304	0,6467	0,6969	0,59			
	Gamma	1	0,5273	0,6069	0,5403	0,5497	0,5538	0,5791	0,5485	0,5458	0,546	0,5327	0,5563	0,5516	0,5781	0,5101			
		4	0,5381	0,7471	0,5613	0,5912	0,597	0,6303	0,5806	0,5456	0,588	0,5462	0,5776	0,5839	0,6278	0,5235			
		10	0,5473	0,8096	0,59	0,6203	0,6327	0,6633	0,6111	0,5821	0,6131	0,5655	0,6066	0,6271	0,6731	0,5407			
		20	0,5834	0,8592	0,6134	0,6408	0,6741	0,6936	0,6291	0,5958	0,6434	0,5932	0,6402	0,6623	0,704	0,5508			
RF	Alpha	1	0,5407	0,6129	0,554	0,576	0,565	0,5845	0,551	0,5493	0,5623	0,5419	0,5657	0,572	0,5905	0,5212			
		4	0,554	0,6689	0,5841	0,6012	0,5998	0,6334	0,5796	0,5652	0,5879	0,5527	0,5801	0,5987	0,6393	0,5408			
		10	0,5629	0,6832	0,5968	0,6128	0,604	0,6512	0,604	0,5743	0,6007	0,56	0,587	0,6141	0,6382	0,5414			
		20	0,5567	0,7053	0,6095	0,6382	0,6271	0,6591	0,6317	0,5815	0,6206	0,5717	0,6284	0,6395	0,6578	0,588			
	Beta	1	0,5491	0,6277	0,5642	0,582	0,5671	0,589	0,5664	0,5608	0,5735	0,5572	0,5789	0,5868	0,6124	0,5393			
		4	0,5625	0,6882	0,5885	0,5974	0,615	0,6513	0,5931	0,5739	0,5899	0,572	0,6167	0,6144	0,6538	0,5623			
		10	0,5668	0,7083	0,5984	0,631	0,6411	0,6718	0,6232	0,5913	0,6232	0,5737	0,6268	0,6349	0,6773	0,5619			
		20	0,5939	0,7256	0,6323	0,6525	0,6708	0,7138	0,6714	0,5945	0,5984	0,603	0,6278	0,6545	0,6767	0,6004			
	Gamma	1	0,5454	0,6278	0,564	0,5838	0,5822	0,6001	0,5716	0,5659	0,5816	0,5498	0,5744	0,602	0,5315				
		4	0,5653	0,7061	0,5882	0,6093	0,6116	0,6532	0,6054	0,5826	0,6133	0,5756	0,6146	0,6577	0,5518				
		10	0,5772	0,7269	0,616	0,6431	0,6437	0,6773	0,6164	0,6043	0,6304	0,5922	0,6327	0,6571	0,6894				
		20	0,6063	0,7503	0,6343	0,6799	0,6734	0,7093	0,6317	0,6213	0,6362	0,59	0,646	0,6754	0,7184				
SVM	Alpha	1	0,5418	0,6165	0,5537	0,5721	0,5646	0,584	0,5518	0,5649	0,548	0,5563	0,5685	0,5901	0,5221				
		4	0,5527	0,6601	0,5807	0,605	0,5927	0,6174	0,5891	0,5629	0,5773	0,5477	0,5756	0,6004	0,6239				
		10	0,5596	0,6561	0,6007	0,6118	0,6118	0,6346	0,6007	0,5854	0,6027	0,5652	0,5913	0,6037	0,6271				
		20	0,5554	0,6636	0,603	0,6173	0,6108	0,6213	0,616	0,5763	0,5841	0,5795	0,5978	0,6284	0,6467				
	Beta	1	0,5502	0,6362	0,5561	0,5712	0,5642	0,589	0,5676	0,5568	0,5706	0,5549	0,5774	0,5884	0,6081				
		4	0,56	0,6737	0,5876	0,6033	0,6082	0,6311	0,596	0,5763	0,5822	0,5557	0,5965	0,6115	0,6368				
		10	0,5603	0,6754	0,6079	0,6063	0,6235	0,6467	0,6248	0,5942	0,6128	0,5691	0,6059	0,6323	0,6441				
		20	0,5711	0,6793	0,633	0,6186	0,6389	0,646	0,6297	0,6108	0,5684	0,5978	0,6441	0,6506	0,5515				
	Gamma	1	0,5494	0,6439	0,563	0,5781	0,5752	0,6041	0,5611	0,5651	0,5492	0,5492	0,5724	0,58	0,601				
		4	0,561	0,687	0,5927	0,6082	0,6056	0,6381	0,6041	0,5712	0,6032	0,5589	0,6029	0,6152	0,6406				
		10	0,5665	0,6881	0,616	0,6359	0,6173	0,6535	0,6183	0,5984	0,6307	0,5665	0,6118	0,6437	0,6574				
		20	0,5867	0,6845	0,6258	0,6415	0,6349	0,6754	0,6375	0,5971	0,6304	0,5913	0,6199	0,6473	0,6649				

Fonte: autoria própria.

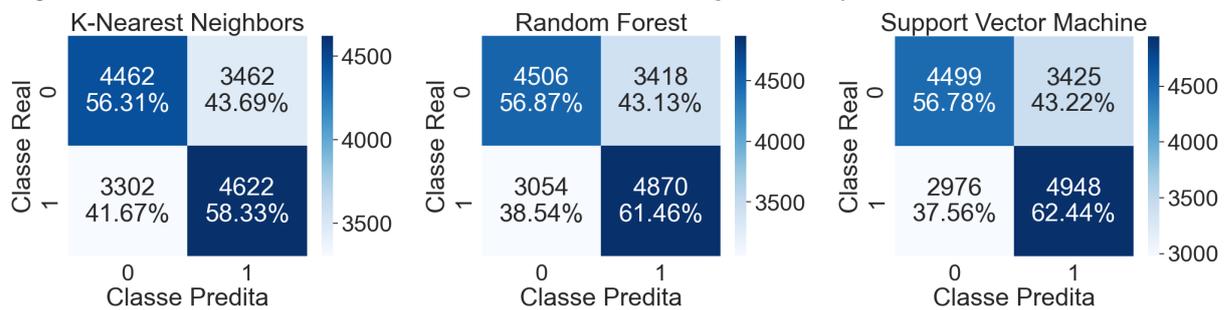
Tabela 15 – Acurácia dos modelos preditores de preferência por região cerebral.

Algoritmo	Banda de Frequência		Janela (s)		Sobreposição (s)		Acurácia por região cerebral													
	AF	All	C	CP	F	F + FC	FC	Fp	Fp + AF	O	O + PO	P	P + CP	PO	T					
K-NN	Alpha	1	0,5068	0,5526	0,5078	0,5158	0,5241	0,5134	0,5119	0,5139	0,5058	0,5146	0,5058	0,5192	0,4943	0,4932				
		4	0,508	0,6974	0,5154	0,5313	0,5502	0,576	0,5476	0,5276	0,517	0,5357	0,5368	0,5657	0,4967	0,5093				
		10	0,5114	0,7763	0,5412	0,5451	0,5808	0,6259	0,5615	0,517	0,5517	0,5386	0,5536	0,5791	0,4997	0,5229				
		20	0,5406	0,8207	0,5543	0,5661	0,6132	0,6819	0,6171	0,5654	0,6132	0,6054	0,6132	0,6505	0,5118	0,5406				
		0	0,5013	0,5615	0,5013	0,5163	0,5179	0,5329	0,5151	0,5144	0,5194	0,524	0,5389	0,512	0,5047					
	Beta	4	0,5077	0,7227	0,5296	0,5394	0,5577	0,5852	0,5501	0,525	0,5391	0,5298	0,5462	0,5506	0,5875	0,5059				
		10	0,518	0,7825	0,5661	0,5863	0,5886	0,6275	0,5768	0,5314	0,5546	0,5481	0,5834	0,6292	0,5098	0,5052				
		20	0,5491	0,8416	0,5635	0,5929	0,6276	0,6715	0,6041	0,5366	0,5805	0,5524	0,6224	0,6171	0,659	0,5438				
		0	0,5073	0,5768	0,5236	0,5301	0,5322	0,5489	0,521	0,4921	0,5197	0,5078	0,5212	0,5247	0,5464	0,5056	0,5031			
		2	0,5166	0,7268	0,5594	0,5563	0,5632	0,603	0,5589	0,5286	0,5577	0,5252	0,5509	0,562	0,5993	0,5194	0,5228			
RF	Gamma	10	0,5412	0,8129	0,5661	0,588	0,6409	0,5971	0,534	0,5739	0,5347	0,5857	0,6027	0,6472	0,5307	0,5291				
		20	0,5373	0,8449	0,5812	0,6139	0,6263	0,6767	0,625	0,5445	0,6008	0,627	0,6322	0,6688	0,5419	0,5582				
		1	0,5218	0,5781	0,5279	0,5294	0,5432	0,5545	0,5439	0,5202	0,5329	0,5221	0,5338	0,5464	0,5106	0,5079				
		4	0,5344	0,6533	0,5542	0,5631	0,5788	0,619	0,5767	0,5386	0,5597	0,5453	0,565	0,5578	0,5973	0,5166	0,5309			
		5	0,5379	0,6833	0,5739	0,5824	0,602	0,6383	0,5919	0,5383	0,5598	0,552	0,588	0,6033	0,6259	0,5245	0,5523			
	Alpha	20	0,5582	0,695	0,5772	0,5955	0,6073	0,6531	0,6185	0,5628	0,591	0,5772	0,5988	0,6198	0,6623	0,5615	0,5524			
		1	0,511	0,5869	0,5255	0,5339	0,5461	0,5583	0,5461	0,5202	0,5278	0,5463	0,561	0,5428	0,5565	0,5219	0,5189			
		4	0,5264	0,6729	0,5557	0,5722	0,5874	0,624	0,5785	0,545	0,56	0,5544	0,5687	0,5788	0,6139	0,5322				
		10	0,5222	0,6884	0,5768	0,5883	0,6158	0,64	0,5909	0,5569	0,5687	0,5683	0,5889	0,62	0,6553	0,5435	0,5455			
		20	0,5556	0,7291	0,5864	0,6178	0,6374	0,6564	0,6113	0,5766	0,6158	0,5825	0,6237	0,6394	0,6754	0,5596	0,5582			
SVM	Gamma	1	0,5215	0,6001	0,5457	0,5418	0,558	0,5525	0,5233	0,5396	0,5302	0,5442	0,5546	0,5724	0,5217	0,5175				
		4	0,5348	0,6801	0,5806	0,5846	0,5874	0,6379	0,6009	0,5538	0,5771	0,5577	0,5824	0,6009	0,6324	0,5399	0,5451			
		10	0,5615	0,6972	0,5948	0,6184	0,6171	0,6664	0,605	0,5464	0,6004	0,5759	0,6076	0,6256	0,6648	0,553	0,5605			
		20	0,57	0,733	0,6093	0,6448	0,6348	0,6806	0,6499	0,5857	0,6158	0,606	0,6518	0,6702	0,6937	0,5589	0,5687			
		0	0,524	0,5839	0,5214	0,5229	0,5435	0,552	0,5471	0,5213	0,5301	0,528	0,5346	0,5327	0,5452	0,5141	0,5158			
	Alpha	4	0,5336	0,6419	0,5497	0,5644	0,5714	0,6047	0,5767	0,5365	0,5479	0,5356	0,5532	0,5624	0,5888	0,5165	0,534			
		10	0,535	0,6557	0,5605	0,5657	0,5883	0,6122	0,5831	0,5415	0,5644	0,5441	0,5791	0,5948	0,6158	0,5392	0,5504			
		20	0,5622	0,642	0,5635	0,5779	0,5949	0,6283	0,6165	0,538	0,5844	0,5713	0,6106	0,5857	0,6191	0,5576	0,57			
		1	0,5106	0,6003	0,5242	0,5291	0,5494	0,5627	0,5472	0,5242	0,5266	0,5408	0,5485	0,5462	0,5627	0,5242	0,5229			
		2	0,5306	0,6511	0,5564	0,5642	0,5896	0,606	0,5747	0,5445	0,5629	0,5513	0,5649	0,5811	0,6071	0,5339	0,5307			
Beta	10	0,5363	0,6553	0,5795	0,5782	0,5925	0,6164	0,5867	0,5405	0,5693	0,569	0,5903	0,6115	0,6302	0,5474	0,5376				
	20	0,5452	0,6551	0,5766	0,6139	0,5923	0,625	0,6126	0,57	0,5838	0,5785	0,6099	0,6165	0,6307	0,5465	0,555				
	1	0,5201	0,6065	0,543	0,5377	0,5552	0,582	0,5517	0,5241	0,5334	0,5294	0,5365	0,5536	0,572	0,5192	0,5184				
	4	0,5355	0,6621	0,5746	0,5759	0,5774	0,6218	0,5945	0,5467	0,5682	0,5509	0,5754	0,5952	0,6176	0,5347	0,5323				
	5	0,5556	0,6606	0,5749	0,5961	0,6037	0,6266	0,6102	0,5556	0,5837	0,5651	0,5893	0,6099	0,6357	0,5484	0,5562				
Gamma	20	0,5635	0,6715	0,5825	0,5962	0,6034	0,6342	0,625	0,5471	0,5772	0,572	0,5955	0,6283	0,6466	0,5196	0,572				

Fonte: autoria própria.

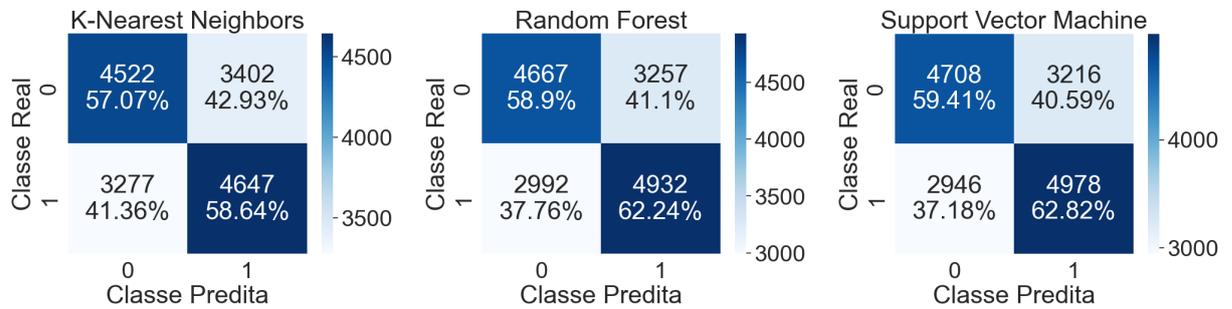
APÊNDICE B – Matrizes de confusão de modelos usando dados de todos os eletrodos

Figura 37 – Cenário 1: Matrizes de confusão de excitação em *Alpha*.

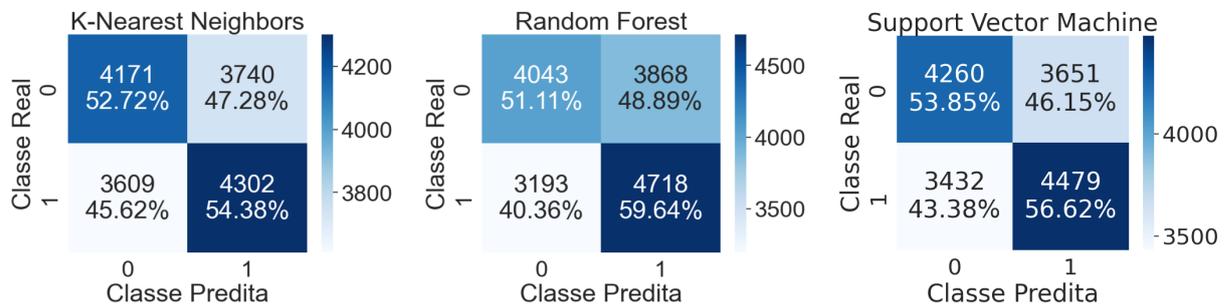


Fonte: autoria própria.

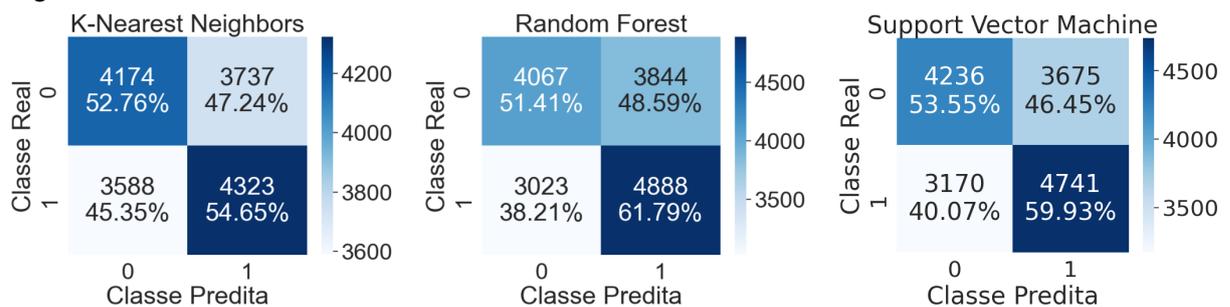
Figura 38 – Cenário 1: Matrizes de confusão de excitação em *Beta*.



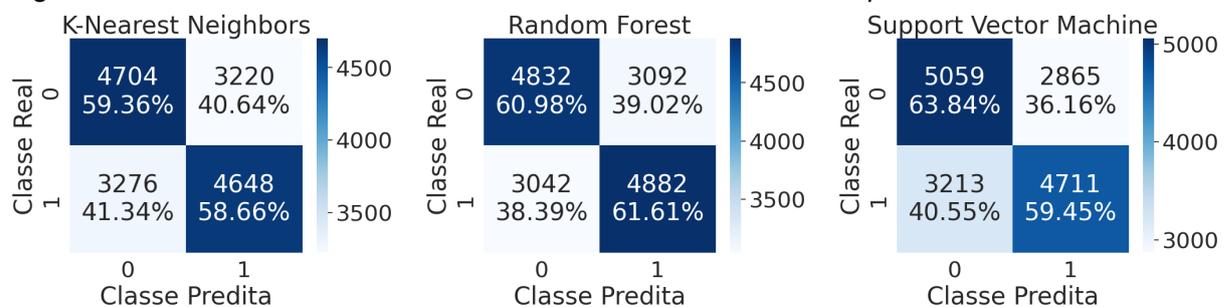
Fonte: autoria própria.

Figura 39 – Cenário 1: Matrizes de confusão de valência em *Alpha*.

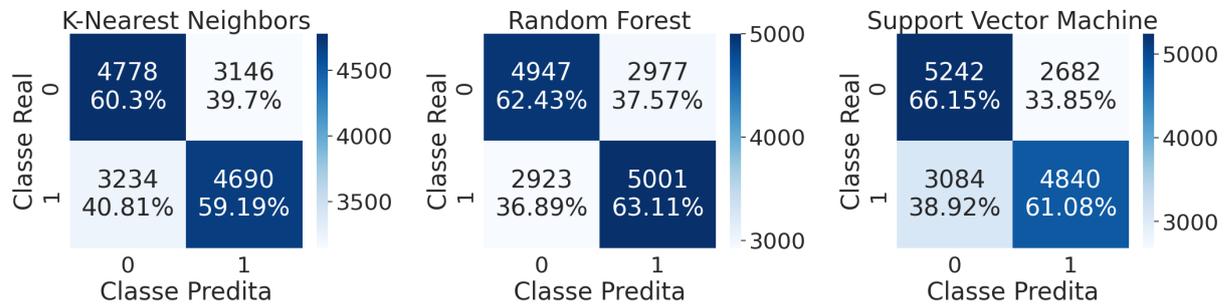
Fonte: autoria própria.

Figura 40 – Cenário 1: Matrizes de confusão de valência em *Beta*.

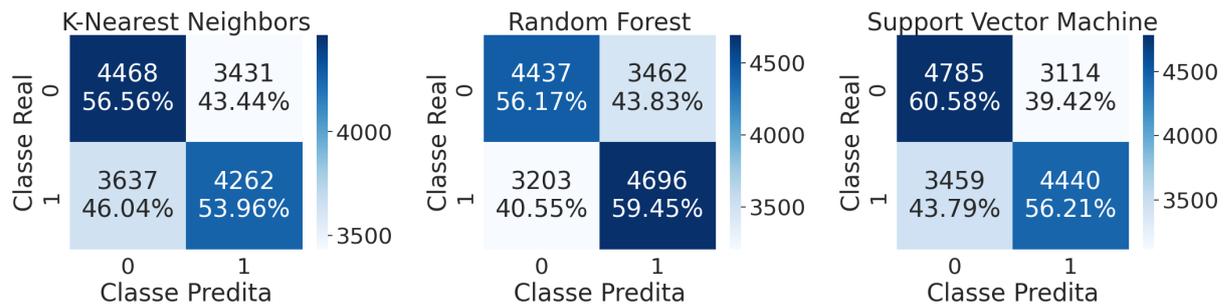
Fonte: autoria própria.

Figura 41 – Cenário 1: Matrizes de confusão de dominância em *Alpha*.

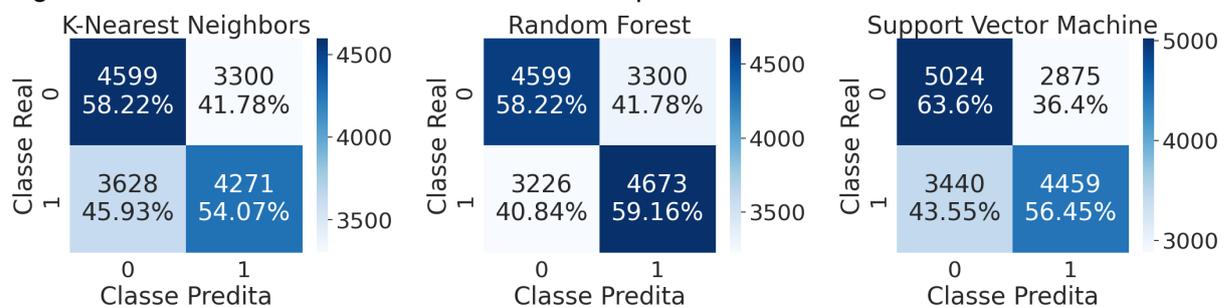
Fonte: autoria própria.

Figura 42 – Cenário 1: Matrizes de confusão de dominância em *Beta*.

Fonte: autoria própria.

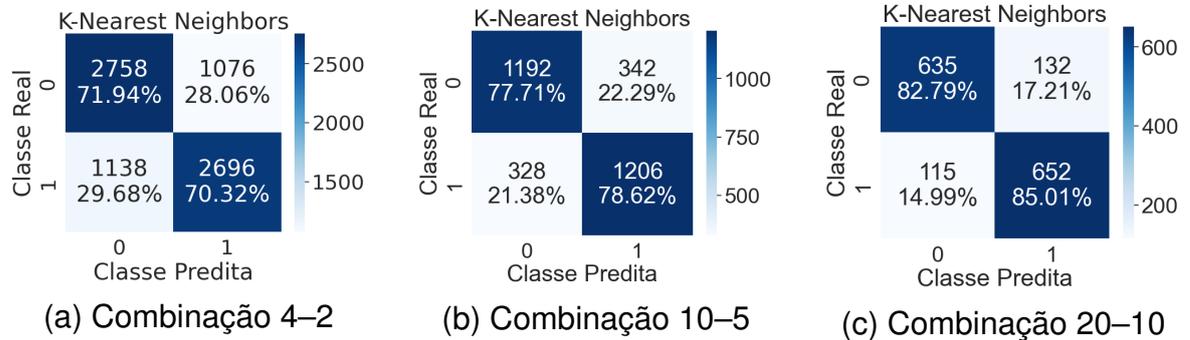
Figura 43 – Cenário 1: Matrizes de confusão de preferência em *Alpha*.

Fonte: autoria própria.

Figura 44 – Cenário 1: Matrizes de confusão de preferência em *Beta*.

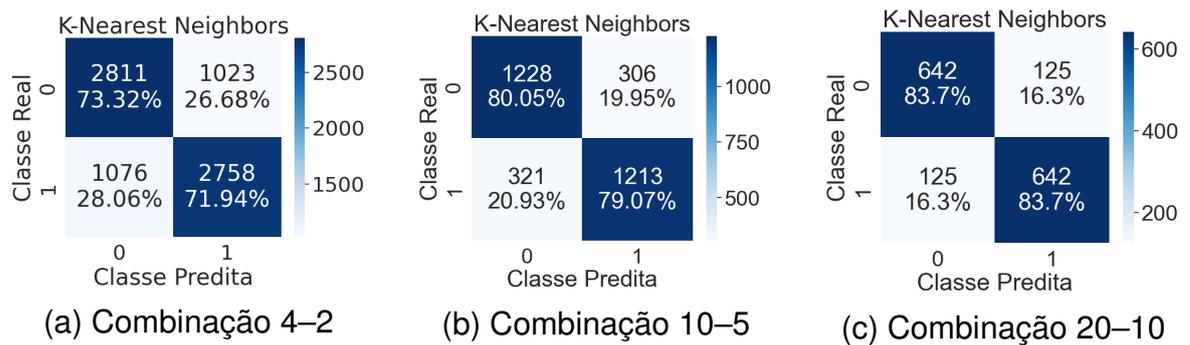
Fonte: autoria própria.

Figura 45 – Cenário 3: Matrizes de confusão de excitação com K-NN em *Alpha*.



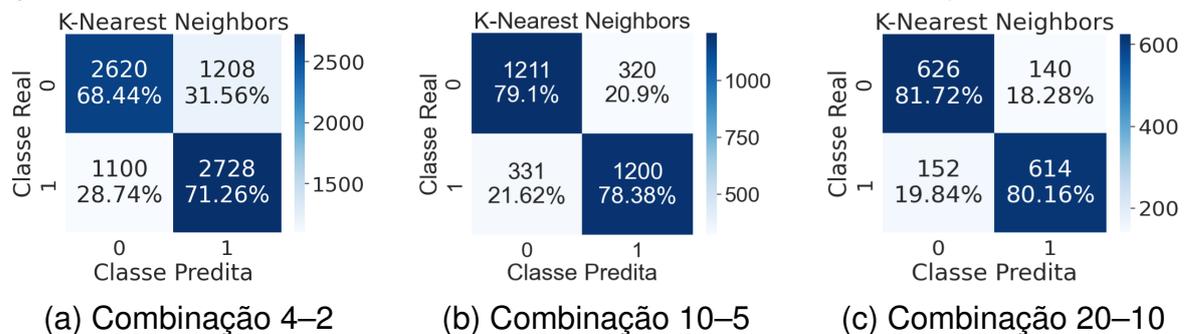
Fonte: autoria própria.

Figura 46 – Cenário 3: Matrizes de confusão de excitação com K-NN em *Beta*.



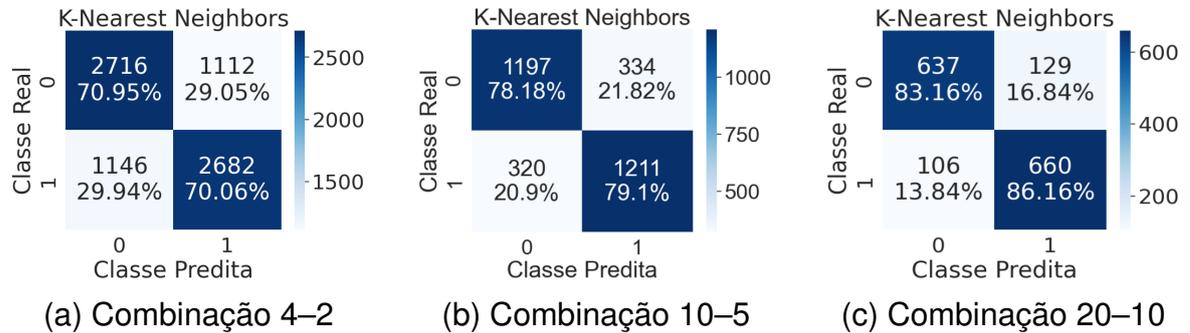
Fonte: autoria própria.

Figura 47 – Cenário 3: Matrizes de confusão de valência com K-NN em *Alpha*.



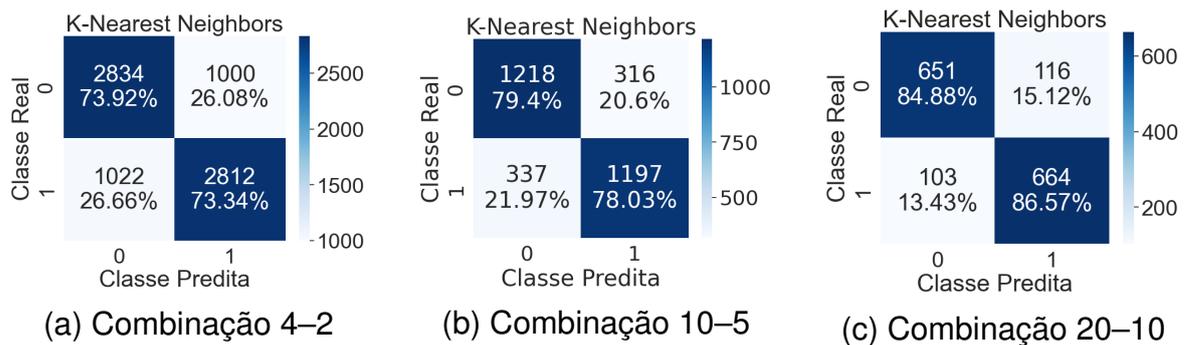
Fonte: autoria própria.

Figura 48 – Cenário 3: Matrizes de confusão de valência com K-NN em *Beta*.



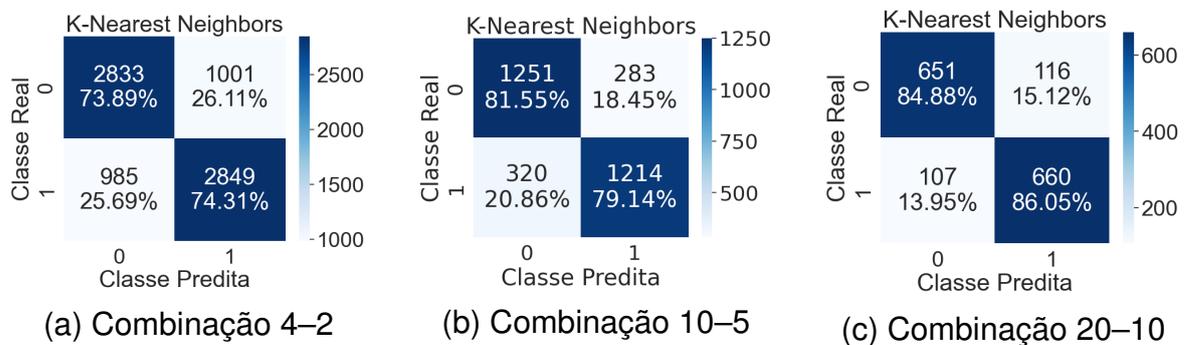
Fonte: autoria própria.

Figura 49 – Cenário 3: Matrizes de confusão de dominância com K-NN em *Alpha*.



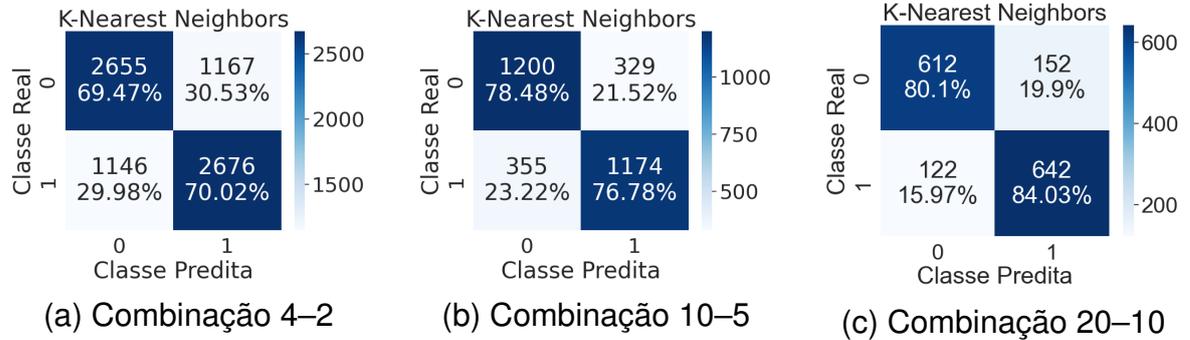
Fonte: autoria própria.

Figura 50 – Cenário 3: Matrizes de confusão de dominância com K-NN em *Beta*.



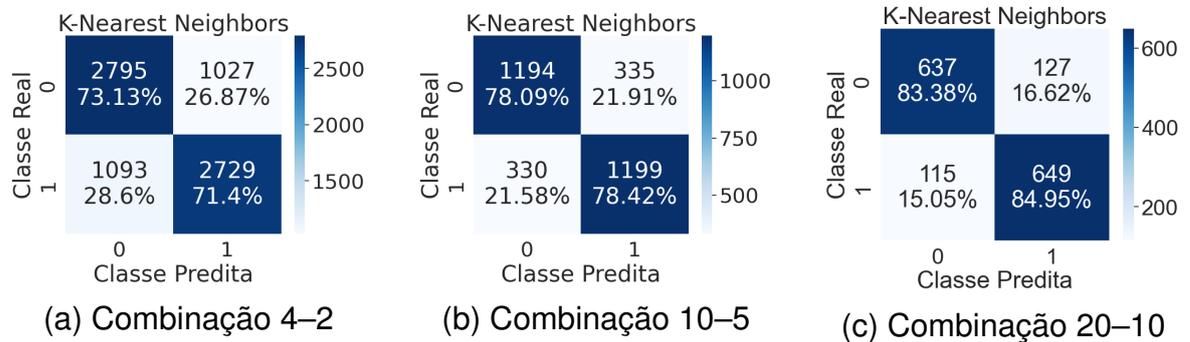
Fonte: autoria própria.

Figura 51 – Cenário 3: Matrizes de confusão de preferência com K-NN em *Alpha*.



Fonte: autoria própria.

Figura 52 – Cenário 3: Matrizes de confusão de preferência com K-NN em *Beta*.



Fonte: autoria própria.