



Universidade Federal do Maranhão
Centro de Ciências Exatas e Tecnologia
Programa de Pós Graduação em Engenharia Elétrica

Identificação de Atividades Cognitivas a Partir de Modelos de
Aprendizado de Máquina Aplicados ao Processamento de Sinais de
Eletroencefalograma (EEG).

Juliana Mycaelle Oliveira Silva

São Luis
2022

Universidade Federal do Maranhão
Centro de Ciências Exatas e Tecnologia
Programa de Pós Graduação em Engenharia Elétrica

Juliana Mycaelle Oliveira Silva

Identificação de Atividades Cognitivas a Partir de Modelos de
Aprendizado de Máquina Aplicados ao Processamento de Sinais de
Eletroencefalograma (EEG).

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica do Centro de Ciências Exatas e Tecnologias, da Universidade Federal do Maranhão, como re-quisito para a obtenção do grau de Mestre em Engenharia Elétrica.

Orientador: Prof. Allan Kardec Duailibe Barros Filho

São Luis
2022

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

Silva, Juliana Mycaelle Oliveira.

Identificação de Atividades Cognitivas a Partir de Modelos de Aprendizado de Máquina Aplicados ao Processamento de Sinais de Eletroencefalograma EEG / Juliana Mycaelle Oliveira Silva. - 2022.

72 f.

Orientador(a): Allan Kardec Duailibe Barros Filho.
Dissertação (Mestrado) - Programa de Pós-graduação em Engenharia Elétrica/ccet, Universidade Federal do Maranhão, São Luis, 2022.

1. Aprendizado de máquina. 2. EEG. 3. Eletroencefalograma. 4. Inteligência Artificial. I. Filho, Allan Kardec Duailibe Barros. II. Título.

IDENTIFICAÇÃO DE ATIVIDADES COGNITIVAS A PARTIR DE MODELOS DE APRENDIZADO DE MÁQUINA APLICADOS AO PROCESSAMENTO DE SINAIS DE ELETROENCEFALOGRAMA (EEG)

Juliana Mycaelle Oliveira Silva

Dissertação aprovada em 16 de Setembro de 2022

Prof. Dr. Allan Kardec Duailibe Barros Filho, Ph.D., UFMA
(Orientador)

Prof. Dr. Gean Carlos Lopes de Sousa, Dr., UFMA
(Membro da Banca Examinadora)

Prof. Dra. Priscila Lima Rocha, Dra., IFMA
(Membro da Banca Examinadora)

São Luís
2022

Dedicatória

Dedico,

À meus pais; à minha prima Elaine que não está mais entre nós, mas foi uma das grandes motivações para que eu chegasse a esta etapa. Dedico também a meus afilhados (Luis Antonio, Henry e Valentina), que busquem nesta vida acima de tudo o céu e a presença de um Cristo que nos ama em cada etapa de nossa vida. Amo todos vocês.

Agradecimentos

Agradeço,

Aos meus pais por todo apoio. À meu namorado por todo o incentivo. À minha amiga Cristiany, que não me faltou em conselhos e em companhia.

Ao meu orientador professor Allan que me deu a oportunidade de ingressar no laboratório e ser sua orientanda, acreditando no meu potencial. De forma Especial agradeço também ao meu amigo Gean Carlos por todas as horas que se dedicou a minhas dúvidas e me ajudou em todas as etapas que surgiram ao longo da minha vida acadêmica. Aos meus amigos de laboratório do PIB, Davi, Marta, George, Fillype. Ao meu amigo Jonathan Queiroz por toda a ajuda e boas ideias durante a execução dessa pesquisa.

Agradeço também à FAPEMA pelo financiamento prestado à esta pesquisa.

A todos meu sincero, Obrigado!

“Há quem busque o saber para vendê-lo por dinheiro ou por honras: é um indigno tráfico. Mas, há quem busque o saber para edificar, e isto é amor. E há quem busque o saber para se edificar, e isto é prudência.”.

São Bernardo de Claraval

Resumo

Os diferentes tipos de atividades realizadas pelo sujeito, como ler; ouvir música; dançar; entre outras, conduzem a ativação das regiões encefálicas. Dentre essas atividades, as atividades cognitivas estão associadas a uma ativação de regiões encefálicas relacionadas com a aprendizagem, como as regiões do lóbulo frontal (Superior Frontal, Precuneus, entre outras). Diversos estudos vem sendo desenvolvidos para relacionar atividades cognitivas e as regiões encefálicas associadas. Este tipo de estudo é importante na compreensão da funcionalidade e conectividade do encéfalo e esse conhecimento pode servir de auxílio para o diagnóstico de anormalidades no seu funcionamento. Este estudo tem como objetivo a elaboração de um modelo classificador de atividades encefálicas durante o desenvolvimento de uma atividade cognitiva dentro das três categorias de atividade: Jogo de video game, música ou matemática. Para isso, utilizou-se dos sinais de Eletroencefalograma (EEG) coletados em duas bases de dados públicas e com uso da técnica de estimação de fontes encefálicas estimou-se as regiões anatômicas relacionadas a cada uma das atividades. Após essa determinação, foi treinado e testado um modelo baseado em aprendizado de máquinas que classifica o tipo de atividade desempenhada de acordo com as categorias de atividade. Dos resultados obtidos, podemos ressaltar o modelo classificador das atividades encefálicas elaborado com accurácia de 99,9%.

Palavras-chave: Eletroencefalograma, EEG, Aprendizado de máquinas, Inteligência Artificial.

Abstract

The different types of activities performed by the subject, such as reading; listen to music; to dance; among others, they lead to the activation of brain regions. Among these activities, cognitive activities are associated with an activation of brain regions related to learning, such as the frontal lobe regions (Superior Frontal, Precuneus, among others). Several studies have been developed to relate cognitive activities and associated brain regions. This type of study is important in understanding the functionality and connectivity of the brain and this knowledge can help to diagnose abnormalities in its functioning. This study aims to develop a classifier model of brain activities during the development of a cognitive activity within the three categories of activity: Video game, music or mathematics. For this, we used the Electroencephalogram (EEG) signals collected in two public databases and using the technique of estimation of brain sources, the anatomical regions related to each of the activities were estimated. After this determination, a model based on machine learning was trained and tested that classifies the type of activity performed according to the activity categories. From the obtained results, we can highlight the encephalic activities classifier model elaborated with an accuracy of 99.9%.

Keywords: Electroencephalogram, EEG, Machine Learning, Artificial Intelligence.

Lista de Figuras

2.1	Estrutura do Encéfalo. Adaptado de (HALL; GUYTON, 2011)	7
2.2	Lobos cerebrais. Adaptado de (MILLER; CUMMINGS, 2017)	8
2.3	Áreas funcionais do córtex cerebral humano. Adaptado de (HALL; GUYTON, 2011)	9
2.4	Estrutura de um neurônio. Adaptado de (HALL; GUYTON, 2011)	11
2.5	Representação do sistema internacional 10-20. Adaptado de (HALL; GUYTON, 2011)	12
2.6	Exemplo de EEG normal. Retirado de (FÜRBAASS, 2017)	13
2.7	Soluções para o problema de estimação de fontes encefálicas, no lado direito a solução do problema inverso e do lado direito a solução do problema direto. Imagem feita pelo autor.	15
2.8	Regiões anatômicas do atlas Mindboogle. Adaptada de (KLEIN et al., 2017). . .	17
2.9	Como funciona o algoritmo Ramdon Forest Classifier. Baseado em (BREIMAN, 2001)	20
2.10	Agrupamento de Voronoi. Retirado de (PETERSON, 2009)	22
3.1	Passos que serão utilizados na elaboração do modelo classificador. Na etapa 1 será realizada a busca pelas bases de dados dos sinais de EEG. Na etapa dois será realizada a estimação de fontes encefálicas. Na etapa será elaborado um banco de dados com as regiões encefálicas associadas a cada uma das atividades. Na etapa quatro será elaborado, treinado e testado o modelo classificador.	29
4.1	Exemplo da ativação encefálica durante a atividade de jogar de video game, obtido com a estimação de fontes encefálicas no software <i>Brainstorm</i>	34
4.2	Exemplo da ativação encefálica durante a atividade de ouvir música, obtido com a estimação de fontes encefálicas no software <i>Brainstorm</i>	35
4.3	Exemplo da ativação encefálica durante a atividade de responder questões matemáticas, obtido com a estimação de fontes encefálicas no software <i>Brainstorm</i> . .	35
4.4	Curva de aprendizagem do modelo Randon Forest.	47

4.5	<p>Regiões encefálicas com maior influência na classificação da atividade realizada. IPE - Inferior Parietral Esquerdo; PRED - Precuneus Direito; SMD - Supra Marginal Direito; LOD - Lateral Occipital Direito; LOE - Lateral Occipital Esquerdo; POSTD - Postcentral Direito; SFD - Superior Frontal Direito; CD - Cuneus Direito; CE - Cuneus Esquerdo; IPD - Inferior Parietral Direito; SME - Superior Marginal Esquerdo; CMFE - Caudal Medio Frontal Esquerdo; RMFE - Rostral Medio Frontal Esquerdo; PARE - Parahippocampal Esquerdo; PARD - Parahippocampal Direito; ITD - Inferior Temporal Direito; STE – Superior Temporal Esquerdo; RMFD - Rostral Medio Frontal Direito; STD – Superior Temporal Direito; PTD - Posterior Temporal Direito. As regiões que apresentam uma relação positiva com a atividade em questão se apresenta seguida do valor 1 no eixo y, enquanto as regiões com relação negativa se apresentam com o valor 0 no eixo y.</p>	48
4.6	<p>Curva ROC do modelo.</p>	49

Lista de Tabelas

2.1	Classificação das frequências encefálicas (LI et al., 2022)	13
2.2	Principais Kernels. Retirado de (SOUSA et al., 2019)	24
4.1	Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)	36
4.1	Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)	37
4.1	Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)	38
4.1	Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)	39
4.1	Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)	40
4.1	Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)	41
4.1	Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)	42
4.1	Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)	43
4.1	Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)	44
4.1	Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)	45
4.2	Resultados obtidos por cada modelo	46
4.3	Comparativo de performance de metodologias anteriores com o a performance obtida neste trabalho.	51

Sumário

1	Introdução	2
1.1	Trabalhos Relacionados	3
1.2	Motivação	4
1.3	Objetivos	4
1.3.1	Objetivo Geral	4
1.3.2	Objetivos Específicos	5
1.4	Organização do Trabalho	5
2	Referencial Teórico	6
2.1	Encéfalo, a Atividade Eletroencefálica e o Processo de Aprendizagem	6
2.1.1	O Encéfalo	6
2.1.2	O Processo de aprendizagem	9
2.1.3	Atividade Encefálica	10
2.1.4	Estimação de fontes encefálicas	14
2.2	Aprendizado de Máquinas e os Classificadores Utilizados	17
2.2.1	Aprendizado de Máquinas (AM)	18
2.2.2	Classificadores Utilizados	19
2.3	Considerações	25
3	Materiais e Métodos para Classificação de Atividades Cognitivas	27
3.1	Pesquisa e Método Científico	27
3.2	Delineamento da Pesquisa	29
3.2.1	Bases de Dados	29
3.2.2	Estimação de Fontes Encefálicas	30
3.2.3	Modelo Classificador	31
3.2.4	Métricas de Avaliação	31
3.3	Considerações	32
4	Resultados	34
4.1	Estimação de Fontes Encefálicas	34
4.2	Classificador da atividade cognitiva a partir das regiões encefálicas ativadas . . .	46
4.3	Discursão dos Resultados	50
4.4	Trabalhos Futuros	51
4.5	Considerações	51

5 Conclusão

52

APÊNDICE

56

Introdução

O encéfalo é o principal órgão do sistema nervoso central e cada uma de suas regiões possui uma funcionalidade específica que pode ser estudada. O estudo dessas regiões fornece informações sobre as atividades desenvolvidas pelo indivíduo, como dançar, ler, ouvir música, entre outras (MICHEL; HE, 2019). Conhecer as funcionalidades e o funcionamento do encéfalo durante a realização das distintas atividades desenvolvidas pelo indivíduo, pode servir de auxílio ao diagnóstico de anormalidades que afetem a funcionalidade encefálica. Essas anormalidades podem gerar deficiências ou problemas que afetam a capacidade cognitiva do indivíduo (MICHEL; HE, 2019). A capacidade cognitiva está associada ao desempenho do indivíduo em atividades predominantemente cognitivas como estudar; ler; ouvir música; entre outras (MICHEL; HE, 2019).

As atividades predominantemente cognitivas estão associadas ao funcionamento de regiões encefálicas relacionadas com a aprendizagem, como as regiões do lóbulo frontal (MORIDERA et al., 2021). A aprendizagem está relacionada com a cognição e para a compreensão da cognição humana, do ponto de vista da neurociência cognitiva, se faz necessário conhecer as características provenientes do funcionamento do encéfalo durante as atividades cognitivas (PURVES et al., 2008). Mas relacionar o funcionamento do encéfalo com atividades específicas desenvolvidas pelo sujeito é um problema complexo, uma vez que necessita-se associar a ativação neuronal com a atividade desenvolvida pelo indivíduo (FRANK; BADRE, 2015). Neste sentido, supomos que o primeiro passo para a solução deste problema é diferenciar a atividade encefálica de indivíduos normais em distintas atividades cognitivas.

Concientes de que essas atividades ocasionam o funcionamento de regiões encefálicas específicas (GIRI; KUMAR; GANDHI, 2020), o objetivo desse trabalho é desenvolver um modelo para classificação da atividade neuronal relacionada aos estímulos emitidos durante as atividades cognitivas de jogar video game, responder questões de matemática ou ouvir música. Esses estímulos emitidos durante essas atividades estão relacionados à concentração, emoção e habilidade (MCCRAE et al., 2022; ZHANG et al., 2016; GAHO et al., 2018).

Conhecer o funcionamento do encéfalo no que diz respeito a cognição humana, pode proporcionar um maior número de abordagens frente aos altos números de indivíduos afetados por doenças que prejudicam a atividade encefálica cognitiva. Em 2019, as doenças que afetam a atividade cognitiva do encéfalo, como a doença de Alzheimer e outras formas de demência, foram classificadas como uma das dez principais causas de morte no mundo (GUERCHET et al., 2020). Atualmente cerca de 55 milhões de pessoas têm demência, com mais de 60% vivendo em países de baixa e média renda. Estima-se que esse número aumente para 78 milhões em 2030 e

139 milhões em 2050 (GUERCHET et al., 2020).

Assim, é notória a necessidade de desenvolvimento de estudos e pesquisas acerca da atividade encefálica responsável pelo desempenho cognitivo. Essa necessidade tem impulsionado o desenvolvimento de métodos autônomos que façam a detecção e previsão da relação entre funcionamento encefálico e atividade desenvolvida (GAHO et al., 2018; ZHANG et al., 2021). Os métodos desenvolvidos em geral utilizam alguma tecnologia de captação da atividade encefálica, e geramente o método utilizado é a Ressonância Magnética Funcional (fMRI) (FOX; RAICHLE, 2007; GANZETTI; MANTINI, 2013).

A fMRI é um exame caro, que requer um alto conhecimento técnico na manipulação e captação do exame, o que dificulta sua obtenção, além disso ele fornece apenas uma medida indireta da atividade neural mediada por uma resposta hemodinâmica lenta (GANZETTI; MANTINI, 2013). Como alternativa a fMRI encontramos a eletroencefalografia (EEG), que é um exame mais barato e de fácil acesso e por isso será utilizado neste trabalho (GANZETTI; MANTINI, 2013).

1.1 Trabalhos Relacionados

Diversos autores desenvolveram estudos que visam classificar a atividade encefálica a partir de uma imagem da atividade cerebral, e diversos trabalhos relacionados a esse tema são encontrados na literatura, dentre eles, (HAFEEZ et al., 2021) apresenta uma estrutura para classificar o nível de experiência do jogador de um jogo de video game usando dados de eletroencefalograma (EEG). Nesse trabalho eles apresentam a hipótese de que a atividade cerebral de jogadores experientes e novatos é diferente, e sugerem a classificação da atividade encefálica a partir da extração de características do sinal de EEG do jogador, eles utilizaram modelos computacionais de aprendizado de máquina na classificação e obtiveram um classificador com 98,33% de acurácia.

Um outro trabalho, de (CHEAH et al., 2020) utiliza aprendizado de máquinas para destacar a capacidade das redes neurais convolucionais (CNNs) em classificar dados de EEG ouvindo diferentes tipos de música. A metodologia utilizada neste trabalho incorpora parte da utilizada em nossa pesquisa. Nos resultados, o autor alcançou uma acurácia de 97,68% em seu modelo classificador que é capaz não apenas de diferenciar o EEG de sujeitos que ouvem música daquele de sujeitos sem entrada auditiva, mas também é capaz de diferenciar com precisão o EEG de sujeitos que ouvem músicas de diferentes ritmos.

Já na perspectiva multi classe, trabalhos como o de (PAWAR; DHAGE, 2020) propõe um método baseado na classificação de eletroencefalogramas (EEG) onde sujeitos foram solicitados a realizar tarefas de repetição mental de quatro palavras diferentes: 'esquerda', 'direita', 'para cima' e 'para baixo'. Utilizando aprendizado de máquina para classificação multiclasse e binária, os autores alcançaram uma precisão de classificação multiclasse e binária de (49,77%) e (85,57%), respectivamente. Seus resultados nos mostram que o uso dos sinais de EEG como imagem encefálica de diferentes atividades relacionadas a ativação neuronal podem ser classificados de maneira análoga a qual propomos.

Em outro estudo, (GAERTNER et al., 2021), propõe um método baseado na classificação de eletroencefalogramas (EEG) para classificar as emoções sentidas por um grupo de pessoas. Os autores usam como metodologia essa abordagem para modelar e classificar diferentes emoções dentro do modelo para detecção de emoções obtendo uma acurácia de 99,79% em sua classificação.

Como supracitado, a comunidade acadêmica desprende uma variedade de esforços para identificação de alguma relação entre atividade encefálica e a atividade desenvolvida pelo sujeito. Ressalta-se que a maioria das metodologias propostas para classificação baseia-se nas regiões encefálicas associadas aos sinais de EEG emitidos. Em outras palavras, os classificadores utilizam a relação existente entre região encefálica e atividade desempenhada, relação observada por exemplo em (WILKEY et al., 2017) onde é feita uma associação entre a atividade encefálica e a memorização de números matemáticos, essa memorização provocava uma atividade em um conjunto de regiões comuns, como o lóbulo parietal inferior.

Diante do conhecimento atual, propomos um modelo de classificador da atividade encefálica com maior poder interpretativo a partir das regiões anatômicas do encéfalo associadas ao sinal emitido durante as três categorias estudadas, gerando assim um modelo multi classe.

1.2 Motivação

A ausência de mecanismos computacionais capazes de identificar as relações entre um funcionamento eletroencefálico normal e a eletroencefalografia, considerando padrões notados na análise e classificação de sinais de EEG durante atividades específicas, como as atividades cognitivas, é um fator importante no que diz respeito a motivação de realização desse trabalho.

É perceptível que a dificuldade em caracterizar padrões de atividades eletroencefálica em indivíduos normais é um fator relevante no que diz respeito ao mapeamento do funcionamento do encéfalo. Pois, a partir do conhecimento dos padrões de funcionamento da atividade encefálica durante a execução de determinadas atividades, possivelmente possa se identificar de que modo as atividades cognitivas associam-se ao funcionamento eletroencefálico (GAHO et al., 2018).

Uma outra dificuldade para identificar o padrão de ativação eletroencefálica no EEG sob influência da atividade desempenhada pelo indivíduo é o fato de existirem diversas regiões encefálicas que são ativadas durante as atividades de maneira semelhante, o que dificulta a classificação do tipo de atividade considerando o funcionamento eletroencefálico (GAERTNER et al., 2021).

Portanto, é a possibilidade de auxiliar o profissional que analisa as atividades eletroencefálicas de indivíduos durante atividades cognitivas, procurando relação entre o funcionamento do encéfalo e a atividade cognitiva desenvolvida pelo sujeito que motiva a realização desse trabalho. Este tipo de situação é muito utilizada por profissionais que fazem monitoramento de pessoas com algum tipo de patologia que degrada a função cognitiva do encéfalo (GUERCHET et al., 2020). Vale ressaltar que os métodos que serão apresentados nesse trabalho vislumbram a possibilidade de oferecer uma alternativa computacional como aplicação de uma análise ao eletroencefalograma captado.

1.3 Objetivos

1.3.1 Objetivo Geral

Desenvolver um modelo, baseado em aprendizado de máquina, para a classificação generalizada da atividade desenvolvida pelo indivíduo a partir dos sinais de eletroencefalograma (EEG) captados durante o desenvolvimento de uma das três atividades escolhidas (Jogo de video game, Música, Matemática).

1.3.2 Objetivos Específicos

- Aplicar a técnica de estimação de fontes encefálicas nos sinais de EEG e verificar seu funcionamento;
- Verificar e testar algoritmos para estimação de fontes encefálicas;
- Analisar as regiões ativadas durante o desenvolvimento de atividades predominantemente cognitivas;
- Testar modelos baseado em aprendizado de máquinas para a classificação de atividades encefálicas;
- Avaliar resultados de classificação de vetores de características;

1.4 Organização do Trabalho

No capítulo 2 são apresentados os conceitos teóricos que nortearam a pesquisa. A metodologia aplicada é apresentada no capítulo 3. Os resultados obtidos são expostos no capítulo 4, através de gráficos e tabelas comparativas, ainda no 4, uma discussão dos resultados é apresentada. No capítulo 5 são abordadas as conclusões observadas e os desafios a serem superados em trabalhos futuros.

Referencial Teórico

2.1 Encéfalo, a Atividade Eletroencefálica e o Processo de Aprendizagem

O encéfalo é um dos mais requintados órgãos humanos, sendo responsável pela reflexão e interpretação das complexidades e do mundo ao nosso redor. É no encéfalo que está o centro da inteligência, linguagem, consciência e pensamento. Ele é responsável pelo controle do corpo humano, o único órgão consciente da sua existência (ROLAND, 1993).

O córtex cerebral é a fina camada de substância cinzenta que reveste o centro medular de todo encéfalo. No córtex cerebral chegam impulsos provenientes de todas as regiões de sensibilidade que aí podem ser interpretadas. É do córtex que saem os impulsos nervosos que iniciam e comandam os movimentos voluntários e com ele estão relacionados os fenômenos psíquicos (HALL; GUYTON, 2011).

Com o desenvolvimento da tecnologia, descobriu-se métodos para capturar imagens da atividade encefálica, a partir dessa imagem é possível estudar as várias áreas e funções cerebrais que comandam o corpo. Um dos métodos de captura da atividade encefálica é o eletroencefalograma (EEG), um exame não invasivo capaz de mapear a atividade eletroencefálica por meio da captação do sinal elétrico emitido, um exame de baixo custo e bastante conhecido e utilizado na área médica (HALL; GUYTON, 2011).

Ressaltando a importância desta pesquisa, esse tópico de Fundamentação Teórica irá guiar os leitores desta dissertação nos conceitos principais para a elaboração deste trabalho, tais como o encéfalo, a atividade eletroencefálica incluindo o conceito de Eletroencefalograma(EEG) e o processo de aprendizagem, identificando áreas importantes para o ser humano que se relacionam com o aprendizado durante atividades cotidianas, como as tratadas aqui.

2.1.1 O Encéfalo

O encéfalo é o principal órgão do sistema nervoso central e está localizado no interior do crânio humano (HALL; GUYTON, 2011). Atualmente, o mapeamento de imagens de funcionamento do encéfalo humano já permite saber diversas informações a cerca do seu funcionamento, bem como sua composição e as diversas regiões que o compõem. O encéfalo é composto de uma massa de tecido cinza-róseo e por substâncias internas em tons branco, que ocupa o centro do encéfalo e cinza que compõe o córtex cerebral (GAZZANIGA, 1989).

O encéfalo compõe algumas estruturas anatômicas (HALL; GUYTON, 2011):

- **Telencéfalo:** Composto pelos dois hemisférios cerebrais (direito e esquerdo) .
- **Diencéfalo:** É localizado na linha mediana entre os dois hemisférios e é dividido em:
 - **Epitálamo:** Forma a glândula pineal e habênula;
 - **Tálamo:** Conhecida como a região transmissora de informações no encéfalo, exceto as informações olfatórias;
 - **Hipotálamo:** Responsável por controlar o sistema endócrino.
- **Cerebelo:** É responsável pelo equilíbrio e coordenação motora e está localizado atrás do tronco cerebral (GAZZANIGA, 1989)
- **Tronco Cerebral:** Está localizado entre o cérebro e a medula e é a estrutura nervosa que liga esses dois. Composto por uma estrutura central responsável pelo controle da consciência, sono e vigília, pode ser dividido em três partes:
 - **Mesencéfalo:** região superior ao tronco cerebral de onde saem os pares de nervos cranianos III e IV (MARTIN, 2012).
 - **Ponte:** região média do tronco cerebral de onde saem os nervos cranianos V, VI, VII e VIII (MARTIN, 2012).
 - **Bulbo:** Porção inferior do tronco cerebral de onde saem os nervos cranianos IX, X, XI, XII (MARTIN, 2012).

Na Figura 2.1 pode ser vista a estrutura encefálica conforme descrição acima:

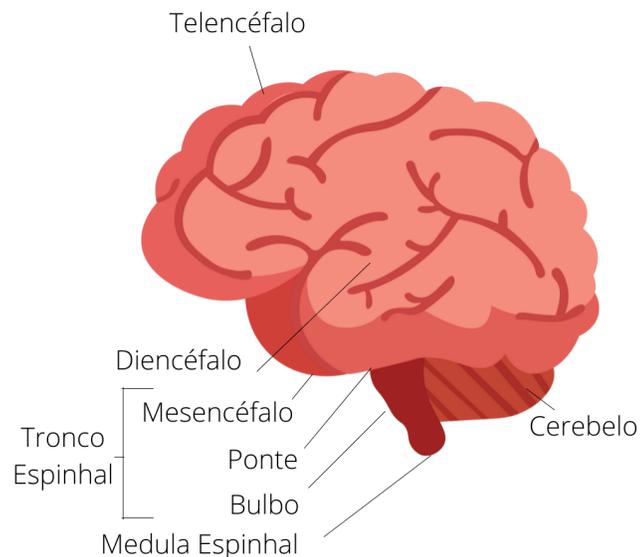


Figura 2.1: Estrutura do Encéfalo. Adaptado de (HALL; GUYTON, 2011)

Estudos em seres humanos mostraram que áreas corticais cerebrais distintas têm funções diferenciadas (HALL; GUYTON, 2011; MILLER; CUMMINGS, 2017) afirma que o telencéfalo

é dividido em quatro regiões anatômicas denominadas lobos: o frontal, o parietal, o occipital e o temporal. A Figura 2.2 mostra cada um dos lobos e como eles são localizados em cada hemisfério do telencéfalo.

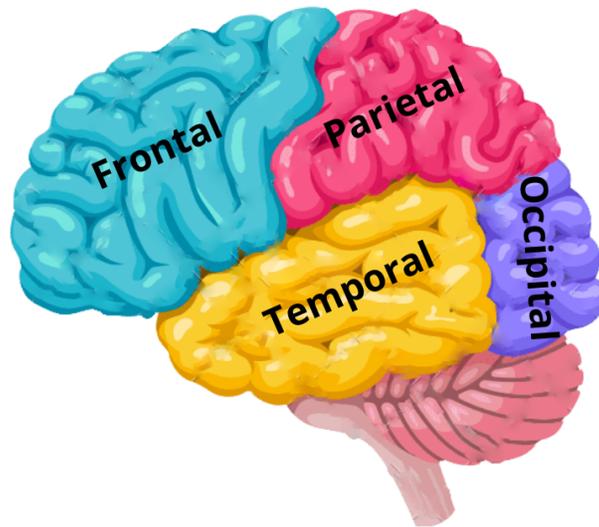


Figura 2.2: Lobos cerebrais. Adaptado de (MILLER; CUMMINGS, 2017)

Cada lobo está associado a um tipo de processamento de informações como pode ser vista na Figura 3 onde se observa a relação entre região encefálica e o processamento de algumas informações. Segundo (HALL; GUYTON, 2011), o lobo frontal está associado com tarefas para tomada de decisão, julgamento, raciocínio, memória de curto prazo, entre outras. O lobo parietal está relacionado com o senso de localização do corpo. O lobo occipital é indicado como a área processadora da visão, e o lobo temporal é indicado como uma região associada ao processamento da audição, mas está associado também a memórias de longo prazo, a emoções e recordações. A relação entre lobo e informação processada pode ser vista na Figura 2.3, onde há o exemplo de processamento de algumas informações por cada lobo.

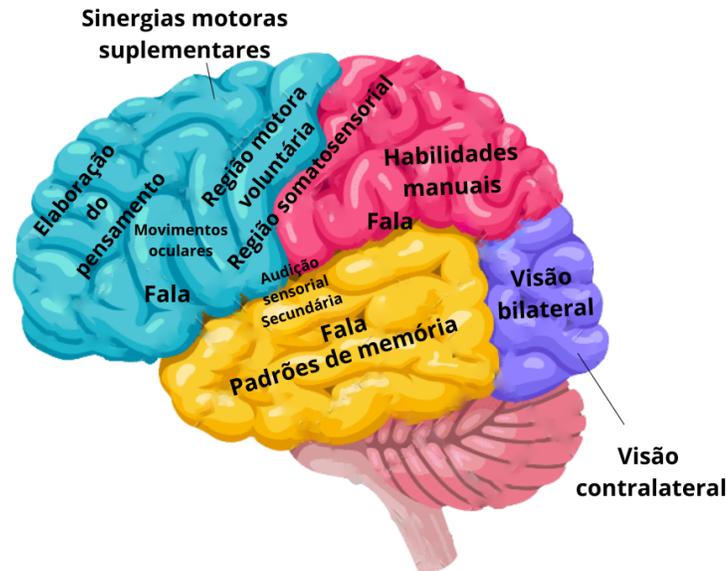


Figura 2.3: Áreas funcionais do córtex cerebral humano. Adaptado de (HALL; GUYTON, 2011)

2.1.2 O Processo de aprendizagem

As funções de aprendizagem do encefálo estão associadas a diversos fatores e funções anatômicas. Entre essas funções lembramos da importância do telencéfalo no processo de aprendizagem e da característica primordial do encefálo que possibilita o aprendizado do ser humano, que é a neuroplasticidade.

Telencéfalo

Ao longo do tempo e de diversos estudos constatou-se que o encefálo é dividido em dois hemisférios: um direito e um esquerdo (HALL; GUYTON, 2011). Esses hemisférios funcionam de forma distintas, no entanto, existe entre eles uma comunicação. Anatomicamente, cada hemisfério aparenta ser uma imagem do outro, o que pode nos lembrar a assimetria geral do corpo humano. Mas, funcionalmente, o controle de movimento e funções do corpo está dividido entre os hemisférios (MCGILCHRIST, 2022).

Assim, embora os hemisférios sejam anatomicamente semelhante, suas funções e controle são distintos, e é fácil notar isso observando as habilidades das mãos de um sujeito. Poucas pessoas são ambidestras, o que se ver geralmente é uma dominância de um dos hemisférios encefálicos no controle das funções (MCGILCHRIST, 2022).

Ao observar-se as funções de aprendizado, estudos mostram que somente o hemisfério direito atende ao campo de visão periférico do qual tende a surgir novas experiências. Desta forma, apenas o hemisfério direito pode direcionar a atenção para o que nos vem com as novas experiências, independentemente do lado (GALLINA et al., 2022).

É o hemisfério direito que está sintonizado com a apreensão do novo o que faz com que novas experiências causem alterações no hipocampo direito, o que não é visto no esquerdo (MCGILCHRIST, 2022). Essa diferença é generalizada em todos os domínios, inclusive no aprendizado de novas informações ou novas habilidades que também envolve mais a atenção

do hemisfério direito do que do esquerdo mesmo que a informação seja de natureza verbal (GALLINA et al., 2022).

Uma vez que as habilidades e aprendizado se tornaram familiares para o encéfalo através da prática, elas passam a serem processadas pelo hemisfério esquerdo. O hemisfério esquerdo processa informações já conhecidas e seu processo é preditivo (GALLINA et al., 2022), isso faz com que ele seja eficiente em situações cotidianas e pouco eficiente em situações de aprendizado.

O hemisfério esquerdo é atraído por suas expectativas, assim o hemisfério direito supera o esquerdo sempre que a previsão é difícil porque a situação é nova para o sujeito (MCGILCHRIST, 2022).

O lobo frontal direito é especialmente importante para a flexibilidade do pensamento e aprendizado. Na resolução de problemas, o hemisfério direito apresenta uma série de soluções possíveis, que permanecem em análise enquanto as alternativas são exploradas, já o hemisfério esquerdo pensa em uma única solução que parece melhor se encaixar a partir do que ele já conhece e se apegua a ela (MCGILCHRIST, 2022).

Essa diferença de atuação dos hemisférios não faz de um mais importante que o outro, pois para um funcionamento perfeito do encéfalo é necessário que ambos os hemisférios atuem adequadamente em suas funções e interajam entre si. A interação inter-hemisférica tem importantes funções que não podem ser concluídas da simples análise de suas partes (MCGILCHRIST, 2022).

É um equívoco pensar que a aprendizagem de novas informações é uma função apenas do hemisfério direito (GALLINA et al., 2022). Há muitas evidências de que o hemisfério direito é importante para a aprendizagem, mas isso é apenas parte do processo de aprendizagem. Ambos os hemisférios estão envolvidos de forma importante (GALLINA et al., 2022). O aprendizado depende da comunicação entre os dois hemisférios, a falta de conexão entre os hemisférios de fato prejudica o aprendizado dos indivíduos (MCGILCHRIST, 2022).

Neuroplasticidade

A neuroplasticidade pode ser definida como a capacidade que o encéfalo possui em se reorganizar ou readaptar diante do novo, produzindo assim o aprendizado. As sinapses ou conexões entre os neurônios se modificam durante o processo de aprendizagem, quando há evocação da memória, quando adquirimos novas habilidades (HOLDERRIETH,).

É a partir da neuroplasticidade que ocorre a reorganização da estrutura do encéfalo no processo de aprendizagem. Isso pode ser observado durante o crescimento, em que há um contínuo desenvolvimento e modificação nas conexões entre neurônios e suas conexões, toda vez que se aprende novos conhecimentos ou habilidades, a estrutura do cérebro é modificada (HOLDERRIETH,). Essa conectividade neuronal não é fixa e está em constante modificação que pode ocorrer em resposta a diversas manifestações e estímulos que produzem no encéfalo algo novo ou uma informação nova.

2.1.3 Atividade Encefálica

A atividade eletroencefálica é produzida através da atividade elétrica que ocorre no interior do órgão por meio de células nervosas denominadas neurônios (GAGE, 2022). Há cerca de 86 bilhões de neurônios no encéfalo humano que interagem entre si e desenvolvem por meio dessa interação a atividade eletroencefálica.

Neurônios

Os neurônios são células altamente estimuláveis, que processam e transmitem informação através de sinais eletro-químicos. Dentre suas principais características, podemos citar a capacidade das suas membranas plasmáticas gerarem impulsos nervosos que quando inseridos em uma rede, produzem o que conhecemos como atividade encefálica (GAGE, 2022).

O encéfalo humano é composto por neurônios que ao interagir entre si formam redes neurais que possuem atividade elétrica e química constante (BARACK; KRAKAUER, 2021). Tipicamente, a maioria dos neurônios possuem corpo celular e dois tipos de prolongamentos citoplasmáticos, os dendritos e os axônios como mostrado na Figura 2.4, onde é mostrada a estrutura de um neurônio típico, encontrado no encéfalo.

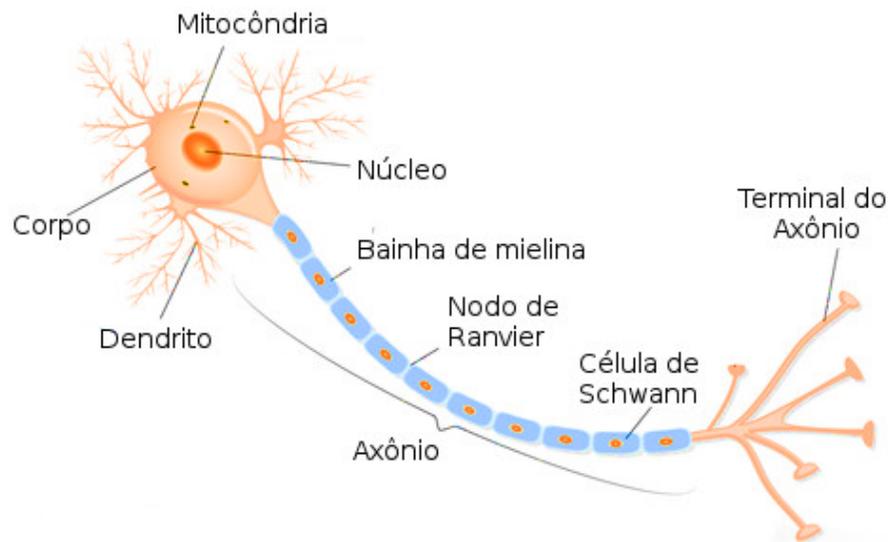


Figura 2.4: Estrutura de um neurônio. Adaptado de (HALL; GUYTON, 2011)

O corpo celular de um neurônio, contém o núcleo e a maior parte das organelas. É nesta parte onde ocorre a síntese proteica; os dendritos são prolongamentos finos, geralmente ramificados, que recebem e conduzem os estímulos provenientes de outros neurônios ou de células sensoriais (HALL; GUYTON, 2011).

O axônio, é responsável por transmitir os impulsos para fora do corpo celular. Eles apresentam uma estrutura cilíndrica que pode medir até um metro de comprimento, terminando sobre outros neurônios ou órgãos efetores por meio de pequenos ramos (GAGE, 2022).

A atividade entre os neurônios é conhecida como sinapses, elas compõem as diversas redes neurais e vão se tornando mais bem estabelecidas e complexas na medida em que o sujeito interage com o meio ambiente interno e externo, produzindo o que conhecemos como aprendizagem (HALL; GUYTON, 2011).

Além dos neurônios, o sistema nervoso é composto por células da glia, que possuem funções importantes funcionando como suporte físico aos neurônios e auxiliando nas ligações durante o desenvolvimento embrionário. Boa parte das células gliais fornecem nutrientes aos neurônios enquanto outras consomem partículas estranhas e resíduos celulares, outra função dessas células, é a manutenção dos níveis iônicos em volta dos neurônios (HALL; GUYTON, 2011).

Essas células, neurônios e células da glia, compõem o tecido nervoso que é a base de construção do encéfalo. É a partir da atividade eletroquímica que ocorre a nível celular que a atividade eletroencefálica passa a existir, através dos potenciais existentes a nível celular. Essa atividade eletroencefálica pode ser captada por meio de imagens da atividade encefálica, neste trabalho utilizamos o eletrocardiograma como exame de captação da imagem da atividade encefálica.

Eletroencefalograma (EEG)

A atividade elétrica do encéfalo pode ser medida por eletrodos colocados no couro cabeludo, como mostrado na Figura 2.5, onde é mostrado o sistema de eletrodos 10-20, uma das várias organizações de eletrodos que pode ser utilizada na captação dos sinais de eletroencefalograma.

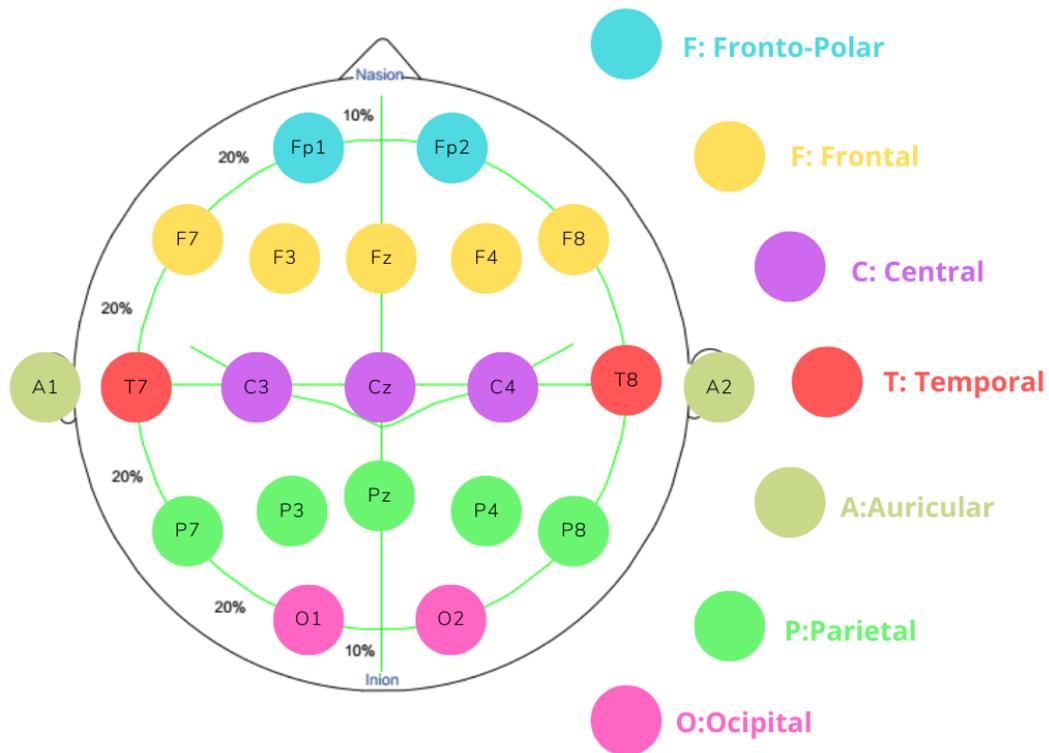


Figura 2.5: Representação do sistema internacional 10-20. Adaptado de (HALL; GUYTON, 2011)

Naturalmente o sistema 10-20 utiliza 21 eletrodos que são colocados em locais específicos do crânio, mas esse número pode ser aumentado intercalando-se novos eletrodos entre os pontos utilizados normalmente. A colocação desses eletrodos tem como objetivo cobrir todas as áreas do escalpo: frontopolar, parietal, temporal, central e occipital.

A nomenclatura dos eletrodos também é onde os eletrodos situados na linha média recebem a denominação "z". E seus nomes estão relacionados ao lóbulo ou área na qual o eletrodo está posicionado: F - frontal, Fp - frontal polar, T - temporal, C-central, P - parietal, O - occipital, A - auricular. Os eletrodos de números pares estão situados à direita e os ímpares estão situados à esquerda e cada eletrodo recebe um número e uma letra correspondente à área anatômica subjacente (BAŞAR et al., 2013). Por exemplo: eletrodo F8 - frontal direito.

As ondas eletromagnéticas emitidas pelo funcionamento encefálico e captadas pelo EEG possuem diversas características importantes, dentre essas características destacam-se cinco grandes ondas cerebrais distintas (LI et al., 2022). Essas ondas são caracterizadas por suas diferentes faixas de frequência e são chamadas de onda alfa (α), theta (θ), beta (β), delta (δ) e gama (γ). As frequências de cada onda podem ser observadas na Tabela 2.1.3:

Tabela 2.1: Classificação das frequências encefálicas (LI et al., 2022)

Tipo	Frequência (Hz)
Delta (δ)	<3.5
Theta (θ)	04 a 07
Alfa (α)	08 a 13
Beta (β)	14 a 25
Gama (γ)	40

Assim, a partir da captações dessas ondas eletromagnéticas pelos sistemas de captação como o 10x20, é criada uma imagem do funcionamento encefálico durante o período de captação, essa imagem é semelhante à mostrada na Figura 2.6. Na Figura 2.6 retirada de (FüRBASS, 2017) mostra em A uma imagem de um EEG sem nenhum tipo de filtragem, logo após a captação. Em B, é mostrado um EEG após um processo de filtragem aplicado. Em ambas as situações vemos o sinal de EEG organizado por cada um dos sinais captados por cada eletrodo.



Figura 2.6: Exemplo de EEG normal. Retirado de (FüRBASS, 2017)

2.1.4 Estimação de fontes encefálicas

A estimação de fontes encefálicas é uma técnica utilizada na localização da região cerebral responsável por emitir um sinal de EEG, esta técnica tem aplicações significativas e variadas, como aplicações médicas e clínicas. Dentre essas aplicações, algumas de grande relevância podem ser citadas, como o uso do algoritmo de localização de fontes encefálicas em hospitais para ajudar cirurgiões e médicos a operar pacientes com distúrbios cerebrais, com a localização de zonas epileptogênicas para pacientes com epilepsia, localização do tumor e localização das áreas afetadas por outros distúrbios cerebrais (ILMONIEMI, 1993).

Estimar a fonte de um sinal é localizar quem está gerando esse sinal, assim, quando se trata da estimação de fontes cerebrais, significa localizar qual região do cérebro está emitindo o sinal elétrico, logo a relação que existe na estimação é entre o sinal captado nos sensores colocados na superfície da cabeça e o sinal gerado (ou a fonte geradora).

As estimativas de fontes cerebrais em tempo real podem ser usadas para melhorar previsões das intenções do sujeito em comparação com previsões baseadas em sensores em aplicações envolvendo o cérebro e interfaces homem-máquina e neurofeedback (ILMONIEMI, 1993).

Quando se trabalha com EEG, a topografia do couro cabeludo pode ser feita pelo arranjo de correntes no cérebro, neste caso é necessário resolver um problema chamado problema inverso em que não há somente uma resposta para a fonte emissora, pois diferentes conjuntos de fontes de corrente neural levam ao campo elétrico analisado (ILMONIEMI, 1993).

Quando se trabalha com outros tipos de imagem cerebral, conhece-se o campo magnético, ou seja, o comportamento das correntes no cérebro, e deseja-se descobrir a forma dessas correntes, ou seja, os dados adquiridos no EEG (ILMONIEMI, 1993).

A partir desta técnica é possível também conhecer o comportamento elétrico do encéfalo que está associado a execução de determinadas tarefas. Quando aplicada aos sinais de EEG, a estimação de fontes encefálicas pode ser feita pelo arranjo de correntes no cérebro, neste caso é necessário resolver um problema chamado problema inverso (JATOI; KAMEL, 2018).

Na solução do problema inverso, não há somente uma resposta para a fonte emissora, pois diferentes conjuntos de fontes de corrente neural levam ao campo elétrico analisado (JATOI; KAMEL, 2018). Quando se trabalha com outros tipos de imagem cerebral, conhece-se o campo magnético, ou seja, o comportamento das correntes no cérebro, e deseja-se descobrir a forma dessas correntes, ou seja, os dados adquiridos no EEG (ILMONIEMI, 1993).

- Problema Direto (*Forward problem*): é o problema que consiste na predição do potencial elétrico ou vetor de campo magnético que seria medido externamente nos sensores se alguma fonte estivesse ativa dentro do cérebro (ILMONIEMI, 1993). Uma quase aproximação das equações de Maxwell é usada para resolver o problema direto apenas para modelos de cabeça simples (normalmente consistindo em uma ou mais esferas) e o perfil de condutividade (ILMONIEMI, 1993). No problema direto, se conhece a região da cabeça que gera o sinal e deseja-se descobrir os dados de EEG registrados a partir delas.
- Problema inverso: consiste no problema de estimar a densidade de corrente ou valores de atividade da fonte que gerou um potencial elétrico medido ou vetor de campo magnético (ILMONIEMI, 1993). No método de solução do problema inverso, pode-se utilizar o modelo de fonte dipolo, onde as fontes são consideradas como vários dipolos magnéticos discretos, localizados em certos lugares em um espaço tridimensional dentro do cérebro (ILMONIEMI, 1993). No problema inverso, conhece-se os sinais de EEG registrados, e deseja-se descobrir quais regiões do cérebro são responsáveis por gerar esse sinal.

Neste trabalho é aplicada a solução do problema inverso, uma vez que possuímos os potênciais elétricos (EEG) e desejamos saber as fontes dos potênciais. O fluxo de trabalho das duas soluções dos problemas de estimação de fontes encefálicas podem ser observadas na Figura 2.7.

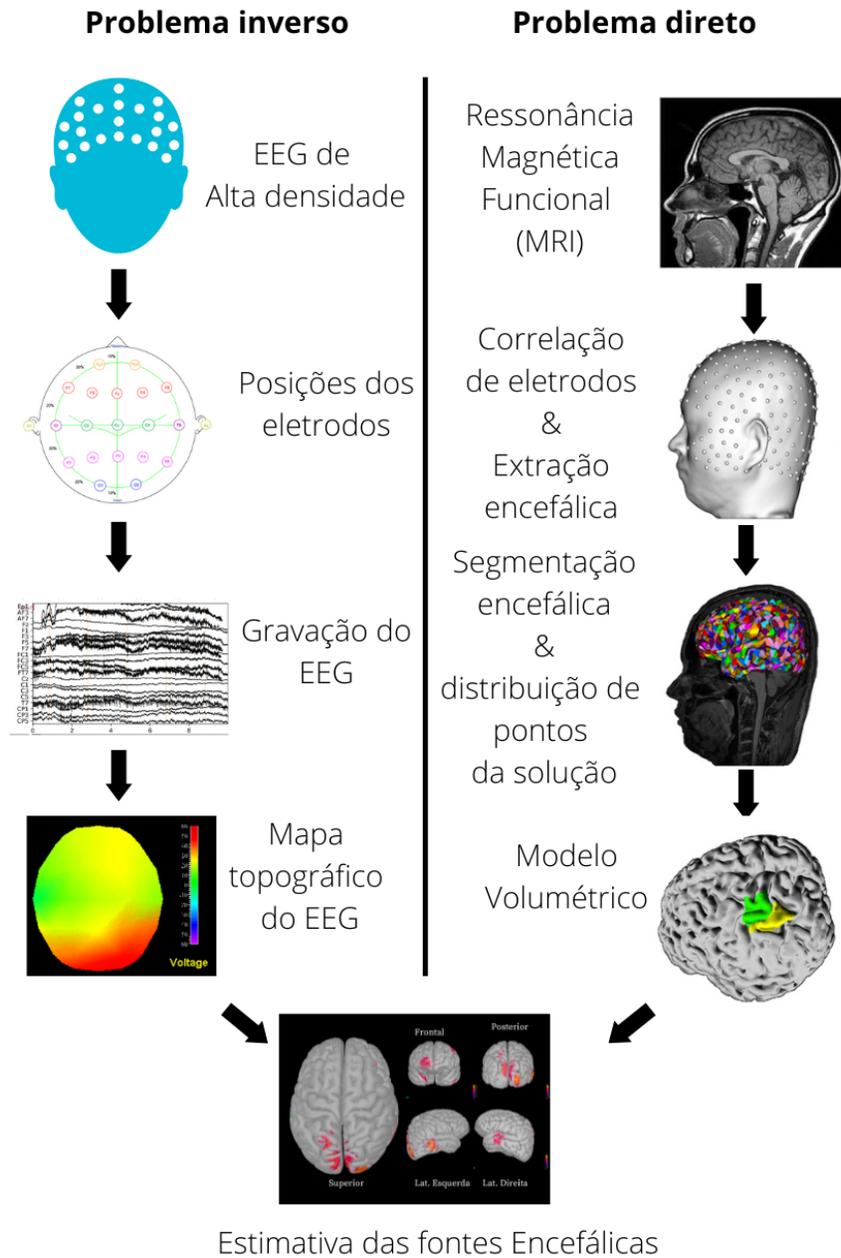


Figura 2.7: Soluções para o problema de estimação de fontes encefálicas, no lado direito a solução do problema inverso e do lado direito a solução do problema direto. Imagem feita pelo autor.

Entre os principais métodos, baseados em espaço de origens para resolver o problema inverso, que é o problema resolvido neste trabalho, temos o *sLORETA* (JATOI; KAMEL, 2018), apresentado a seguir.

sLORETA

O *sLORETA* é uma versão avançada da técnica LORETA, que consiste em uma técnica de imagem distribuída em baixa resolução para a localização da fonte cerebral e fornece uma localização suave da fonte, mas com resolução espacial baixa e imagens localizadas borradas de uma fonte pontual com dispersão na imagem (JATOI; KAMEL, 2018).

O *sLORETA* é um método de solução do problema inverso que se baseia na variância dos ruídos de medições do EEG e na variância do próprio sinal biológico. Nele, a variância do sinal biológico é considerada uniformemente distribuída através do cérebro, o que faz com que esta metodologia tenha um erro nulo de localização das fontes cerebrais.(JATOI; KAMEL, 2018).

Matematicamente, o *sLORETA* é dado pelo funcional da eq. 2.1 (JATOI; KAMEL, 2018):

$$F = \|\varphi - KJ - c1\|^2 + \alpha\|J\| \quad (2.1)$$

sendo φ é o potencial elétrico medido na superfície da cabeça pelos eletrodos. K é a matriz de vetores associados às fontes, J é a densidade de corrente, α é um parâmetro de regularização e $c1$ uma constante. F precisa ser minimizado em relação a J e $c1$ para dados K , φ e α . Desta forma, se utilizarmos as referências de transformação média de φ e K , podemos reescrever a eq. 2.1 como na eq. 2.2

$$F = \|\varphi - KJ\|^2 + \alpha\|J\| \quad (2.2)$$

sendo \hat{J} corresponde a densidade de corrente no espaço de fontes e é igual a $T\varphi$, onde $T = K^T[KK^T + \alpha H]^+$. Assim, o valor de \hat{J} deve ser estimado, e a variação do potencial elétrico pode ser definida como na eq. 2.3

$$S_j = K^T[KK^T + \alpha H]^+ K \quad (2.3)$$

Assim, o método *sLORETA* é dado por 2.4

$$\sigma_V = [S_j]_V^{-\frac{1}{2}} \hat{j}_V \quad (2.4)$$

sendo $[S_j]_V \in \mathfrak{R}^{3 \times 3}$ é a matriz diagonal de S_j com ordem 3×3 e $[S_j]_V^{-\frac{1}{2}}$ é o inverso da raiz quadrada simétrica. Por fim a norma quadrada de σ_V pode ser padronizada como na eq. 2.5 e corresponde à estimativa da potência da densidade de corrente (JATOI; KAMEL, 2018).

$$\sigma_V^T \sigma_V = j_V^T [S_j]_V^{-1} \hat{j}_V \quad (2.5)$$

Neste trabalho utilizou-se o software *Brainstorm* para a estimação das fontes encefálicas, e a partir dessas fontes estimadas, faz-se necessário conhecer a anatomia do cérebro para determinar em qual região anatômica a fonte cerebral relacionada ao evento do jogo se encontra, para isso utilizou-se o atlas anatômico do cérebro humano Mindboggle (KLEIN et al., 2017), com 14.125 vértices, e está apresentado a seguir.

Atlas Mindboggle

No software *Brainstorm* se faz necessário o uso de um atlas anatômico para determinação das regiões encefálicas associadas a cada evento estudado, para isso, optou-se pelo atlas Mindboggle. De acordo com o atlas de Mindboggle o cérebro humano apresenta a morfometria de dados pré-processados de volume de saída, superfície e dados tabulares contendo informações de rótulo,

recurso e forma para análise posterior (KLEIN et al., 2017). A Definição de cada região do cérebro de acordo com o atlas é mostrada na Figura 2.8.

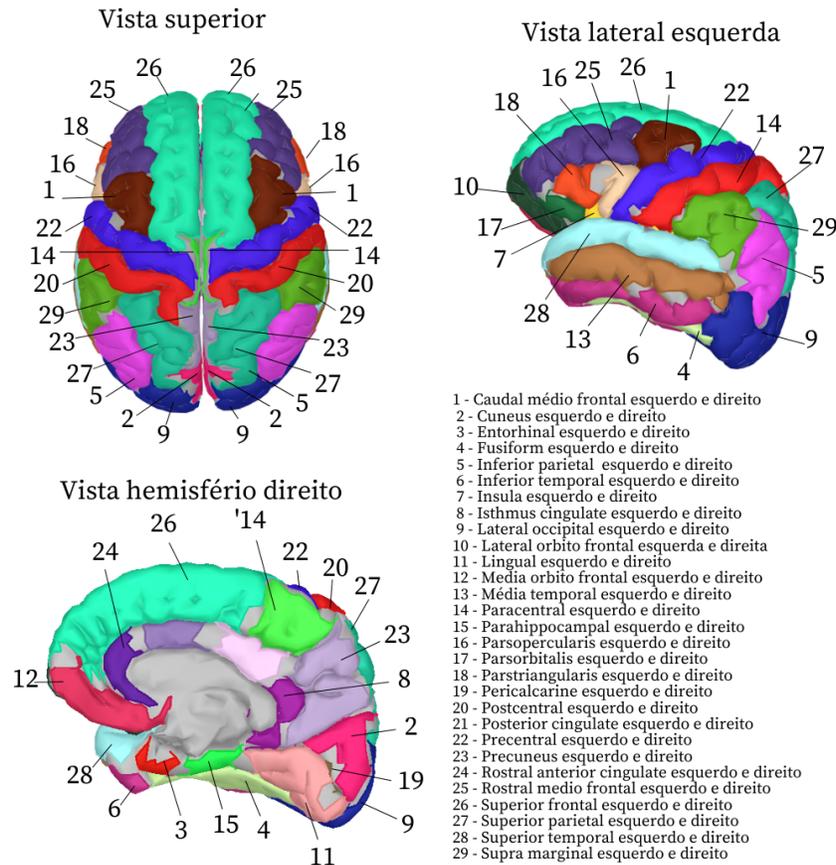


Figura 2.8: Regiões anatômicas do atlas Mindboggle. Adaptada de (KLEIN et al., 2017).

De acordo com o atlas de Mindboggle o cérebro humano apresenta a morfometria de dados pré-processados de volume de saída, superfície e dados tabulares contendo informações de rótulo, recurso e forma para análise posterior (KLEIN et al., 2017).

2.2 Aprendizado de Máquinas e os Classificadores Utilizados

O Aprendizado de Máquina (AM) é uma das áreas que compõem a Inteligência Artificial. O principal objetivo do AM é desenvolver modelos e mecanismos que sejam capazes de extrair conhecimento a partir de dados.

Partindo do princípio de que as máquinas podem aprender sozinhas quando são submetidas a uma grande quantidade de dados, o AM considera principalmente o fato de que os dispositivos conseguem detectar padrões e informações nos dados analisados, utilizando para isso diversos modelos de AM.

Os algoritmos de AM realizam análises estatísticas nos dados recebidos, gerando respostas e previsões delicadas, o que faz com que os algoritmos se tornem inteligentes por suas previsões. O que mais se destaca no AM é o fato de que os algoritmos de classificação não necessitam de reprogramação periódica para que aprendam e melhorem seu desempenho.

Dentre as vantagens do AM ressaltamos a alta precisão dos modelos quando treinados, possibilitando que um alto volume de dados seja analisado com maior certeza, assim é viável criar algoritmos eficazes que possam fazer previsões de cenário, livres dos erros provocados por fator humano.

Quando se trata da aplicação de modelos de AM na análise de sinais de EEG, diversos estudos já aplicam modelos e verificam ótimos resultados, como em (HAFEEZ et al., 2021; CHEAH et al., 2020; PAWAR; DHAGE, 2020; GAERTNER et al., 2021), o que nos motiva mais ainda à aplicação dos modelos de AM neste trabalho.

Neste capítulo, realizaremos uma breve exposição do conceito de AM, e apresentaremos detalhadamente os cinco modelos selecionados, apresentando seu funcionamento e a lógica de cada um deles.

2.2.1 Aprendizado de Máquinas (AM)

O Aprendizado de Máquina (AM) é uma área da Inteligência Artificial (IA) cujo principal objetivo é o desenvolvimento de técnicas e modelos computacionais, bem como a construção de sistemas capazes de adquirir conhecimento de forma automática. De forma que os sistemas desenvolvidos sejam capazes de tomar decisões baseado em experiências acumuladas através da solução bem sucedida de problemas anteriores (MAHESH, 2020).

No AM utiliza-se o método de indução como forma de inferência lógica que permite obter conclusões lógicas genéricas sobre um conjunto particular de dados. A indução pode ser caracterizada como o raciocínio que se origina em um conceito específico e o generaliza, ou seja, da parte para o todo (MAHESH, 2020). A partir desse papel do AM na predição de eventos, é possível observar que o AM tem sido cada vez mais utilizado com sucesso em diversas áreas do conhecimento que fazem uso de computadores, seja para a classificação e reconhecimento de padrões, controle, jogos, entre outras áreas (MAHESH, 2020).

De acordo com (BRUCE; BRUCE, 2019), o aprendizado indutivo pode ser dividido em supervisionado, não-supervisionado e por reforço. Neste trabalho o aprendizado aplicado é o supervisionado, nele é fornecido ao algoritmo de aprendizado um conjunto de exemplos de treinamento para os quais o rótulo da classe associada é conhecido.

De forma geral, no aprendizado supervisionado, cada exemplo é descrito por um vetor de valores de características, ou atributos, e o rótulo da classe associada. O objetivo é construir um classificador que possa determinar corretamente a classe de novos exemplos ainda não rotulados, ou seja, exemplos que não seja conhecido o rótulo da classe. Segundo (BRUCE; BRUCE, 2019), no aprendizado supervisionado nota-se a figura de um treinador ou instrutor externo, que apresenta o conhecimento do ambiente por conjuntos de exemplos na forma: entrada, saída desejada.

O objetivo final do aprendizado supervisionado é que o modelo computacional seja capaz de classificar, a partir de um vetor de características, os dados analisados como pertencentes a um rótulo previamente aprendido. O algoritmo de aprendizado de máquina aprende a agrupar as entradas submetidas segundo uma medida de qualidade (BRUCE; BRUCE, 2019). Essas técnicas são aplicadas geralmente quando se deseja encontrar padrões de ocorrência em dados. Como citado, neste trabalho utilizaremos aprendizado supervisionado, visando identificar (classificar) atividades cognitivas a partir da atividade eletroencefálica.

2.2.2 Classificadores Utilizados

Existem diversos modelos classificadores baseados em AM, dentre eles alguns se destacam pelo seu amplo uso e aplicação em diversas situações. Ao buscar por modelos classificadores que pudessem servir nesta pesquisa, para classificação de atividades eletroencefálica, foram eleitos cinco modelos: Random Forest Classifier; K-Nearest Neighbors(KNN); Linear Discriminant Analysis(LDA); Decision Tree Classifier; Support Vector Machines (SVM).

Random Forest Classifier

O algoritmo Random Forest trata-se de um algoritmo que constrói árvores de decisão e deixa que essas árvores escolham como classificar as entradas (BRUCE; BRUCE, 2019). Essas árvores são estruturas de dados que permitem a tomada de decisão considerando questionamentos com respostas sim/não, que podem ser utilizada para regressão e classificação (CUTLER; CUTLER; STEVENS, 2012).

Matematicamente, para um vetor de variáveis aleatórias $X = (X_1, X_2, \dots, X_n)^T$, que é a entrada do algoritmo composta de variáveis preditoras de valor real, e uma variável aleatória Y , representando a resposta também de valor real, o algoritmo assume uma distribuição conjunta $P_{XY}(X, Y)$ desconhecida (CUTLER; CUTLER; STEVENS, 2012).

O objetivo do Random Forest, é então, encontrar uma função de previsão $f(X)$, que seja capaz de prever Y . Essa função de previsão será determinada por uma função de perda $L(Y, f(X))$, que é definida para minimizar o valor esperado da perda (CUTLER; CUTLER; STEVENS, 2012):

$$E_{XY}(L(Y, f(X))) \quad (2.6)$$

Em outras palavras, segundo (CHEAH et al., 2020), $L(Y, f(X))$ será uma medida do quão próximo $f(X)$ está de Y . De modo que os valores escolhidos para L será a função de perda ao quadrado quando o algoritmo estiver realizando a regressão, $L(Y, f(X)) = (Y - f(X))^2$, e a função de perda L zero-um para classificação

$$L(Y, f(X)) = 1(Y \neq f(X)) = \begin{cases} 0, & \text{se } Y = f(X) \\ 1, & \text{c.c.} \end{cases} \quad (2.7)$$

Na tentativa de minimização de $E_{XY}(L(Y, f(X)))$, ocorre o surgimento da expectativa do surgimento da equação 2.8 que é conhecida como a função de regressão

$$f(X) = E(Y|X = x) \quad (2.8)$$

Quando se trata da classificação, se o conjunto de soluções Y é chamado de γ , ao minimizarmos a função $E_{XY}(L(Y, f(X)))$ na função zero-um, encontraremos a regra de *Bayes* dada pela equação 2.9

$$f(x) = \operatorname{argmax} P(Y = y|X = x). \quad (2.9)$$

Assim, segundo (CUTLER; CUTLER; STEVENS, 2012), na regressão o algoritmo constrói f em termos de um conjunto chamado “aprendizes de base”, $h_1(x), h_2(x), \dots, h_j(x)$. Esses aprendizes de base são então combinados entre si para gerar o que chamamos de “conjunto preditor” $f(x)$. A média de aprendizes de base é calculada pela função mostrada na equação 2.10

$$f(x) = \frac{1}{J} \sum_{j=1}^J h_j(x), \quad (2.10)$$

enquanto na classificação, Y será a classe mais prevista na “votação” realizada pela árvore de decisão, dada pela equação 2.11

$$f(x) = \underset{y \in \gamma}{\operatorname{argmax}} \sum_{j=1}^J I(y = h_j(x)). \quad (2.11)$$

Assim, o j -ésimo aprendiz de base será uma árvore denotada por $h_j(X, \Theta_j)$ onde Θ_j será um conjunto de variáveis aleatórias independentes para $j = 1, \dots, J$. Depois que um número grande de árvores de decisão é gerado, essas árvores “votam” na classe mais popular para o registro que está sendo classificado (BREIMAN, 2001). Na Figura 2.9 pode-se observar o funcionamento do algoritmo random forest de acordo com o exposto.

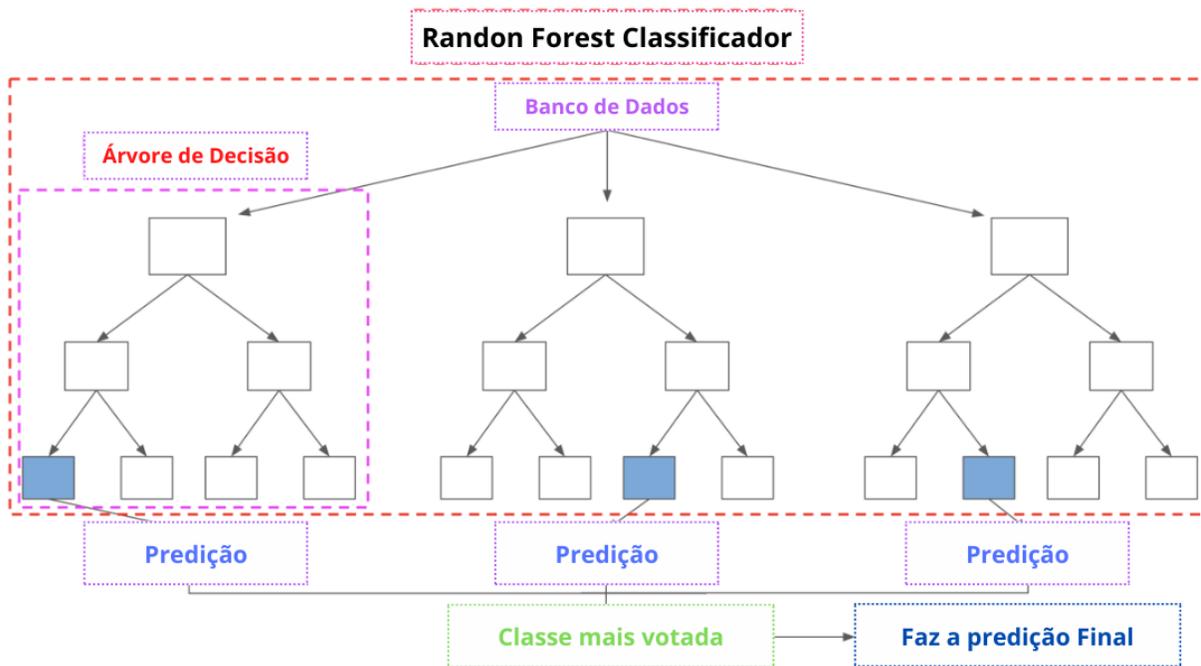


Figura 2.9: Como funciona o algoritmo Random Forest Classifier. Baseado em (BREIMAN, 2001)

K-Nearest Neighbors(KNN)

O algoritmo KNN é um dos mais simples no AM, é sempre uma das melhores escolhas em estudos onde tem-se pouco ou nenhum conhecimento dos dados. Indicado pela literatura como um dos métodos de classificação mais simples e fundamentais de classificação, o algoritmo K-Nearest Neighbors(KNN) tem as seguintes ideias para classificação de registro segundo (BRUCE; BRUCE, 2019) [35]:

- O algoritmo deve encontrar K registros que tenham características similares (ou seja, valores preditivos semelhantes);

- Para classificação: o algoritmo descobrirá qual a classe majoritária entre os registros semelhantes e atribuirá essa classe ao registro que está classificando;
- Para regressão: o algoritmo encontrará a média entre os registros semelhantes e preverá tal média para o registro que está analisando.

Segundo (PETERSON, 2009), o algoritmo KNN pode ser dividido em etapas: Inicialmente realiza-se a distância geométrica entre as amostras, seguida da aplicação da regra de decisão e matriz de confusão.

- **Distância Geométrica Entre as Amostras:**

O KNN geralmente se baseia na distância euclidiana entre as amostras de teste e as amostras de treinamento especificadas (PETERSON, 2009). Dado uma amostra de entrada x_i com p características $(x_{i1}, x_{i2}, \dots, x_{ip})$ com n número de amostras, $(i = 1, 2, \dots, n)$ e p o número total de características $(j = 1, 2, \dots, p)$. A distância euclidiana entre as amostras x_i e x_l pode ser definida como na equação 2.12

$$d(x_i, x_l) = \sqrt{(x_{i1} - x_{l1})^2 + (x_{i2} - x_{l2})^2 + \dots + (x_{ip} - x_{lp})^2} \quad (2.12)$$

Na Figura 2.10 está apresentada uma descrição gráfica apresentada por (PETERSON, 2009) do conceito aplicado no algoritmo KNN, o conceito é ilustrado por Voronoi Tessellation (Voronoi, 1907). A figura mostra 19 amostras que são marcadas com "+", e a célula de Voronoi, R , circula cada amostra. A célula de Voronoi coloca todos os KNN vizinhos dentro de um mesmo ponto, e a equação que define esta célula é definida como na equação 2.13

$$R_i = \{x \in \mathbb{R}^p : d(x, x_i) \leq d(x, x_m), \forall i \neq m\}, \quad (2.13)$$

onde R_i representa o agrupamento de Voronoi para a amostra x_i , e x é todos os pontos possíveis para x_i dentro do espaço de agrupamento de Voronoi R_i .

Resumidamente, a distância euclidiana no algoritmo KNN serve para identificar que todos os pontos possíveis dentro do agrupamento de Voronoi de uma amostra são os vizinhos mais próximos dessa amostra e para identificar que para qualquer amostra, a amostra mais próxima é determinada pela borda do agrupamento de Voronoi mais próximo (PETERSON, 2009). Em outras palavras, a regra de classificação do k-vizinho mais próximo consiste em atribuir a uma amostra de teste o rótulo da categoria majoritária de suas k amostras de treinamento mais próximas (BRUCE; BRUCE, 2019). Na prática, k geralmente é escolhido como ímpar, para evitar empates.

- **Regra de decisão de classificação e matriz de confusão**

No algoritmo KNN a classificação envolve o particionamento em categorias de treinamento e teste. Na amostra de treinamento x_i eu tenho uma categoria conhecida ω , na amostra de teste x temos uma categoria desconhecida que será predita pelo KNN $\hat{\omega}$, de forma que teremos um conjunto solução dado por $(\omega, \hat{\omega} = 1, 2, \dots, \Omega)$ onde Ω é o número total de classes (PETERSON, 2009).

Assim, no KNN, para k vizinhos mais próximos, a classe prevista da amostra de teste x é igual à classe verdadeira $\hat{\omega}$ mais frequente entre k amostras de treinamento mais próximas. Isso forma a regra de decisão mostrada na equação 2.14

$$D : x \rightarrow \hat{\omega}. \quad (2.14)$$

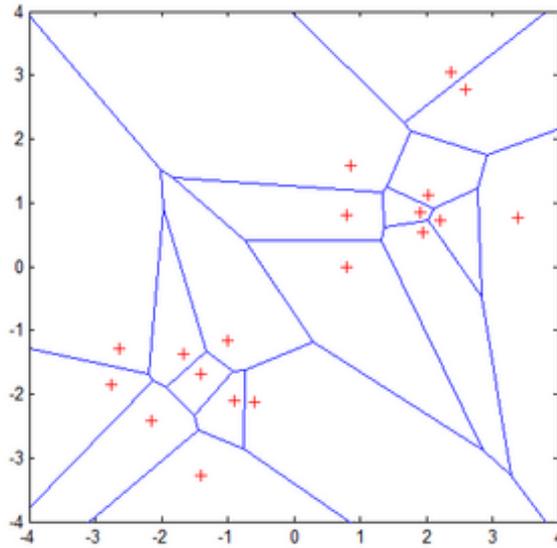


Figura 2.10: Agrupamento de Voronoi. Retirado de (PETERSON, 2009)

A partir dessa decisão, o KNN utiliza a matriz de confusão para tabular as previsões de classe da amostra de teste durante o teste. Neste caso essa matriz é denotada por C e terá dimensão $\Omega \times \Omega$, durante o teste, se $\hat{\omega} = \omega$ então o elemento $c_{\omega\hat{\omega}}$ será incrementado em 1, mas, se a predição estiver incorreta, então o elemento fora da diagonal da matriz será incrementado em 1 (PETERSON, 2009). Tendo sido todas as amostras classificadas, a precisão da classificação do KNN será dada pela equação 2.15

$$A_{cc} = \frac{\sum_{\omega} c_{\omega\omega}}{n_{total}} \quad (2.15)$$

nesta equação, $c_{\omega\omega}$ é um elemento da diagonal de C e n_{total} é o número de amostras classificadas.

Linear Discriminant Analysis (LDA)

O modelo LDA é um dos modelos mais populares que apresentam classificação binária, podendo também ser aplicado na fase de pré-processamento de dados para diminuir significativamente o custo de computação. No LDA algumas suposições são realizadas antes da classificação segundo (XANTHOPOULOS; PARDALOS; TRAFALIS, 2013):

- Pressupõe que os dados sejam distribuídos normalmente, ou seja, os dados de cada classe deve fazer uma curva em forma de sino.
- Cada classe tem matriz de covariância idênticas.

Aplicando LDA em um conjunto de dados que consiste em n amostras $(x_i, y_i)_{i=1}^n$ onde $x_i \in \mathbb{R}^d$ e $y_i \in 1, 2, \dots, k$ é o rótulo da classe da i -ésima amostra, d é a dimensionalidade dos dados, e k é o número de classes existentes. Tomando a matriz de dados $X = [x_1, x_2, \dots, x_n]$ e particionando ela em k classes, por exemplo $X = [X_1, \dots, X_k]$, onde $X_i \in \mathbb{R}^{d \times n_i}$, onde n_i é o tamanho da i -ésima classe X_i e $\sum_{i=1}^k n_i = n$ (YE, 2007).

O LDA clássico calcula uma transformação linear $G \in \mathbb{R}^{d \times l}$ que faz o mapeamento de x_i no espaço dimensional para um vetor x_i^L no espaço l -dimensional: $G : x_i \in \mathbb{R}^d \rightarrow x_i^L = G^T x_i \in \mathbb{R}^l$ ($l < d$) (YE, 2007).

(FUKUNAGA, 1990) define três matrizes de dispersão que são associadas à análise discriminante, chamadas de matriz de dispersão intra-classe; entre classe e dispersão total, definidas como nas equações 2.16 2.17 e 2.18, respectivamente

$$S_w = \frac{1}{n} \sum_{i=1}^k \sum_{x \in X_i} (x - c^{(i)})(x - c^{(i)})^T \quad (2.16)$$

$$S_b = \frac{1}{n} \sum_{i=1}^k n_i (c^{(i)} - c)(c^{(i)} - c)^T \quad (2.17)$$

$$S_t = \frac{1}{n} \sum_{j=1}^n (x_j - c)(x_j - c)^T, \quad (2.18)$$

onde c_i é o centróide da i -ésima classe e c é o centróide global.

Decision Tree Classifier

Um dos algoritmos de Aprendizado de Máquinas que mais se destaca visualmente porque o aspecto visual do algoritmo é similar a um fluxograma, com etapas bem definidas e facilmente perceptível (SAFAVIAN; LANDGREBE, 1991). As árvores de decisão são utilizadas no aprendizado de máquinas tanto para classificação e para regressão.

Sua estrutura é semelhante a de uma árvore, como o próprio nome sugere, Decision Tree que traduzindo para o português é Árvore de Decisão, estabelece nós que se relacionam entre si como as estruturas que compõem uma árvore, formando uma hierarquia. Essa hierarquia é formada pelos nós, onde existe um *nó-raiz*, representando o *nó* mais importante na árvore de decisão e um *nó-folha*, que representam os resultados finais (SAFAVIAN; LANDGREBE, 1991).

Nas árvores de decisão são empregados ganho de informação quando os dados passam pelos nós na fase de testes. Seja S um conjunto qualquer de objetos, $|S|$ que possuem o rótulo C_j , a quantidade média de informação necessária para identificar o rótulo de um objeto em S é dada pela equação 2.19, que também é conhecida como a entropia do conjunto S (DU; ZHAN, 2002):

$$info(S) = -\sum_{j=1}^k \frac{freq(C_j, S)}{S} \cdot \log_2 \frac{(C_j, S)}{|S|}. \quad (2.19)$$

A partir desse ganho, todo o algoritmo da árvore de decisão é estruturado, o algoritmo irá utilizar a recursão para aprendizagem, e entre seus atrativos, podemos citar sua boa performance em classificação multiclasse, quando há diversos rótulos (DU; ZHAN, 2002).

Support Vector Machines (SVM)

O SVM é um modelo baseado em AM muito utilizado na execução de tarefas de aprendizado de máquina, principalmente para classificação ou regressão. Seu treino requer a solução de um problema de complexidade para a programação (SWEILAM; THARWAT; MONIEM, 2010).

Dentre as suas principais características, podemos ressaltar sua robustez e convexidade da função objetivo, uma vez que o SVM se baseia em uma função quadrática (SWEILAM; THARWAT; MONIEM, 2010).

O método de aprendizagem computacional baseado em vetores de suporte é fundamentado, inicialmente, em se obter uma função capaz de separar duas classes. Esta função deve ter boa generalização, ou seja, deve ter um bom desempenho na separação de exemplos não vistos (LORENA; CARVAHO, 2003; TAKAHASHI, 2012; RUFINO, 2011; FILHO, 2010).

O SVM é um algoritmo de classificação que utiliza aprendizado supervisionado, onde o hiperplano, é orientado de maneira que esteja o mais longe possível dos dados mais próximos. Esses hiperplanos criados são chamados de vetores de suporte (HUANG et al., 2018). Desta forma, o hiperplano ideal pode ser definido como aquele que separa os dados e maximiza a margem (HUANG et al., 2018). Segundo (HUANG et al., 2018) se tomarmos X como um conjunto de dados com n objetos x_i , seus rótulos ii e X como espaço de entrada, a equação do hiperplano, um hiperplano α é dado por:

$$\alpha : \{x | w^T x = b\}, \quad (2.20)$$

em que a constante real b determina o deslocamento do hiperplano a partir da origem.

Em se tratando de um conjunto de amostras existirem vários hiperplanos de separação, é necessário encontrar o hiperplano que seja capaz de separar os padrões de tal forma que a distância entre o mesmo e o ponto mais próximo de uma classe (margem) seja maximizada (HUANG et al., 2018). É possível dizer que, para um problema de classificação binária, uma classe são todos os pontos x que satisfazem $w^T x \geq b$ ou $w^T x \leq b$.

• Função Kernel

Em alguns casos, quando se utiliza o SVM, não é possível separar de forma adequada os padrões do conjunto de treinamento através de um hiperplano. Neste caso, a solução para esse problema é realizar um mapeamento utilizando uma função kernel. Um kernel é uma função $k : S_{(\mathbf{x}_i, \mathbf{x}_j)} \rightarrow \Omega_{\varphi^T(\mathbf{x}_i)\varphi(\mathbf{x}_j)}$, que é representado da seguinte forma (TAKAHASHI, 2012):

$$k(x_i, x_j) = \varphi^T(\mathbf{x}_i)\varphi(\mathbf{x}_j) \quad (2.21)$$

Segundo (SOUSA et al., 2019), os kernels mais utilizados são os polinomiais, os gaussianos e os sigmoidais. Na Tabela 2.2 apresentada por (SOUSA et al., 2019) está mostrado os kernels especificados pelo usuário.

Tabela 2.2: Principais Kernels. Retirado de (SOUSA et al., 2019)

Kernel	Função	Parâmetros
Polinomial	$[a(x_i x_j + k)]^d$	a, k e d
Gaussiano ou RBF	$e^{-\sigma x_i - x_j ^2}$	σ
Sigmoidal	$\tanh[a(x_i x_j + k)]$	a e k

Aplicando-se os Kernels apresentados na Tabela 2.2, é possível realizar o mapeamento de dados não linearmente separáveis, porque são funções não lineares (SOUSA et al., 2019). Essas funções transformam o espaço original em um espaço de característica no qual a separabilidade dos dados é mais evidente.

Transformação de Características

É muito comum utilizarem transformação de características para maximizar o desempenho de um classificador (PETERSON, 2009). Existem diversas maneiras de realizar essa transformação, dentre elas a padronização. A padronização realiza a remoção dos efeitos de escala causados pelo uso de recursos com diferentes escalas de medição.

Neste trabalho, antes de realizar a classificação, o vetor de características é padronizado. Segundo (PETERSON, 2009), para realizar a padronização das características de entrada dos classificadores, utiliza-se a transformação dos valores brutos da característica em *z-scores* usando a média e o desvio padrão dos valores de uma característica em todas as amostras de entrada, fornecidas pela relação mostrada na equação 2.22

$$z_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j}, \quad (2.22)$$

onde x_{ij} é o valor para a i -ésima amostra e j -ésima característica, μ_j é a média de todas as x_{ij} para a característica j , σ_j é o desvio padrão de todas as x_{ij} sobre todas as amostras de entrada.

Avaliação de desempenho com validação cruzada

A seguir, os resultados do modelo são verificados por meio de validação cruzada para avaliar o desempenho do algoritmo. A partir da validação cruzada obtemos uma matriz de confusão com os seguintes campos:

- Verdadeiro positivo: a atividade eletroencefálica pertence à categoria de atividade testada (Jogo, música ou matemática) e o modelo identificou corretamente.
- Falso negativo: a atividade eletroencefálica pertence à categoria de atividade, mas o modelo identificou erroneamente como pertencente à outra categoria de atividade.
- Falso positivo: a atividade eletroencefálica não pertence à categoria, mas o modelo identificou erroneamente como pertencente.
- Verdadeiro negativo: a atividade eletroencefálica não pertence à categoria e isso foi detectado corretamente pelo modelo.

O resultado dessa validação é um modelo válido, que pode ser usado para previsão no conjunto de teste real.

2.3 Considerações

Este capítulo compõe uma parte do referencial teórico que trata dos conceitos referentes ao cérebro, observando a estrutura física e seu funcionamento. Além disso, observa-se ainda neste capítulo como funciona o exame de Eletroencefalograma, que será utilizado na captura da imagem encefálica dos indivíduos durante a execução das atividades cognitivas aqui estudadas: jogar video-game, ouvir música, responder questões de matemática.

Sobre o cérebro, observou-se como acontece seu funcionamento, observando as divisões de regiões existentes na literatura: os lobos. Além disso, observamos como ocorre o processo de aprendizagem no cérebro, processo esse que implica diretamente no processo cognitivo do indivíduo.

Sobre o exame de EEG, observou-se como ocorre o processo de captação deste tipo de imagem encefálica, bem como apresentou-se o sistema 10-20 para posicionamento dos eletrodos na realização do exame. Observou-se também a composição do eletroencefalograma, conhecendo as ondas que o compõem.

Tendo em vista que um dos objetivos desse trabalho é aplicar técnicas de estimação de fontes encefálicas nos sinais de EEG, foi reservado um subtópico no qual é apresentado a aplicação desta metodologia em sinais de EEG, explicando seu funcionamento e o porque do uso da estimação de fontes encefálicas como metodologia na estimação das regiões do encéfalo responsáveis pela emissão dos sinais de EEG associados às atividades cognitivas investigadas.

Sobre os modelos de AM foram apresentados neste capítulo, onde pode-se observar que cada modelo selecionado possui uma formulação matemática distinta, no entanto todos os modelos convergem para o mesmo objetivo, a classificação ou regressão de dados utilizando os princípios do AM.

O AM na perspectiva deste trabalho se mostra a técnica mais indicada na análise dos dados de EEG, uma vez que o número de informações associadas nestes sinais é grande demais para ser analisada de forma simplificada ou sem considerar todas as informações.

Os modelos apresentados serão utilizados na classificação do tipo de atividade desenvolvida pelo indivíduo a partir das regiões encefálicas associadas a cada atividade.

Materiais e Métodos para Classificação de Atividades Cognitivas

O desenvolvimento deste capítulo consiste na exposição dos conceitos referentes ao método científico, ao delineamento e a metodologia de pesquisa. Um detalhamento de todas as fases da pesquisa e do processo de elaboração do modelo computacional também são apresentados.

Uma descrição das fases e etapas é apresentada no decorrer do texto. Propõe-se também uma metodologia para a aplicação da estimação de fontes encefálicas nos sinais de EEG de forma a produzir características para a entrada do modelo classificador.

No primeiro índice será apresentado um delineamento do método científico. No segundo índice será apresentado toda a metodologia aplicada na classificação das atividades cognitivas, apresentando o passo a passo utilizado.

3.1 Pesquisa e Método Científico

Segundo (SOUZA; SANTOS; DIAS, 2013), a pesquisa científica é uma atividade humana, cujo objetivo é conhecer e explicar os fenômenos, oferecendo respostas às questões significativas para a compreensão da natureza. Para isso, o pesquisador utiliza o conhecimento adquirido em seu processo de aprendizagem e manipula cuidadosamente os diferentes métodos e as técnicas para obter resultados pertinentes às suas indagações (SOUZA; SANTOS; DIAS, 2013).

(ZANELLA; VIEIRA; MORAES, 2013) classifica pesquisa de acordo com os objetivos, quanto à abordagem e quanto aos Procedimentos Adotados na Coleta de Dados [46]. Quanto aos objetivos ele especifica que a:

- Pesquisa exploratória: objetiva a ampliação do conhecimento a respeito de um determinado fenômeno, explorando a realidade e buscando maior conhecimento. Essa modalidade de pesquisa serve como suporte para o planejamento de uma pesquisa descritiva (ZANELLA; VIEIRA; MORAES, 2013).
- Pesquisa descritiva: busca estudar as características e os problemas do objeto de pesquisa (ZANELLA; VIEIRA; MORAES, 2013).

Ainda, (ZANELLA; VIEIRA; MORAES, 2013) especifica a pesquisa quanto ao tipo de abordagem, de forma que a pesquisa pode ser classificada em:

- Pesquisa Qualitativa: cuja principal característica é a não utilização do instrumental estatístico como centro de suas análises (ZANELLA; VIEIRA; MORAES, 2013).
- Pesquisa Quantitativa: caracterizada pelo emprego de instrumentos estatísticos, tanto na coleta como no tratamento dos dados. Esse tipo de pesquisa tem por objetivo estabelecer medidas que relacionem as variáveis que compõe o fenômeno estudado (ZANELLA; VIEIRA; MORAES, 2013).

Ele também versa sobre os procedimentos para a coleta de dados, onde ele lista os seguintes tipos de pesquisa (ZANELLA; VIEIRA; MORAES, 2013):

- Pesquisa bibliográfica: caracterizada pelo uso exclusivo de fontes bibliográficas;
- Pesquisa documental: caracterizada pelo uso exclusivo das fontes documentais;
- Pesquisa Experimental: caracterizado pelo uso de algum tipo de experimento onde o pesquisador pode manipular as variáveis envolvidas.
- Ex-post-facto (“Partindo - do fato - passado”): definido como o estudo realizado após a ocorrência de variações na variável.

Partindo-se dos conceitos de (SOUZA; SANTOS; DIAS, 2013) e (ZANELLA; VIEIRA; MORAES, 2013), podemos concluir que o conceito de pesquisa está associado a uma série de procedimentos e etapas que estão relacionadas ao processo de obtenção do conhecimento, e isso nos faz-nos ter a necessidade de conhecer intimamente os conceitos associados ao método científico.

Para (SOUZA; SANTOS; DIAS, 2013), o método científico é um conjunto de procedimentos adotados com o propósito de atingir o conhecimento, já para (ZANELLA; VIEIRA; MORAES, 2013), o método científico é a forma que o cientista escolhe para ampliar o conhecimento sobre determinado objeto, fato ou fenômeno.

Dada a diversidade de métodos, alguns autores costumam classificá-los em gerais e específicos:

- Métodos científicos gerais: oferecem ao pesquisador normas genéricas destinadas a estabelecer uma ruptura entre objetos científicos e não-científicos (ou de senso comum). Os principais métodos gerais são: indutivo, dedutivo, dialético, fenomenológico e hipotético-dedutivo.
- Métodos científicos específicos: também denominados discretos ou de procedimento, estão relacionados com os procedimentos técnicos a serem seguidos pelo pesquisador dentro de uma determinada área de conhecimento (SOUZA; SANTOS; DIAS, 2013).

Apesar da grande quantidade de métodos descritos na literatura, observa-se que o pesquisador dispõe de bastante liberdade para escolher os melhores procedimentos na execução de sua pesquisa, visando sempre alcançar os objetivos propostos de maneira mais adequada possível.

3.2 Delineamento da Pesquisa

Na Figura 3.1, é ilustrada a metodologia seguida para a elaboração deste trabalho. Primeiramente, foi realizada uma busca pelos temas “Eletroencefalograma”; “Estimação de Fontes Encefálicas”; “Modelos classificadores das atividades encefálicas a partir dos sinais de EEG”, esta etapa se faz importante para o norteamento da pesquisa. A partir da definição do tema que seria abordado, na etapa dois, foram definidas as bases de dados a serem utilizadas, separando-as de acordo com as categorias de atividades escolhidas: Jogo de vídeo game, música, matemática.

Em seguida, foi realizado o pré-processamento dos sinais do banco de dados e organização dos dados para a etapa de extração de recursos, onde foi realizada por meio da aplicação da estimação de fontes encefálicas.

A partir das regiões determinadas, é realizada a elaboração de um banco de dados contendo todas as regiões encefálicas associadas a cada uma das atividades “Jogo de video game, Música, Matemática”.

A partir do banco de dados criado, obteremos o vetor de características necessário para o treinamento e teste do modelo, onde as características do vetor de entrada serão as regiões encefálicas relacionadas com cada uma das atividades.

O passo seguinte será a elaboração do modelo classificador, nesta etapa, serão testados alguns modelos de classificadores baseados em aprendizado de máquinas, e a partir dos modelos testados será eleito um modelo para uso, o modelo escolhido será treinado e testado.



Figura 3.1: Passos que serão utilizados na elaboração do modelo classificador. Na etapa 1 será realizada a busca pelas bases de dados dos sinais de EEG. Na etapa dois será realizada a estimação de fontes encefálicas. Na etapa será elaborado um banco de dados com as regiões encefálicas associadas a cada uma das atividades. Na etapa quatro será elaborado, treinado e testado o modelo classificador.

3.2.1 Bases de Dados

As bases de ados utilizadas foram as bases de dados ds003517 utilizada em (CAVANAGH; CASTELLANOS, 2016) e disponível na plataforma Openeuro (CAVANAGH; CASTELLANOS, 2021) e a base de dados ds003685 utilizada em (DUAN et al., 2021) disponível na plataforma Openeuro (WANG et al., 2022).

Na base ds003517¹, está registrado o EEG de 17 indivíduos normais com idade média de 20,94 anos. Dos 17 participantes 11 são do sexo masculino e não apresentam nenhum tipo de disfunção ou problema de desempenho em atividades cognitivas. Os sinais de EEG da base de dados foram registrados continuamente em 0,01 a 100 Hz com uma taxa de amostragem de 500 Hz e uma referência CPz online em um sistema Brain Vision de 64 canais durante o jogo contínuo de um vídeo game onde cada tarefa envia gatilhos para o arquivo EEG e também produz dados contínuos em um arquivo de registro (CAVANAGH; CASTELLANOS, 2016). Os dados foram coletados por volta de 2015 no Laboratório de Ritmos Cognitivos e Computação da Universidade do Novo México (CAVANAGH; CASTELLANOS, 2016).

Na base ds003685², está registrado o EEG de 57 participantes saudáveis dos quais 24 são homens, com idade média de 19,7 anos, que não apresentam nenhum tipo de disfunção ou problema de desempenho em atividades cognitivas (DUAN et al., 2021). Os indivíduos realizam algumas tarefas: Abrir os olhos, fechar os olhos, responder questões de matemática, ouvir música, teste de memória (CA). Os sinais de EEG da base de dados foram registrados continuamente com uma taxa de amostragem de 500 Hz e uma referência CPz online em um sistema EEGLAB de 63 canais, para este trabalho foi selecionado os sinais de EEG coletados durante as seções em que os participantes responderam questões matemáticas e ouviram músicas.

3.2.2 Estimação de Fontes Encefálicas

Neste trabalho propomos o uso dos sinais de Eletroencefalograma (EEG) como forma de obtenção de imagens da atividade encefálica, pois por meio da aplicação de uma técnica conhecida como estimação de fontes encefálicas no EEG, é possível obter as regiões anatômicas do encéfalo relacionadas com o sinal de EEG captado (DUAN et al., 2021). A estimação de fontes encefálicas consiste em um mecanismo que, dado o sinal de EEG ou uma imagem da atividade eletromagnética encefálica, é capaz de identificar as regiões do encéfalo que são ativadas durante um evento qualquer (DUAN et al., 2021).

Nesta etapa utilizou-se o software de análise de sinais neurais Brainstorm (RASHEED et al., 2021). O software tem entre outras funções, a função de realizar a estimação de fontes encefálicas, neste trabalho em específico utilizou-se o algoritmo sLORETA para a estimação das fontes encefálicas (JATOI; KAMEL, 2018), a partir do algoritmo é realizada a estimação das fontes no software. As estimações das fontes encefálicas foram necessárias para identificar as regiões encefálicas relacionadas com o sinal de EEG de cada uma das atividades “Jogo de video game, Música, Matemática”.

Após a estimação das fontes encefálicas associadas a cada uma das atividades, fez-se uma contagem das regiões anatômicas associadas ao EEG emitido durante a atividade, nesta etapa considerou-se o atlas anatômico Mindboggling (KLEIN et al., 2017). O atlas Mindboggling possui 29 regiões anatômicas definidas, e foi desenvolvido visando o auxílio da identificação de doenças mentais através da localização de regiões de interesse em exames de imagem encefálicas (KLEIN et al., 2017).

A contagem das regiões foi feita através da anotação da ativação de cada região relacionada a cada uma das atividades, onde adotou-se a seguinte metodologia: Caso a área tenha sido ativada na atividade, esta área receberia 1, caso contrário receberia 0, para este trabalho é considerado região ativa a região do encéfalo que apresenta alguma atividade eletromagnética encefálica

¹<https://openneuro.org/datasets/ds003517/versions/1.1.0>

²<https://openneuro.org/datasets/ds003685/versions/1.0.2>

durante o evento específico, essa atividade apresenta-se como uma corrente eletromagnética na região encefálica diferente de zero e é observada na etapa de estimação de fontes encefálicas.

A partir da elaboração do banco de dados foi feito o vetor de características que seria entrada para o modelo classificador, o vetor possui a forma mostrada na equação 3.1

$$X = \begin{bmatrix} x_{1,1} & \cdots & x_{1,29} \\ \vdots & \ddots & \vdots \\ x_{n,1} & \cdots & x_{n,29} \end{bmatrix} \quad (3.1)$$

onde cada x é uma região encefálica que está associada a cada uma das atividades “Jogo de vídeo game, Música, Matemática”. A dimensão do vetor de características é 29 porque existem 29 regiões anatômicas no encéfalo anatomicamente. E n é a quantidade de EEG analisados.

Como as bases de dados possuem quantidade de indivíduos diferentes, 57 indivíduos na base de dados de música e matemática e somente 17 indivíduos na base de dados de jogos de vídeo game, para que houvesse um mesmo número de sinais de EEG de indivíduos para cada categoria de atividade (jogar vídeo game; ouvir música; responder questões matemáticas), considerou-se 57 sinais coletados durante a atividade de jogar vídeo game, pois os 17 participantes da base de dados foram submetidos a várias seções de coletarem de EEG, cada coleta em momentos diferentes, assim as três categorias de atividade tiveram a mesma quantidade de sinais de EEG, 57 sinais de cada atividade.

Esse procedimento de balanceamento foi necessário para que os dados utilizados tivessem a mesma quantidade de sinais de EEG pra cada classe de atividade cognitiva, e assim o treino e teste do modelo não fosse prejudicado pela diferença de quantidade de voluntários de cada base de dados.

3.2.3 Modelo Classificador

A partir do banco de dados criado, com todos os dados referentes às regiões anatômicas para os indivíduos das bases de dados, foi desenvolvido um modelo baseado em aprendizado de máquinas para classificar a atividade encefálica dentro de uma das três categorias: “Jogo de vídeo game, Música, Matemática”. Nesta etapa, foram testados os modelos apresentados no ??.

Para a implementação do modelo, utilizou-se a linguagem de programação *Python* (VAN-ROSSUM; DRAKE, 2010). Onde o modelo foi implementado e testado considerando os dados selecionados.

3.2.4 Métricas de Avaliação

Neste trabalho, foram utilizados os valores de acurácia (*ACC*) e precisão (*PREC*), descritos nas equações abaixo, para verificar o desempenho dos classificadores mostrado na equação 3.2 e 3.3, respectivamente

$$ACC = \frac{VP + VN}{VP + VN + FN + FP} \times 100 \quad (3.2)$$

$$PREC = \frac{VP}{VP + FP} \times 100 \quad (3.3)$$

onde temos que Verdadeiro positivo (*VP*) indica a quantidade de registros que foram classificados como positivos corretamente, ou seja, a resposta do classificador foi que o a atividade

encefálica pertencia a dada classe e a classificação foi correta. Verdadeiro negativo (VN) indica a quantidade de registros que foram classificados como negativos de maneira correta, ou seja, a resposta do classificador foi que a atividade encefálica não pertencia a dada classe e a classificação foi correta. Falso positivo (FP) indica a quantidade de registros que foram classificados como positivos de maneira incorreta, ou seja, a resposta do classificador foi que a atividade encefálica pertencia a dada classe, mas a atividade encefálica não pertencia aquela classe. Falso negativo (FN) indica a quantidade de registros que foram classificados como negativos de maneira incorreta, ou seja, a resposta do classificador foi que a atividade encefálica não pertencia a dada classe, mas a atividade encefálica pertencia aquela classe.

Como temos um modelo classificador multiclasse, onde ele classifica a atividade encefálica como pertencente a uma das três categorias: Jogo de vídeo game, Música ou Matemática, diferente do processo dos problemas de classificação binária, você não precisa escolher um limite de pontuação para fazer previsões. A resposta prevista é a classe (por exemplo, rótulo) com a maior pontuação prevista. Em alguns casos, talvez você use a resposta prevista apenas se ela for prevista com uma pontuação alta. Nesse caso, você pode escolher um limite nas pontuações previstas com base no qual aceitará ou não a resposta prevista.

- Técnica de Validação cruzada

A validação cruzada é uma técnica para avaliar a generalização de um modelo, com base em um conjunto de dados. No Aprendizado de Máquina, a validação cruzada é um método de re-amostragem usado para avaliação de modelo para evitar o teste de um modelo no mesmo conjunto de dados no qual ele foi treinado. Este é um erro comum, especialmente que um conjunto de dados de teste separado nem sempre está disponível.

No entanto, isso geralmente leva a medidas de desempenho imprecisas (já que o modelo terá uma pontuação quase perfeita, pois está sendo testado nos mesmos dados em que foi treinado). Para evitar esse tipo de erro, a validação cruzada é geralmente preferida. O conceito de validação cruzada é realmente simples: em vez de usar todo o conjunto de dados para treinar e, em seguida, testar nos mesmos dados, poderíamos dividir aleatoriamente nossos dados em conjuntos de dados de treinamento e teste.

Neste trabalho utilizaremos validação cruzada k-fold com 10 iterações. Este método é adequado, pois fornece informações sobre a robustez de um modelo. Neste tipo de validação, o conjunto de treinamento é dividido em 10 amostras escolhidas aleatoriamente. Nove delas são usadas para treinar o modelo, e o restante é usado para testá-lo. O resultado das 10 validações cruzadas é o valor médio de todos os ensaios.

3.3 Considerações

Foi apresentado nesse capítulo as definições de método científico, para que seja esclarecido a metodologia escolhida para aplicar no delineamento geral dessa pesquisa, também apresentado neste capítulo. Apresentou-se as fases de desenvolvimento do modelo. O banco de dados utilizado foi apresentado de maneira descritiva e os detalhes associados à extração de características dos sinais de EEG. Além disso foram expostas nesse capítulo as ferramentas utilizadas na extração de características dos sinais de EEG e o desenvolvimento do modelo desenvolvido, além da avaliação do modelo de classificação (Precisão e Acurácia). Uma breve ilustração das etapas realizadas também teve exposta no capítulo.

No delineamento da pesquisa ficou claro que a mesma foi realizada em cinco fases, e nesse capítulo foi percorrido detalhadamente sobre cada uma delas. Os elementos obtidos na execução dessas etapas serão detalhados no capítulo seguinte na apresentação dos resultados.

Resultados

A organização deste capítulo é composta de três seções. Na primeira seção consta o resultado da classificação das atividades cognitivas a partir das regiões encefálicas ativadas. Na segunda seção apresentamos uma discussão a respeito dos resultados alcançados. Na terceira seção, é apresentado sugestões de trabalhos futuros.

4.1 Estimação de Fontes Encefálicas

O uso da estimação de fontes encefálicas foi essencial na execução deste trabalho, pois a partir desta etapa foi possível identificar as regiões anatômicas que estão diretamente relacionadas com a atividade de jogar video game. Assim, a partir desta etapa foi possível identificar as regiões que apresentaram relação com cada uma das atividades

Nas Figuras 4.1, 4.2 e 4.3 estão apresentados a atividade neuronal característica observadas, respectivamente, durante as atividades de jogo de video game, música e resolução de questões matemáticas.

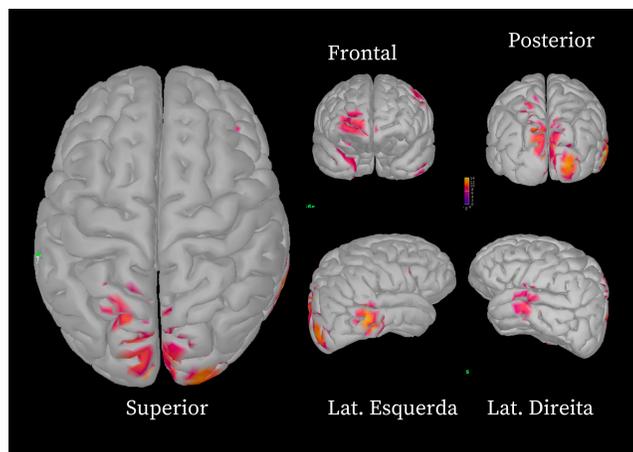


Figura 4.1: Exemplo da ativação encefálica durante a atividade de jogar de video game, obtido com a estimação de fontes encefálicas no software *Brainstorm*.

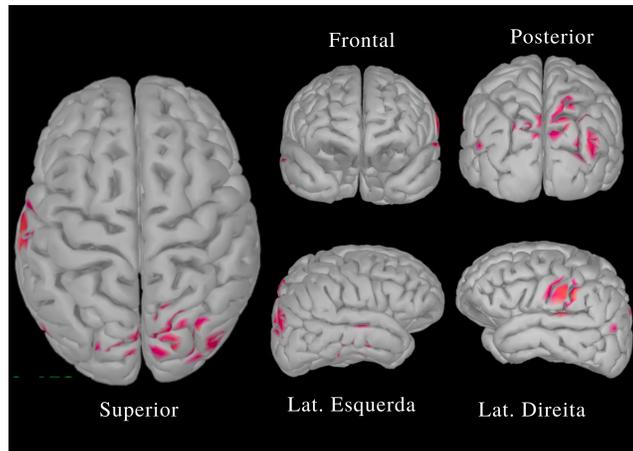


Figura 4.2: Exemplo da ativação encefálica durante a atividade de ouvir música, obtido com a estimação de fontes encefálicas no software *Brainstorm*

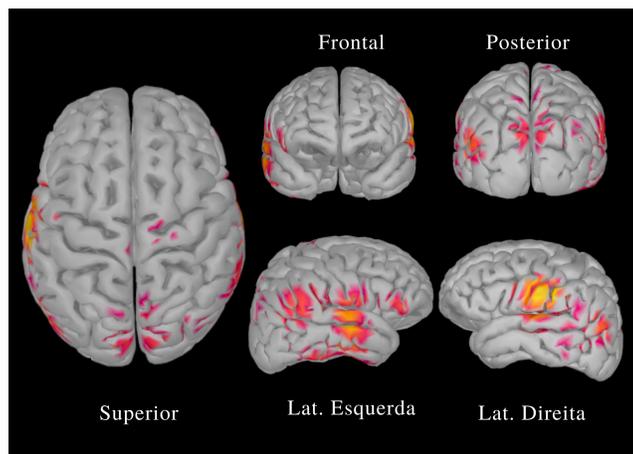


Figura 4.3: Exemplo da ativação encefálica durante a atividade de responder questões matemáticas, obtido com a estimação de fontes encefálicas no software *Brainstorm*

Quando observamos o comportamento da ativação neuronal em cada uma das atividades, notamos que as regiões do hemisfério esquerdo no lóbulo frontal, temporal e posterior occipital foi notado nas atividades encefálicas dos indivíduos durante as atividades de jogar video game, música e matemática, o que se relaciona com a literatura quando se trata de atividades cognitivas (CAVANAGH; CASTELLANOS, 2016; DUAN et al., 2021; HUANG et al., 2018; CHEAH et al., 2020) que sempre relaciona essas atividades com as regiões que se apresentaram ativadas.

É importante salientar que a região ativada, mostrada em cores distintas do resto do cérebro nas figuras, estão relacionadas à região responsável por emitir o sinal de EEG associado à respectiva atividade, o que não significa que as outras regiões do cérebro estão eletricamente inativas.

A partir das regiões encefálicas associadas aos sinais de EEG, no software *Brainstorm* (TADDEL et al., 2011), é possível identificar a região do atlas anatômico *mindboogle* que está associada ao sinal de EEG em cada uma das atividades cognitivas analisadas, com isso podemos observar

características estatísticas da ativação de cada região encefálica durante as atividades de jogar video-game, ouvir música e responder questões de matemática. Essas estatísticas por região são apresentadas na Tabela 4.1

Tabela 4.1: Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)

Nº Atlas	Região	Esquerda	Direita
1	Caudal Médio Frontal		
2	Cuneus		
3	Entorhinal		

Tabela 4.1: Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)

Nº Atlas	Região	Esquerda	Direita
4	Fusiform	<p>Média de ativação da região FE</p>	<p>Média de ativação da região FD</p>
5	Inferior Parietal	<p>Média de ativação da região IPE</p>	<p>Média de ativação da região IPD</p>
6	Inferior Temporal	<p>Média de ativação da região ITE</p>	<p>Média de ativação da região ITD</p>

Tabela 4.1: Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)

Nº Atlas	Região	Esquerda	Direita
7	Insula	<p>Média de ativação da região IE</p>	<p>Média de ativação da região ID</p>
8	Isthmus cingulate	<p>Média de ativação da região ICE</p>	<p>Média de ativação da região ICD</p>
9	Lateral occipital	<p>Média de ativação da região LOE</p>	<p>Média de ativação da região LOD</p>

Tabela 4.1: Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)

Nº Atlas	Região	Esquerda	Direita
10	Lateral orbito frontal		
11	Lingual		
12	Media orbito frontal		

Tabela 4.1: Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)

Nº Atlas	Região	Esquerda	Direita
13	Media temporal	<p>Média de ativação da região MTE</p>	<p>Média de ativação da região MTD</p>
14	Paracentral	<p>Média de ativação da região PE</p>	<p>Média de ativação da região PD</p>
15	Parahippocampal	<p>Média de ativação da região PAE</p>	<p>Média de ativação da região PAD</p>

Tabela 4.1: Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)

Nº Atlas	Região	Esquerda	Direita
16	Parsopercularis	<p>Média de ativação da região PARE</p>	<p>Média de ativação da região PARD</p>
17	Parsorbitalis	<p>Média de ativação da região PARSD</p>	<p>Média de ativação da região PARSE</p>
18	Parstriangularis	<p>Média de ativação da região PTE</p>	<p>Média de ativação da região PTD</p>

Tabela 4.1: Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)

Nº Atlas	Região	Esquerda	Direita
		10 -	10 -
		0.8 - 0.6 - 0.4 - 0.2 - 0.0	0.8 - 0.6 - 0.4 - 0.2 - 0.0
19	Pericalcarine	<p>Média de ativação da região PERIE</p>	<p>Média de ativação da região PERID</p>
		1.0 - 0.8 - 0.6 - 0.4 - 0.2 - 0.0	1.0 - 0.8 - 0.6 - 0.4 - 0.2 - 0.0
20	Postcentral	<p>Média de ativação da região POSTE</p>	<p>Média de ativação da região POSTD</p>
		1.0 - 0.8 - 0.6 - 0.4 - 0.2 - 0.0	1.0 - 0.8 - 0.6 - 0.4 - 0.2 - 0.0
21	Posterior cingulate	<p>Média de ativação da região PCE</p>	<p>Média de ativação da região PCD</p>
		1.0 - 0.8 - 0.6 - 0.4 - 0.2 - 0.0	1.0 - 0.8 - 0.6 - 0.4 - 0.2 - 0.0

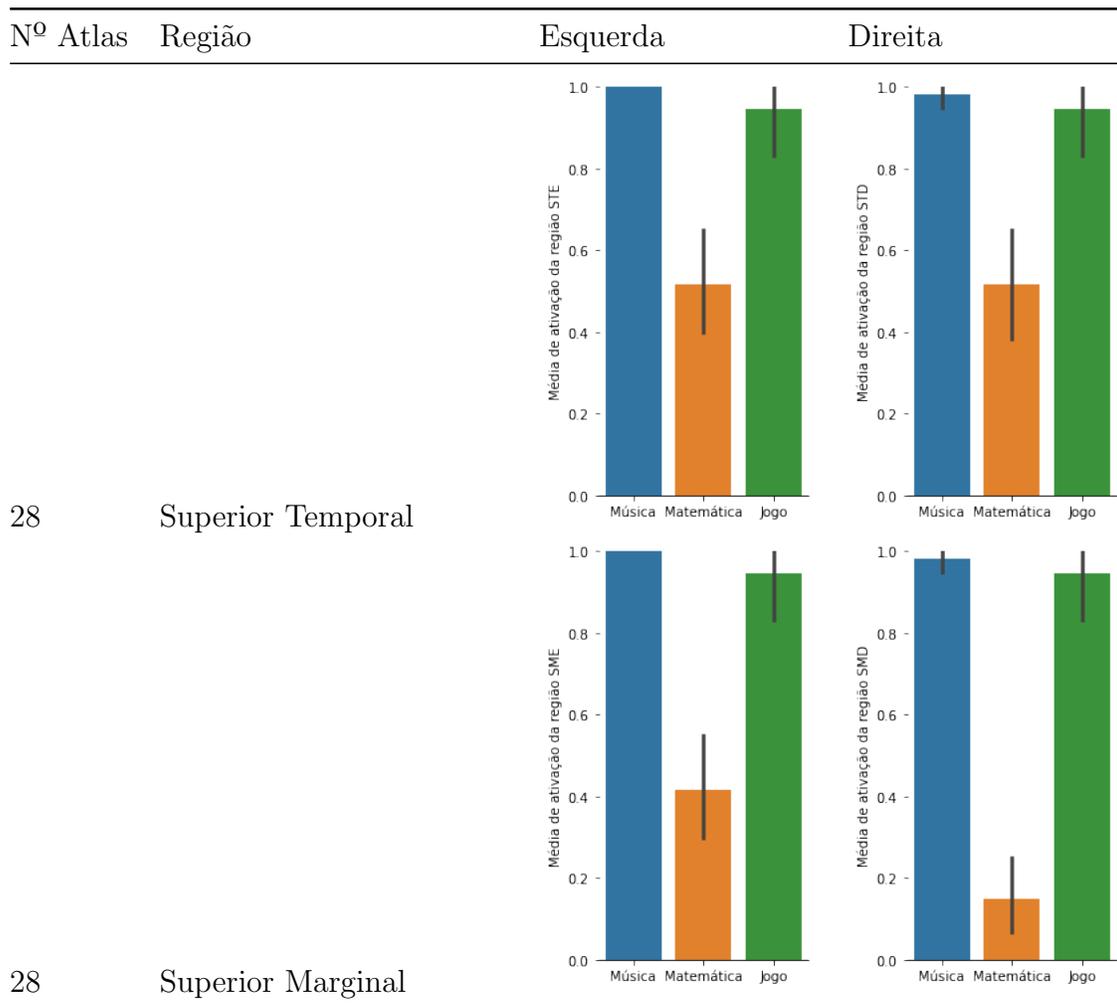
Tabela 4.1: Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)

Nº Atlas	Região	Esquerda	Direita
22	Precentral esquerdo	<p>Média de ativação da região PREE</p>	<p>Média de ativação da região PREED</p>
23	Precuneus	<p>Média de ativação da região PRECE</p>	<p>Média de ativação da região PRECD</p>
24	Rostral anterior cingulate	<p>Média de ativação da região RACE</p>	<p>Média de ativação da região RACD</p>

Tabela 4.1: Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)

Nº Atlas	Região	Esquerda	Direita
25	Rostral medio frontal	<p>Média de ativação da região RMFE</p>	<p>Média de ativação da região RMFD</p>
26	Superior Frontal	<p>Média de ativação da região SFE</p>	<p>Média de ativação da região SFD</p>
27	Superior parietal	<p>Média de ativação da região SPE</p>	<p>Média de ativação da região SPD</p>

Tabela 4.1: Ativação média de cada região durante cada atividade cognitiva (Música, Matemática, Jogo)



Ao observar-se a tabela 4.1 podemos notar que há regiões que não possuem nenhuma ativação durante as atividades cognitivas analisadas, como a região 19 do atlas mindboogle (Pericalcarine) que não se apresenta ativada em nenhum momento. Observando-se também, a ocorrência de algumas regiões que se mostram ativadas em um só hemisfério com relação a uma única atividade, como a região 10 do atlas mindboogle (Lateral orbito frontal) que se mostra ativada no hemisfério esquerdo, com uma média de 20% de ativação. Nota-se também uma ocorrência considerável de ativação de algumas regiões durante as três atividades cognitivas, como a região 13 do atlas mindboogle (Media temporal), que se mostra com uma média de ativação de 100% para as atividades de ouvir música e jogo de video game nos dois hemisférios, para matemática a região se mostra ativa em 60% dos sinais de EEG analisados.

A partir dessas ativações encefálicas notadas durante cada atividade cognitiva, que só são possíveis com a aplicação da estimação de fontes encefálicas, foi produzido o vetor de características que é entrada do modelo classificador das atividades cognitivas.

4.2 Classificador da atividade cognitiva a partir das regiões encefálicas ativadas

O uso da estimação de fontes encefálicas foi essencial na execução deste trabalho, pois a partir desta etapa foi possível identificar as regiões anatômicas que estão diretamente relacionadas com cada uma das atividades “Jogar video game, Música, Matemática”. A partir dessas regiões foi elaborado o banco de dados usado no treino e teste do modelo.

Na etapa de implementação do modelo, este foi implementado utilizando-se da biblioteca `pycaret` da linguagem Python (VANROSSUM; DRAKE, 2010), onde a partir do uso da biblioteca o modelo foi implementado, testado e validado com validação cruzada a partir do banco de dados produzido. O banco de dados foi dividido na porcentagem 90% para treino e 10% para teste, assim, a partir do banco de dados com as regiões encefálicas associadas a cada uma das atividades “Jogo de video game, Música, Matemática”, foi feito o treino e teste do modelo.

Considerando-se um modelo classificador multiclasse, fez-se um teste dos modelos de aprendizado de máquina que foram apresentados no capítulo 2. Estes modelos foram treinados e testados para os dados coletados e os resultados do treinamento estão mostrados na Tabela 4.2.

Tabela 4.2: Resultados obtidos por cada modelo

Modelo	Acurácia	Precisão
Random Forest Classifier	0.9990	0.9933
K Nearest Neighbors Classifier	0.9900	0.9917
Linear Discriminant Analysis	0.9900	0.9917
Decision Tree Classifier	0.9800	0.9833
SVM - Linear Kernel	0.9800	0.9833

A partir do treinamento dos modelos, observou-se que o modelo que apresentou os melhores resultados na classificação do tipo de atividade executada a partir das regiões encefálicas relacionadas com as atividades “Jogo de video game, Música, Matemática” foi o modelo Random Forest, que foi o modelo escolhido.

Com o modelo Random Forest selecionado, pode-se observar a curva de aprendizagem do modelo, mostrada na Figura 4.4 onde observa-se um modelo com uma aprendizagem precisa e progressiva. Na Figura 4.4 podemos observar que a precisão do treino para o modelo foi de 99.33%, e que a validação do modelo tem um comportamento parecido.

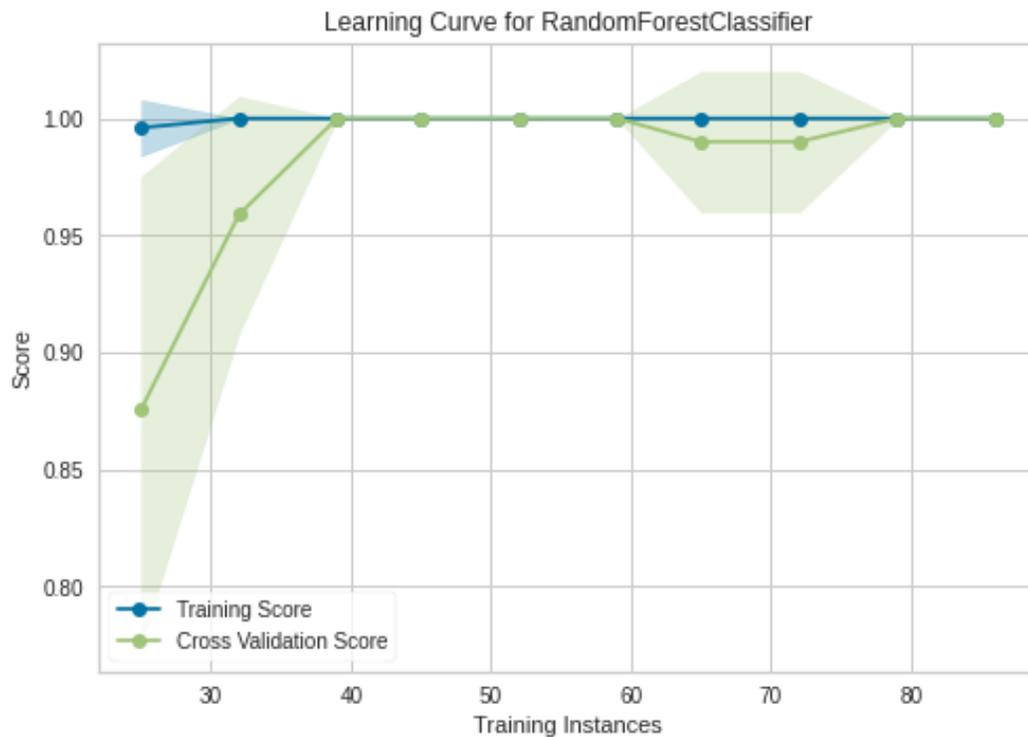


Figura 4.4: Curva de aprendizagem do modelo Random Forest.

Após a validação do modelo, pode-se observar as regiões de maior influência na classificação do modelo de acordo com cada classe: jogo de video game, matemática e música. Na Figura 18 podemos observar as regiões com maiores influências na classificação para cada classe, na imagem, a classe 0 se trata da atividade de ouvir música, na classe 1 é a atividade de responder questões matemáticas e na classe 2 é a atividade de jogar video game. As regiões encefálicas citadas na Figura 4.5 que apresentam relação positiva com a atividade se apresentam ativadas durante a execução da atividade específica, uma relação positiva significa que a ativação daquela região é um fator considerado na classificação do tipo de atividade.

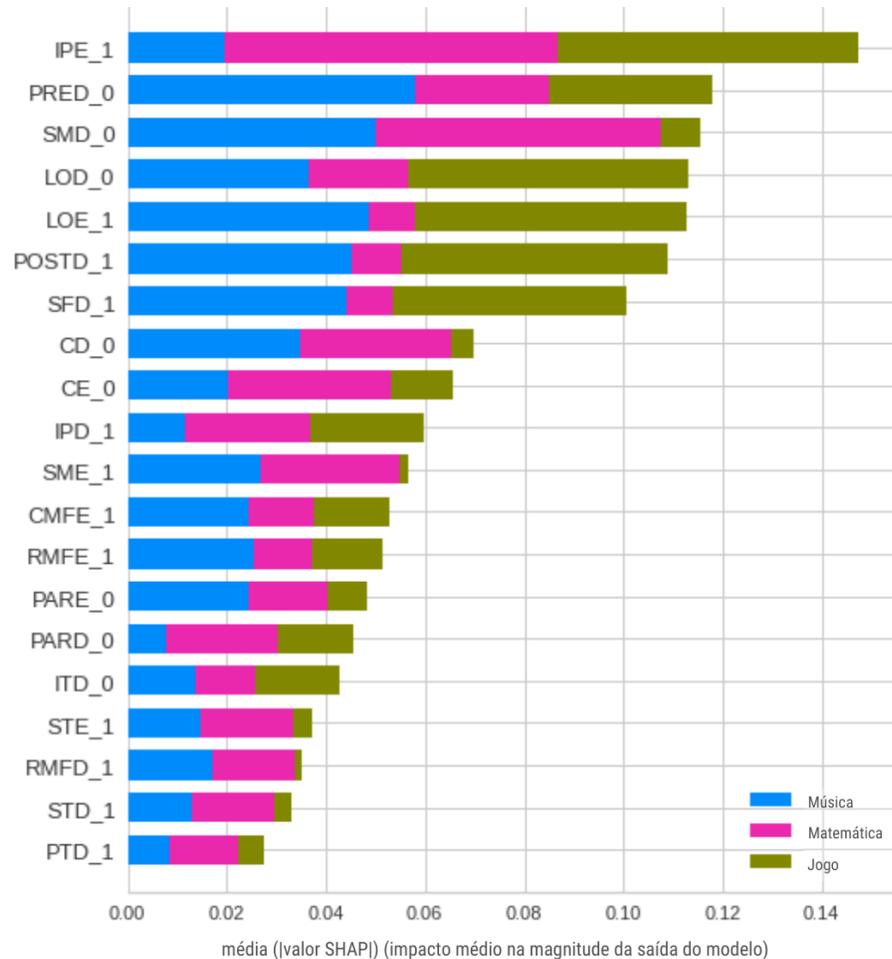


Figura 4.5: Regiões encefálicas com maior influência na classificação da atividade realizada. IPE - Inferior Parietral Esquerdo; PRED - Precuneus Direito; SMD - Supra Marginal Direito; LOD - Lateral Occipital Direito; LOE - Lateral Occipital Esquerdo; POSTD - Postcentral Direito; SFD - Superior Frontal Direito; CD - Cuneus Direito; CE - Cuneus Esquerdo; IPD - Inferior Parietral Direito; SME - Superior Marginal Esquerdo; CMFE - Caudal Medio Frontal Esquerdo; RMFE - Rostral Medio Frontal Esquerdo; PARE - Parahippocampal Esquerdo; PARD - Parahippocampal Direito; ITD - Inferior Temporal Direito; STE - Superior Temporal Esquerdo; RMFD - Rostral Medio Frontal Direito; STD - Superior Temporal Direito; PTD - Posterior Temporal Direito. As regiões que apresentam uma relação positiva com a atividade em questão se apresenta seguida do valor 1 no eixo y, enquanto as regiões com relação negativa se apresentam com o valor 0 no eixo y.

As regiões encefálicas que apresentam relação negativa com a atividade não apresentam atividade encefálica relacionada com a execução da atividade. Dentre todas as regiões que possuem relação positiva com a atividade, se destaca a região Inferior Parietral Esquerda, que é uma região do lóbulo parietal que se relaciona com emoção e coordenação motora [40-44].

Quatro das regiões com relação positiva com as atividades pertencem ao lóbulo frontal, ou seja, quatro regiões do lóbulo frontal apresentam alguma relação direta de ativação durante o desenvolvimento das atividades cognitivas: jogo de video game, música e matemática. Essas regiões do lóbulo frontal são relacionadas, segundo a literatura, com a cognição e aprendizagem (DUAN et al., 2021). Regiões do lóbulo occipital também se relacionam com as atividades de forma positiva, o que indica uma ativação de regiões relacionadas a processamento de imagens (JATOI; KAMEL, 2018).

A partir da indicação de relação entre região encefálica ativada e atividade cognitiva determinada utilizando o modelo de classificação eleito: Random Forest, pode-se analisar a eficiência do modelo na classificação das atividades cognitivas a partir da ativação encefálica durante a realização das atividades classificadas por meio da curva ROC do método. A curva ROC do modelo, na Figura 4.6, indica a precisão de classificação do modelo, apresentando uma excelente classificação multiclasse.

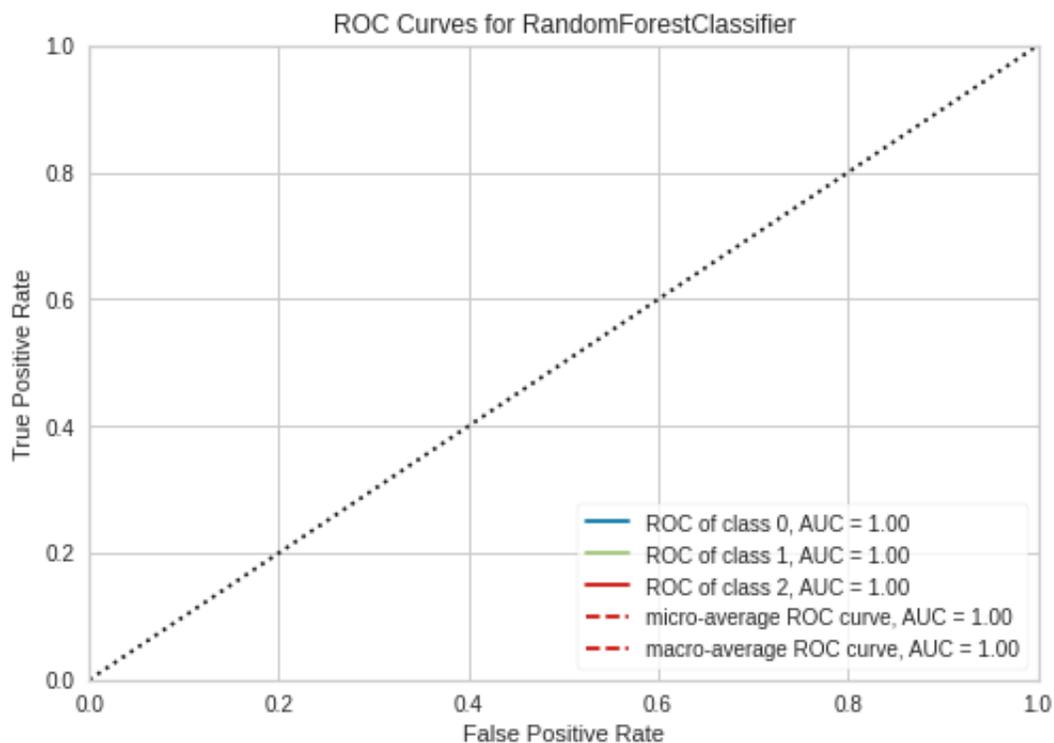


Figura 4.6: Curva ROC do modelo.

4.3 Discursão dos Resultados

Neste trabalho foi apresentado o desenvolvimento de um modelo de classificação de atividades encefálicas, baseado em um modelo de aprendizado de máquinas para classificar a atividade encefálica como pertencente a uma das três classes: Jogo de video game, música ou matemática. No modelo, considera-se o desenvolvimento de uma das três atividades pelo indivíduo. O modelo trabalha a partir do EEG coletado, com o uso da técnica de estimação de fontes encefálicas, localizando as regiões encefálicas relacionadas a atividade.

O modelo de classificação das atividades encefálicas se mostrou eficiente, com um número de acertos de 0,9990 na fase de testes, e com um funcionamento adequado. Notamos que é possível a predição do tipo de atividade cognitiva que está sendo realizada a partir das regiões encefálicas ativadas que possuem relação com a tarefa em questão. Assim, este trabalho representa um passo importante no mapeamento das atividades cognitivas e sua relação com a atividade eletromagnética encefálica.

Ressaltamos, que há diversos trabalhos na literatura que relacionam a ativação encefálica com a atividade desempenhada (CHEAH et al., 2020; CUTLER; CUTLER; STEVENS, 2012; DU; ZHAN, 2002), mas, em sua grande maioria, esses trabalhos utilizam imagem de Ressonância Magnética Funcional (fMRI), que é uma técnica cara, cuja manutenção e manuseio requer alto grau de conhecimento e habilidade.

Neste trabalho, propomos o uso dos sinais de EEG, nos casos em que seja possível a substituição da fMRI, como fonte de observação da ativação encefálica, notando que este tipo de observação através dos sinais de EEG é possível com o uso da técnica de estimação de fontes encefálicas.

As vantagens do uso dos sinais de EEG neste tipo de análise está relacionada com seu baixo custo, pouca manutenção, e facilidade de acesso, uma vez que esta é uma técnica bastante utilizada em todas as classes sociais para aquisição de informações quanto a saúde encefálica.

Observamos que o modelo classificador teve um desempenho bom e pretende-se, em trabalhos futuros, buscar o desenvolvimento de uma interface gráfica que possa classificar o tipo de atividade cognitiva a partir do EEG captado, o que se mostra um grande diferencial no sentido de um monitoramento eficiente e rápido da atividade eletroencefálica, utilizando o modelo classificador aqui desenvolvido.

Este é um passo importante na busca por um monitoramento seguro de pacientes que possuam alguma patologia que afete seu desenvolvimento cognitivo, uma vez que a atividade encefálica em indivíduos com problemas cognitivos não ocorre da maneira normal esperada, como em indivíduos normais.

Em seu trabalho, (MULLEN et al., 2015), usou os sinais de Eletroencefalograma (EEG) para uma estrutura de software em tempo real que utiliza localização de fonte cortical para visualização de dados e classificação de estado cognitivo de recursos de conectividade usando uma abordagem de regressão logística restrita a classificação, obtendo uma AUC de 97,0%. No trabalho de (DATTA et al., 2015) é apresentado uma metodologia para classificar os sinais de Eletroencefalograma (EEG) correspondentes a três atividades cognitivas diferentes, obtendo uma AUC de 85,33%. Um outro estudo, de (RUIZ-GÓMEZ et al., 2018) avalia a utilidade de uma metodologia baseada na eletroencefalografia (EEG) para detectar Alzheimer, utilizando o aprendizado de máquinas para a classificação, obtendo uma AUC de 89,47%.

Vale ressaltar que a contribuição deste trabalho é a caracterização da atividade desenvolvida pelo indivíduo a partir da atividade eletroencefálica, por meio do uso da estimação de fontes encefálicas que é amplamente utilizado pelos autores já citados. A comparação é mostrada na

Tabela 4.3.

Tabela 4.3: Comparativo de performance de metodologias anteriores com o a performance obtida neste trabalho.

Autor	Parâmetros	Acurácia
MULLEN et al. (2015)	Eletroencefalograma (EEG) e estimação de fontes encefálicas.	97.0%
DATTA et al. (2015)	Eletroencefalograma (EEG)	85.33%
Ruiz-Gómez et. al (2018)	Eletroencefalograma e estimação de fontes encefálicas.	89.47%
Este Trabalho	Nosso método	99.90%

4.4 Trabalhos Futuros

Em trabalhos futuros, pode-se verificar características associativas entre regiões encefálicas ativadas e sexo dos indivíduos a fim de verificar-se a relação entre sexo e áreas encefálicas que mais apresentam ativação eletromagnética durante as atividades cognitivas.

Pode-se ainda verificar a relação entre hemisfério cerebral com atividade eletromagnética e período de desempenho da atividade a fim de verificar a relação entre aprendizagem e o hemisfério direito citado por diversas vezes na literatura. Dessa maneira, poderia-se verificar e comparar quais das regiões encefálicas oferecem uma melhor abordagem para classificação das atividades cognitivas desempenhadas considerando-se a atividade eletroencefálica do indivíduo.

Outro trabalho interessante é a mudança de parâmetros dos classificadores utilizados, e até utilizado outras técnicas de estimação de fontes encefálicas existentes na literatura, tais como Loreta, eLoreta, etc. Além disso, pode-se elaborar uma aplicação do modelo aqui desenvolvido para classificação de outros bancos de dados, com outras características de captação de EEG.

Diante do exposto, seria interessante também a confecção de uma aplicação que detecte o tipo de atividade cognitiva desenvolvida a partir do eletroencefalograma, que seria bem útil no monitoramento de quadros clínicos de pacientes com disfunção encefálica, uma vez que as alterações na atividade eletroencefálica durante a realização de atividades cognitivas poderia ser monitorada e acompanhada de forma efetiva.

4.5 Considerações

Nesse capítulo foram apresentados os principais resultados obtidos nas simulações realizadas na execução desse trabalho. Observamos que o modelo desenvolvido obteve um bom desempenho, o que nos faz observar o alcance dos objetivos elencados no início deste trabalho.

Conclusão

Algumas definições importantes, como o funcionamento do encéfalo, Eletroencefalograma (EEG), estimação de fontes encefálicas, Aprendizado de Máquinas (AM) e alguns modelos de AM foram abordadas no decorrer desse trabalho. Sobre estimação de fontes encefálicas, além da definição, as várias maneiras que ela pode ser utilizada e aplicada aos sinais de EEG foram analisadas. Através deste trabalho observamos a possibilidade da classificação das atividades cognitivas utilizando as técnicas de Estimação de Fontes encefálicas e AM para analisar sinais de EEG, que possuem baixo custo de aquisição.

Ressaltamos o desenvolvimento de um modelo de classificação de atividades cognitivas a partir das regiões encefálicas relacionadas a atividade de três classes (Jogo de video game, música, matemática). Onde foi realizado o teste de alguns modelos de aprendizado de máquinas, mas o modelo eleito que apresentou o melhor desempenho foi o Random Forest utilizado no desenvolvimento do modelo classificador.

O modelo desenvolvido classifica a atividade encefálica como pertencente a uma das classes: jogo de video game, música, matemática. Assim, este estudo representa um passo importante em mapear a atividade neural do funcionamento do encéfalo no contexto do desenvolvimento cognitivo dentro dos indivíduos, uma vez que ainda é um mistério como se comporta o cérebro de diferentes indivíduos no desenvolvimento cognitivo.

No que diz respeito a classificação multiclasse dos vetores de características a aplicação do Random Forest proporcionou maior separação entre os grupos, obtendo melhores índices de acurácia, com destaque para a AUC de 99.90%. A partir da metodologia proposta também torna-se possível implementação de um modelo de classificação de atividades encefálicas, com uma implementação mais amigável em dispositivo embarcado, pois utiliza o Python.

A implementação da metodologia mostra-se relevante como alternativa para auxílio ao conhecimento da atividade neuronal durante o desempenho de atividades cognitivas, pois são utilizadas características da atividade eletroencefálica durante o desenvolvimento desse tipo de atividade.

Diante das tarefas já realizadas nesse trabalho surge outros desafios a serem superados na continuidade do mesmo. Dentre esses desafios, diferentes aspectos da atividade cerebral podem ser estudadas na metodologia e técnicas podem ser utilizadas para melhorar o pré-processamento e estimação de fontes encefálicas, bem como aplicar outros classificadores para avaliar as métricas e testar hiperparâmetros dos algoritmos de classificação.

Referências Bibliográficas

- BARACK, D. L.; KRAKAUER, J. W. Two views on the cognitive brain. *Nature Reviews Neuroscience*, Nature Publishing Group, v. 22, n. 6, p. 359–371, 2021.
- BAŞAR, E. et al. Brain’s alpha, beta, gamma, delta, and theta oscillations in neuropsychiatric diseases: proposal for biomarker strategies. *Supplements to Clinical neurophysiology*, Elsevier, v. 62, p. 19–54, 2013.
- BREIMAN, L. Random forests. *Machine learning*, Springer, v. 45, n. 1, p. 5–32, 2001.
- BRUCE, A.; BRUCE, P. *Estatística Prática para Cientistas de Dados*. [S.l.]: Alta Books, 2019.
- CAVANAGH, J. F.; CASTELLANOS, J. Identification of canonical neural events during continuous gameplay of an 8-bit style video game. *NeuroImage*, Elsevier, v. 133, p. 1–13, 2016.
- CAVANAGH, J. F.; CASTELLANOS, J. "EEG: Continuous gameplay of an 8-bit style video game". [S.l.]: OpenNeuro, 2021.
- CHEAH, K. H. et al. Convolutional neural networks for classification of music-listening eeg: comparing 1d convolutional kernels with 2d kernels and cerebral laterality of musical influence. *Neural Computing and Applications*, Springer, v. 32, n. 13, p. 8867–8891, 2020.
- CUTLER, A.; CUTLER, D. R.; STEVENS, J. R. Random forests. In: *Ensemble machine learning*. [S.l.]: Springer, 2012. p. 157–175.
- DATTA, S. et al. Cognitive activity classification from eeg signals with an interval type-2 fuzzy system. In: *Advancements of medical electronics*. [S.l.]: Springer, 2015. p. 235–247.
- DU, W.; ZHAN, Z. Building decision tree classifier on private data. 2002.
- DUAN, W. et al. Reproducibility of power spectrum, functional connectivity and network construction in resting-state eeg. *Journal of Neuroscience Methods*, Elsevier, v. 348, p. 108985, 2021.
- FILHO, J. G. *APLICAÇÃO DE TÉCNICAS DE RECONFIGURAÇÃO DINÂMICA A PROJETO DE SVM*. 1–107 p. Dissertação (Dissertação de mestrado) — Escola Politécnica, 2010.
- FOX, M.; RAICHLE, M. Spontane svingninger i hjerneaktivitet observert med funksjonell magnetisk resonansavbildning. *Nat Rev Neurosci*, v. 8, p. 700–711, 2007.

- FRANK, M. J.; BADRE, D. How cognitive theory guides neuroscience. *Cognition*, Elsevier, v. 135, p. 14–20, 2015.
- FUKUNAGA, K. Introduction to statistical pattern classification academic press. *San Diego, California, USA*, 1990.
- FÜRBAASS, F. *EEG monitoring based on automatic detection of seizures and repetitive discharges*. Tese (Doutorado), 12 2017.
- GAERTNER, M. et al. Multi-class emotion recognition within the valence-arousal-dominance space using eeg. In: *AMCIS*. [S.l.: s.n.], 2021.
- GAGE, F. H. Structural plasticity of the adult brain. *Dialogues in clinical neuroscience*, Taylor & Francis, 2022.
- GAHO, A. A. et al. Eeg signals based brain source localization approaches. *International Journal of Advanced Computer Science and Applications*, Science and Information (SAI) Organization Limited, v. 9, n. 9, 2018.
- GALLINA, J. et al. Hemispheric differences in altered reactivity of brain oscillations at rest after posterior lesions. *Brain Structure and Function*, Springer, v. 227, n. 2, p. 709–723, 2022.
- GANZETTI, M.; MANTINI, D. Functional connectivity and oscillatory neuronal activity in the resting human brain. *Neuroscience*, Elsevier, v. 240, p. 297–309, 2013.
- GAZZANIGA, M. S. Organization of the human brain. *Science*, American Association for the Advancement of Science, v. 245, n. 4921, p. 947–952, 1989.
- GIRI, A.; KUMAR, L.; GANDHI, T. K. Brain source localization in head harmonics domain. *IEEE Transactions on Instrumentation and Measurement*, IEEE, v. 70, p. 1–10, 2020.
- GUERCHET, M. et al. Numbers of people with dementia worldwide: An update to the estimates in the world alzheimer report 2015. 2020.
- HAFEEZ, T. et al. Eeg in game user analysis: A framework for expertise classification during gameplay. *Plos one*, Public Library of Science San Francisco, CA USA, v. 16, n. 6, p. e0246913, 2021.
- HALL, J. E.; GUYTON, A. C. Tratado de fisiología médica. Elsevier, 2011.
- HOLDERRIETH, P. Brain-machine interfaces and neuroplasticity: Towards accurate and robust two-learner systems. *The New Collection*, p. 113.
- HUANG, S. et al. Applications of support vector machine (svm) learning in cancer genomics. *Cancer genomics & proteomics*, International Institute of Anticancer Research, v. 15, n. 1, p. 41–51, 2018.
- ILMONIEMI, R. Models of source currents in the brain. *Brain topography*, Springer, v. 5, n. 4, p. 331–336, 1993.
- JATOI, M. A.; KAMEL, N. Brain source localization using reduced eeg sensors. *Signal, Image and video processing*, Springer, v. 12, n. 8, p. 1447–1454, 2018.

- KLEIN, A. et al. Mindboggling morphometry of human brains. *PLoS computational biology*, Public Library of Science San Francisco, CA USA, v. 13, n. 2, p. e1005350, 2017.
- LI, X. et al. Eeg based emotion recognition: A tutorial and review. *ACM Computing Surveys (CSUR)*, ACM New York, NY, 2022.
- LORENA, A. C.; CARVAHO, A. C. P. L. F. de. *Introdução às Máquinas de Vetores Suporte*. [S.l.]: Instituto de Ciências Matemáticas e de Computação, 2003. ISSN 0103-2569.
- MAHESH, B. Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. [Internet], v. 9, p. 381–386, 2020.
- MARTIN, J. H. *Neuroanatomy text and atlas*. [S.l.]: McGraw-Hill, 2012.
- MCCRAE, C. S. et al. Neural activation changes in response to pain following cognitive behavioral therapy for patients with comorbid fibromyalgia and insomnia: a pilot study. *Journal of Clinical Sleep Medicine*, American Academy of Sleep Medicine, v. 18, n. 1, p. 203–215, 2022.
- MCGILCHRIST, I. Reciprocal organization of the cerebral hemispheres. *Dialogues in clinical neuroscience*, Taylor & Francis, 2022.
- MICHEL, C. M.; HE, B. Eeg source localization. *Handbook of clinical neurology*, Elsevier, v. 160, p. 85–101, 2019.
- MILLER, B. L.; CUMMINGS, J. L. *The human frontal lobes: Functions and disorders*. [S.l.]: Guilford Publications, 2017.
- MORIDERA, T. et al. High-resolution eeg source localization in segmentation-free head models based on finite-difference method and matching pursuit algorithm. *Frontiers in Neuroscience*, Frontiers, p. 789, 2021.
- MULLEN, T. R. et al. Real-time neuroimaging and cognitive monitoring using wearable dry eeg. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 62, n. 11, p. 2553–2567, 2015.
- PAWAR, D.; DHAGE, S. Multiclass covert speech classification using extreme learning machine. *Biomedical Engineering Letters*, Springer, v. 10, n. 2, p. 217–226, 2020.
- PETERSON, L. E. K-nearest neighbor. *Scholarpedia*, v. 4, n. 2, p. 1883, 2009.
- PURVES, D. et al. *Cognitive neuroscience*. [S.l.]: Sunderland: Sinauer Associates, Inc, 2008. v. 6.
- RASHEED, M. A. et al. Use of artificial intelligence on electroencephalogram (eeg) waveforms to predict failure in early school grades in children from a rural cohort in pakistan. *Plos one*, Public Library of Science San Francisco, CA USA, v. 16, n. 2, p. e0246236, 2021.
- ROLAND, P. E. *Brain activation*. [S.l.]: Wiley-Liss, 1993.
- RUFINO, H. L. P. *Algoritmo de Aprendizado Baseado em Máquina de Vetores de Suporte-Uma contribuição Para o Reconhecimento de Dados Desbalanceados*. 1–107 p. Dissertação (Tese de Doutorado) — Universidade Federal de Uberlândia, 2011.

RUIZ-GÓMEZ, S. J. et al. Automated multiclass classification of spontaneous eeg activity in alzheimer's disease and mild cognitive impairment. *Entropy*, MDPI, v. 20, n. 1, p. 35, 2018.

SAFAVIAN, S. R.; LANDGREBE, D. A survey of decision tree classifier methodology. *IEEE transactions on systems, man, and cybernetics*, IEEE, v. 21, n. 3, p. 660–674, 1991.

SOUSA, G. C. L. d. et al. Identificação do padrão de hipsarritmia em eletroencefalogramas: utilizando decomposição de sinais em pequenas ondas. Universidade Federal do Maranhão, 2019.

SOUZA, G. S. de; SANTOS, A. R. dos; DIAS, V. B. *Metodologia da pesquisa científica: a construção do conhecimento e do pensamento científico no processo de aprendizagem*. [S.l.]: Animal, 2013.

SWEILAM, N. H.; THARWAT, A.; MONIEM, N. A. Support vector machine for diagnosis cancer disease: A comparative study. *Egyptian Informatics Journal*, v. 11, n. 2, p. 81 – 92, 2010. ISSN 1110-8665. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1110866510000241>>.

TADEL, F. et al. Brainstorm: a user-friendly application for meg/eeg analysis. *Computational intelligence and neuroscience*, Hindawi, v. 2011, 2011.

TAKAHASHI, A. *Máquina de Vetores de Suporte Intervalar*. 1–72 p. Dissertação (Tese de Doutorado) — Universidade Federal do Rio Grande do Norte, 2012.

VANROSSUM, G.; DRAKE, F. L. *The python language reference*. [S.l.]: Python Software Foundation Amsterdam, Netherlands, 2010.

WANG, Y. et al. "A test-retest resting and cognitive state EEG dataset". [S.l.]: OpenNeuro, 2022.

WILKEY, E. D. et al. The effect of visual parameters on neural activation during nonsymbolic number comparison and its relation to math competency. *NeuroImage*, Elsevier, v. 159, p. 430–442, 2017.

XANTHOPOULOS, P.; PARDALOS, P. M.; TRAFALIS, T. B. Linear discriminant analysis. In: *Robust data mining*. [S.l.]: Springer, 2013. p. 27–33.

YE, J. Least squares linear discriminant analysis. In: *Proceedings of the 24th international conference on Machine learning*. [S.l.: s.n.], 2007. p. 1087–1093.

ZANELLA, L. C. H.; VIEIRA, E. M. F.; MORAES, M. *Técnicas de pesquisa*. [S.l.: s.n.], 2013.

ZHANG, J.-T. et al. Effects of craving behavioral intervention on neural substrates of cue-induced craving in internet gaming disorder. *NeuroImage: Clinical*, Elsevier, v. 12, p. 591–599, 2016.

ZHANG, N. et al. The effects of age on brain cortical activation and functional connectivity during video game-based finger-to-thumb opposition movement: A functional near-infrared spectroscopy study. *Neuroscience Letters*, Elsevier, v. 746, p. 135668, 2021.

CONTRIBUIÇÕES ALCANÇADAS COM ESTE TRABALHO

- Artigo publicado no evento Latin American Workshop on Computational Neuroscience (III LAWCN), publicada no Volume 1519 of Communications in Computer and Information Science (CCIS / Springer).
- Registro de programa de computador DAASINC, para processamento de sinais de ECG utilizando as técnicas de aprendizado de máquinas aplicadas neste trabalho.

Modelo baseado em aprendizado de máquinas para classificar atividades encefálicas cognitivas ^{*}

Juliana Mycaelle Silva^{1,2}[0000-0002-6518-6892], Gean C. Sousa¹[0000-0003-0797-1099], George V. S. Souza¹[0000-0003-4496-834X], Jonathan A. Queiroz¹[0000-0001-8006-6242], and Allan Kardec Barros¹[0000-0002-1654-0955]

¹ Universidade Federal do Maranhão, São Luís, Brasil

² juliana.mycaille@outlook.com

Abstract. Os diferentes tipos de atividades realizadas pelo sujeito, como ler; ouvir música; dançar; entre outras, conduzem a ativação das regiões encefálicas. Dentre essas atividades, as atividades cognitivas estão associadas a uma ativação de regiões encefálicas relacionadas com a aprendizagem, como as regiões do lóbulo frontal (Superior Frontal, Precuneus, entre outras). Diversos estudos vem sendo desenvolvidos para relacionar atividades cognitivas e as regiões encefálicas associadas. Este tipo de estudo é importante na compreensão da funcionalidade e conectividade do encéfalo e esse conhecimento pode servir de auxílio para o diagnóstico de anormalidades no seu funcionamento. Este estudo tem como objetivo a elaboração de um modelo classificador de atividades encefálicas durante o desenvolvimento de uma atividade cognitiva dentro das três categorias de atividade: Jogo de video game, música ou matemática. Para isso, utilizou-se dos sinais de Eletroencefalograma (EEG) coletados em duas bases de dados públicas e com uso da técnica de estimação de fontes encefálicas estimou-se as regiões anatômicas relacionadas a cada uma das atividades. Após essa determinação, foi treinado e testado um modelo baseado em aprendizado de máquinas que classifica o tipo de atividade desempenhada de acordo com as categorias de atividade. Dos resultados obtidos, podemos ressaltar o modelo classificador das atividades encefálicas elaborado com acurácia de 99,9%. Este trabalho se faz um passo importante na elaboração de um sistema de monitoramento de sinais de EEG considerando a ativação encefálica.

Keywords: Eletroencefalograma, EEG, Aprendizado de máquinas, Inteligência Artificial.

1 Introdução

O encéfalo é o principal órgão do sistema nervoso central [1] e a funcionalidade de cada região do encéfalo pode ser estudada para fornecer informações a cerca do desempenho nas atividades desenvolvidas pelo indivíduo [2, 1]. O conhecimento

^{*} Este trabalho foi financiado por FAPEMA (75121/2021).



REPÚBLICA FEDERATIVA DO BRASIL

MINISTÉRIO DA ECONOMIA

INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL

DIRETORIA DE PATENTES, PROGRAMAS DE COMPUTADOR E TOPOGRAFIAS DE CIRCUITOS INTEGRADOS

Certificado de Registro de Programa de Computador

Processo Nº: **BR512021001495-2**

O Instituto Nacional da Propriedade Industrial expede o presente certificado de registro de programa de computador, válido por 50 anos a partir de 1º de janeiro subsequente à data de 14/06/2021, em conformidade com o §2º, art. 2º da Lei 9.609, de 19 de Fevereiro de 1998.

Título: DAASINC

Data de publicação: 14/06/2021

Data de criação: 02/03/2021

Titular(es): UNIVERSIDADE FEDERAL DO MARANHÃO

Autor(es): MARCUS VINICIUS DE SOUSA LOPES; JONATHAN ARAUJO QUEIROZ; RAYANNE MARIA CUNHA SILVEIRA; JULIANA MYCAELLE OLIVEIRA SILVA; LUIS FILLYPE DA SILVA LAGO CUTRIM BARROS; GEAN CARLOS LOPES DE SOUSA; DAVI COSTA NASCIMENTO; RUTH GABRIELLE FERREIRA GOMES; ALLAN KARDECK DUAILIBE BARROS FILHO

Linguagem: MATLAB

Campo de aplicação: SD-09

Tipo de programa: AP-01; FA-01; UT-01

Algoritmo hash: OUTROS

Resumo digital hash: 426fde0f6a10b283e0af1759d99d404c

Expedido em: 06/07/2021

Aprovado por:

Joelson Gomes Pequeno

Chefe Substituto da DIPTO - PORTARIA/INPI/DIRPA Nº 02, DE 10 DE FEVEREIRO DE 2021