

Universidade de Brasília - UnB  
Faculdade UnB Gama - FGA  
Engenharia eletrônica

**Aplicação de Algoritmos de Processamento de  
Sinais e Aprendizagem de Máquina para  
Reconhecimento de Emoções Humanas a partir  
de Sinais de Eletroencefalografia**

Autor: Julia de Melo Franco Fernandes  
Orientador: Prof. Dr. Marcus Vinícius Chaffim Costa

Brasília, DF  
2022



Julia de Melo Franco Fernandes

**Aplicação de Algoritmos de Processamento de Sinais e  
Aprendizagem de Máquina para Reconhecimento de  
Emoções Humanas a partir de Sinais de  
Eletroencefalografia**

Monografia submetida ao curso de graduação em (Engenharia eletrônica) da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em (Engenharia eletrônica).

Universidade de Brasília - UnB

Faculdade UnB Gama - FGA

Orientador: Prof. Dr. Marcus Vinícius Chaffim Costa

Brasília, DF

2022

---

Julia de Melo Franco Fernandes    Aplicação de Algoritmos de Processamento de Sinais e Aprendizagem de Máquina para Reconhecimento de Emoções Humanas a partir de Sinais de Eletroencefalografia/ Julia de Melo Franco Fernandes. – Brasília, DF, 2022-    82 p. : il. (algumas color.) ; 30 cm.

Orientador: Prof. Dr. Marcus Vinícius Chaffim Costa

Trabalho de Conclusão de Curso – Universidade de Brasília - UnB

Faculdade UnB Gama - FGA , 2022.

1. EEG. 2. Emoções. I. Prof. Dr. Marcus Vinícius Chaffim Costa. II. Universidade de Brasília. III. Faculdade UnB Gama. IV. Aplicação de Algoritmos de Processamento de Sinais e Aprendizagem de Máquina para Reconhecimento de Emoções Humanas a partir de Sinais de Eletroencefalografia

CDU 02:141:005.6

---

# **Aplicação de Algoritmos de Processamento de Sinais e Aprendizagem de Máquina para Reconhecimento de Emoções Humanas a partir de Sinais de Eletroencefalografia**

Monografia submetida ao curso de graduação em (Engenharia eletrônica) da Universidade de Brasília, como requisito parcial para obtenção do Título de Bacharel em (Engenharia eletrônica).

Trabalho aprovado. Brasília, DF, 10 de maio de 2022:

---

**Prof. Dr. Marcus Vinícius Chaffim  
Costa**  
Orientador

---

**Prof. Dr. Cristiano Jacques Miosso**  
Convidado 1

---

**Prof. Dr. Flávio de Barros Vidal**  
Convidado 2

Brasília, DF  
2022

**À Deus e minha família.**

# Agradecimentos

Agradeço esse projeto primeiramente a Deus, por sempre me proteger e estar comigo nos momentos tristes.

Agradeço à minha mãe, Aline, por ser minha inspiração de vida, um exemplo de mulher forte e determinada que sempre fez de tudo para me dar o melhor, por me acompanhar em cada passo e estar lá quando pensei em desistir, por me ter dado o maior amor do mundo e me querer fazer viver sempre na minha melhor versão.

Agradeço à minha família, por me apoiar e sempre torcer pelo meu sucesso, em especial minha avó, Wilma, e minha irmã, Sophia, por me fazer querer dar o exemplo.

Agradeço a cada professor que passou na minha vida, desde o maternal até a faculdade, guardo cada ensino e pedaço de vocês comigo, o incentivo e carinho de vocês me ajudaram a continuar e a querer ser melhor e maior.

Agradeço aos meus amigos, que em momentos de estresse e ansiedade estiveram ali para me acalmar e me ajudar a descansar.

Agradeço ao SRBR (*Samsung RD Institute Brazil*), que me ajudou nessa conquista, dando ênfase aos meus amigos de projeto, destacando ao Giuliano, à Lin, minha chefe, por terem me dado orientações e calma em momentos decisivos.

*“O que as suas mãos tiverem que fazer,  
que o façam com toda a sua força, pois na sepultura,  
para onde você vai, não há atividade nem planejamento,  
não há conhecimento nem sabedoria.  
(Bíblia Sagrada, Eclesiastes 9:10)*

# Resumo

Este trabalho propõe a aplicação de algoritmos de Processamento Digital de Sinais e técnicas de Aprendizagem de Máquina à sinais de Eletroencefalografia (EEG), a fim de reconhecer emoções humanas, com o objetivo de colaborar com os estudos de identificação de sentimentos e ressaltar a importância de uma boa saúde mental.

A proposta desse projeto é analisar uma base de dados de sinais e, a partir dela, extrair características para um modelo determinar em qual quadrante a emoção desejada se encontra, sendo o quadrante definido por sua alta ou baixa intensidade e valência. Foram treinados algoritmos que continham dados com e sem extração de características em três domínios: tempo, frequência e tempo-frequência, além de terem sido divididos tanto em bandas de frequência quanto nos 14 canais de EEG da base DREAMER. Para cada conjunto de dados diferente foram treinados de três a quatro modelos, uma regressão linear, um K-ésimo Vizinho mais Próximo (*K-Nearest Neighbors*, KNN), uma floresta de decisão (*Random Forest*, RF) e uma Máquina de vetores de suporte (*Support Vector Machine*, SVM), com o objetivo final de ter dados o suficiente para haver uma conclusão sobre a melhor forma de se conseguir extrair a emoção desejada, conseguindo assim ter um conclusão mais precisa e certa sobre o resultado.

O documento foi dividido em introdução, explicação teórica, métodos e implementação, algoritmos utilizados, resultados e conclusão.

**Palavras-chaves:** EEG, BCI, Aprendizagem de Máquina, Identificação de Emoções, Saúde Mental.



# Abstract

This work proposes an application of Digital Signal Processing algorithms and Machine Learning techniques to electroencephalography (EEG) signals, in order to recognize human emotions, to collaborate with the studies of feelings identification and to emphasize the importance of good mental health. The purpose of this project was to analyze a database and, from it, extract characteristics to discover in which quadrant the desired emotion is. The quadrant is defined by its high or low arousal and valence. Algorithms were trained with data with and without feature selection in three domains: time, frequency and time-frequency, in addition to being divided into both frequency bands and the 14 EEG channels of the DREAMER base. For each different dataframe, three to four models were trained: a linear regression, a K-th Nearest Neighbor (KNN), a random forest (RF) and a support vector machine (SVM), with the ultimate goal of having enough data to reach a conclusion on the best way to extract the desired emotion, in addition to improving the study of artificial intelligence, thus achieving a more accurate and certain conclusion. about the result.

The document was divided into introduction, theoretical explanation, methods and implementation, algorithms, results and conclusion.

**Key-words:** EEG; BCI; *Machine Learning*; Emotion Identification; Mental Health.

# Lista de ilustrações

Figura 1 – Córtex cerebral, modificado de (WOLPAW, 2013) . . . . .	25
Figura 2 – Plano valência <i>vs</i> excitação, retirado de (RUSSELL, 1980) . . . . .	38
Figura 3 – Sistema 10-20, retirado e autorizado por (RODRIGUES, 2018) . . . . .	39
Figura 4 – Tabela das características do EEG, modificado de (FREITAS; FILHO, 2008) . . . . .	40
Figura 5 – Fluxo básico de algoritmo de aprendizagem de máquina. . . . .	41
Figura 6 – Diagrama inteligência artificial . . . . .	42
Figura 7 – Gráfico de KNN, retirado de (SAKURAI, 2020) . . . . .	43
Figura 8 – Fluxograma do algoritmo proposto . . . . .	59
Figura 9 – Gráfico de distribuição de vídeos por valência . . . . .	60
Figura 10 – Gráfico de distribuição de vídeos por valência . . . . .	60
Figura 11 – Gráfico de distribuição de gênero por valência . . . . .	61
Figura 12 – Gráfico de distribuição de gênero por atividade . . . . .	62
Figura 13 – Gráfico de distribuição de idade por valência . . . . .	62
Figura 14 – Gráfico de distribuição de idade por atividade . . . . .	63
Figura 15 – Fluxograma do algoritmo com seleção de características . . . . .	64
Figura 16 – Fluxograma do algoritmo sem seleção de características . . . . .	66

# Lista de tabelas

Tabela 1 – Resumo características das bases . . . . .	51
Tabela 2 – Matriz de confusão . . . . .	56
Tabela 3 – Resumo do algoritmo . . . . .	67
Tabela 4 – Resumo dos resultados para atividade no domínio do tempo com seleção de características . . . . .	69
Tabela 5 – Resumo dos resultados para valência no domínio do tempo com seleção de características . . . . .	69
Tabela 6 – Resumo dos resultados para atividade no domínio da frequência com seleção de características . . . . .	69
Tabela 7 – Resumo dos resultados para valência no domínio da frequência com seleção de características . . . . .	70
Tabela 8 – Resumo dos resultados para atividade no domínio de tempo-frequência com seleção de características . . . . .	70
Tabela 9 – Resumo dos resultados para valência no domínio de tempo-frequência com seleção de características . . . . .	70
Tabela 10 – Resumo dos resultados para atividade com a combinação de vários domínios com seleção de características . . . . .	71
Tabela 11 – Resumo dos resultados para valência com a combinação de vários domínios com seleção de características . . . . .	71
Tabela 12 – Resumo dos resultados para atividade no domínio do tempo sem seleção de características . . . . .	72
Tabela 13 – Resumo dos resultados para valência no domínio do tempo sem seleção de características . . . . .	72
Tabela 14 – Resumo dos resultados para atividade no domínio da frequência sem seleção de características . . . . .	72
Tabela 15 – Resumo dos resultados para valência no domínio da frequência sem seleção de características . . . . .	73
Tabela 16 – Resumo dos resultados para atividade no domínio do tempo-frequência sem seleção de características . . . . .	73
Tabela 17 – Resumo dos resultados para valência no domínio do tempo-frequência sem seleção de características . . . . .	73
Tabela 18 – Maiores resultados com seleção de características de Atividade . . . . .	74
Tabela 19 – Maiores resultados com seleção de características de valência . . . . .	75
Tabela 20 – Maiores resultados sem seleção de características Atividade. . . . .	75
Tabela 21 – Maiores resultados sem seleção de características Valência. . . . .	75

# Lista de abreviaturas e siglas

AIP	Área anterior média intraparietal
BCI	<i>Brain-Computer Interface</i> (Interface Cérebro-Máquina)
CNN	<i>Convolutional Neural Networks</i> (Rede Neural Convolutacional)
CSP	<i>Common Spatial Pattern</i> (Padrão Espacial Comum)
DASM	<i>Differential asymmetry</i> (Assimetria diferencial)
DE	<i>Differential entropy</i> (Entropia diferencial)
DEAP	<i>Database for Emotion Analysis using Physiological Signals</i> (Banco de dados para análise de emoções usando sinais fisiológicos)
ECoG	Eletrocorticografia
EEG	Eletroencefalografia
EMG	Eletromiografia
EP	<i>Evoked Potentials</i> (Potenciais Evocados)
ERP	<i>Event related Potentials</i> (Potenciais relacionados a Eventos)
FFT	<i>Fast Fourier transform</i> (Transformada rápida de Fourier)
GA	<i>Genetic Algorithm</i> (Algoritmo Genético)
IADS	<i>the International Affective Digitized Sound System</i> (Sistema de som digital afetivo internacional)
IAPS	<i>International Affective Picture System</i> (Sistema Internacional de Imagens Afetivas)
ICA	<i>Independent component analysis</i> (Análise de componentes independentes)
LFP	<i>Local Field Potential</i> (Potenciais locais de campo)
LIP	<i>Lateral intraparietal cortex</i> (Córtex lateral intraparietal)
M1	Córtex motor primário
MIP	<i>Medial intraparietal area</i> (Área anterior intraparietal)

MPED	<i>Multi-Modal Physiological Emotion Database</i> (Banco de dados de emoções fisiológicas multimodais)
OMS	Organização Mundial da Saúde
OPAS	Organização Pan-Americana da Saúde
PCA	<i>Principal component analysis</i> (Análise de componentes principais)
PFC	<i>Prefrontal cortex</i> (Córtex pré-frontal)
PM	<i>Premotor cortex</i> (Córtex pré-motor)
PPC	<i>Posterior parietal cortex</i> (Córtex posterior parietal)
PSD	<i>Power spectral density</i> (Densidade espectral de potência)
RASM	<i>Rational asymmetry</i> (Assimetria racional)
RF	Rádio frequência
ROC	<i>Receiver Operating Characteristic Curve</i> (Curva Característica de Operação do Receptor)
S1	Córtex somatossensorial primário
SDA	<i>Stacked Denoising Autoencoder</i>
SNC	Sistema Nervoso Central
SVM	<i>Support Vector Machine</i> (Máquinas de Vetores de Suporte)
VIP	<i>Ventral intraparietal area</i> (Área ventral intraparietal)
WT	<i>Wavelet transform</i> (Transformada de Wavelet)

# Lista de símbolos

$\alpha$	Acurácia
$\epsilon$	Especificidade
$\omega$	F-score
FN	Falsos negativos
FP	Falsos positivos
N	Total de elementos
$\phi$	Precisão
$\eta$	Preditos-negativos
$\rho$	Preditos-positivos
$\tau$	Reais-negativos
$\mu$	Reais-positivos
VN	Verdadeiros negativos
VP	Verdadeiros positivos

# Sumário

1	<b>INTRODUÇÃO</b>	16
1.1	Justificativa	18
1.2	Objetivo geral	18
1.3	Objetivos específicos	18
1.4	Organização do documento	19
2	<b>BREVES TÓPICOS SOBRE ANATOMIA HUMANA</b>	20
2.1	Células nervosas, seus circuitos e comportamento	20
2.2	Sistema nervoso	20
2.3	O básico da atividade neuronal	23
2.4	Córtex	24
2.5	Áreas do subcórtex	24
2.6	Áreas sensoriais e motoras do córtex	26
2.7	Áreas cerebrais corticais e controle motor	27
3	<b>INTERFACES CÉREBRO-MÁQUINA AFETIVAS E ANÁLISE DE EMOÇÕES</b>	30
3.1	BCI não-invasivo	30
3.2	BCI invasivo	30
3.3	<i>Spikes</i>	31
3.4	Potenciais locais de campo	31
3.5	Eletrocorticografia	32
3.6	Gravações, resolução espacial e fontes cerebrais	32
3.7	Eletrodo de referência	33
3.8	Eletroencefalografia e suas limitações	33
3.9	Atividade metabólica cerebral	34
3.10	Fluxo sanguíneo	35
3.11	Resposta da atividade cerebral	35
3.12	Emoção x Sentimento	36
3.13	Métodos e análises de emoções	36
4	<b>ANÁLISE DE SINAIS E APRENDIZAGEM DE MÁQUINA</b>	39
4.1	Regressão Logística	42
4.2	K-ésimo Vizinho mais Próximo - KNN	42
4.3	Florestas aleatórias	43
4.4	Máquina de vetores de suporte	43

4.5	Técnicas . . . . .	44
4.6	Estudos prévios . . . . .	45
5	<b>MÉTODO E IMPLEMENTAÇÃO</b> . . . . .	47
5.1	Base de dados . . . . .	47
5.2	Pré-processamento dos sinais . . . . .	52
5.3	Extração de características . . . . .	52
5.4	Seleção de características . . . . .	53
5.5	Tratamento pré-classificação . . . . .	54
5.6	Classificação . . . . .	54
5.7	Métricas de avaliação . . . . .	55
6	<b>ALGORITMOS UTILIZADOS</b> . . . . .	58
6.1	Diagrama de blocos . . . . .	58
6.2	Análise dos dados . . . . .	58
6.3	Com seleção de características . . . . .	61
6.4	Sem seleção de características . . . . .	65
6.5	Elementos em comum . . . . .	65
6.6	Bibliotecas computacionais . . . . .	66
7	<b>RESULTADOS E DISCUSSÕES</b> . . . . .	68
7.1	Com seleção de características . . . . .	68
7.2	Sem seleção de características . . . . .	71
8	<b>CONCLUSÃO</b> . . . . .	74
8.1	Trabalhos futuros . . . . .	76
	<b>REFERÊNCIAS</b> . . . . .	77



# 1 Introdução

A saúde mental, compreensão humana e interação com a sociedade são assuntos cada vez mais recorrentes no dia a dia. De acordo com a Organização Mundial da Saúde (OMS) e com a Sociedade Brasileira de Clínica Médica, a juventude da atual geração foi considerada aquela com os piores indicadores de saúde mental em décadas recentes, com alta probabilidade da depressão ser a doença mais comum do mundo em 2030 (MÉDICA, 2009). Os sintomas de ansiedade dobraram em jovens na pandemia da COVID-19, a taxa de depressão subiu de 12,8% para 25,2% e de ansiedade de 11,6% para 20,5% (RACINE et al., 2021). Portanto, é necessário um maior cuidado e estudo sobre esses casos. Há diversas formas de se analisar uma emoção como: por macro expressões, micro expressões, por textos, em terapia, pelo tom de voz, e também pela análise dos sinais de eletroencefalografia, que é o objetivo de estudo deste trabalho, cujo fim último poderia ser prover uma colaboração com a psicologia e a psiquiatria para auxiliar na melhora dos casos de saúde mental da população.

De acordo com a Organização Pan-Americana da Saúde (OPAS), os determinantes da saúde mental vão além de atributos individuais como a capacidade de desenvolver plena inteligência emocional, mas abrangem fatores sociais, culturais, econômicos, políticos e ambientais, além dos fatores de genética, estresse, nutrição. Também é visto que os sistemas de saúde em inúmeros países ainda não conseguem responder à altura da quantidade de transtornos mentais que existem. Em países mais pobres a taxa de pessoas que não recebem tratamento fica entre 76% a 85%, já em países mais ricos fica em torno de 35% a 50%, ainda um número alto. Um fator agravante a tais números é o fato de haver baixa qualidade de muitos serviços e cuidados (SAÚDE, b).

Analisando de modo mais específico, a depressão, na faixa de 10 a 19 anos, é uma das principais causas de doença nos adolescentes, sendo o suicídio a terceira principal causa mundial de morte (SAÚDE, a). Devido a esses dados alarmantes, a preocupação para um melhor tratamento ganha relevância.

A análise dos sinais biológicos é capaz de propiciar evidências mais objetivas e juntamente com a terapia, pode ajudar mais rapidamente na melhora dos pacientes que precisam de tratamento. A exposição de relações e sentimentos é difícil de ser passada ao psicólogo, da mesma forma que a fala do médico ao paciente pode ser não interpretada corretamente. No estudo (IBANEZ et al., 2014), se pode observar até que em relação aos medicamentos para se tomar no tratamento 29,6% dos pacientes não aderiram e 51,9% não sabiam a dose do remédio.

A função de ter uma certeza maior e mais exata do que o paciente está sentindo consegue colaborar tanto com a interpretação quanto com a prescrição da medicação

certa, fazendo com que essa tendência de se utilizar sinais pessoais para um tratamento melhorado, facilitado se desenvolva mais.

A eletroencefalografia possui vantagens muito claras para esse desenvolvimento, uma vez que é uma técnica não-invasiva, possui uma ótima resolução temporal, tem baixo custo, podendo ser portátil, já sendo um sinal que ajuda a diagnosticar ansiedade (IMPERATORI et al., 2019) e outras doenças psiquiátricas/não-psiquiátricas como - epilepsia, perda de consciência, tumores, apneias, neuroses, histeria, autismo (ASSOCIATION et al., 2014), (VANITHA; KRISHNAN, 2017), porém como todo sinal também possui suas desvantagens: o EEG é um sinal muito ruidoso e possui uma baixa resolução espacial, podendo dificultar seu estudo.

Então, é proposto um trabalho cujo resultado poderá contribuir com as pesquisas recentes acerca da importância do EEG na área de identificação de emoções, ajudando análises sobre os métodos e reforçando a relevância da preocupação com a saúde mental e de como se tratar as pessoas ao seu redor no cotidiano. No geral o método de extração de características é bem parecido nas bases DEAP (KOELSTRA et al., 2011), MPED (SONG et al., 2019), SEED (ZHENG; LU, 2015) e DREAMER (KATSIKIANNIS; RAMZAN, 2017). Todas foram coletadas a partir da observação de vídeos e músicas seguida de auto-avaliação dos sentimentos observados durante aquele momento, além de uma coleta de sentimento neutro como base de comparação.

A análise e reconhecimento de emoções possuem questões éticas e pessoais, em que é possível invadir a privacidade, o fator de ser extraído por sinais de eletroencefalografia vêm com a vantagem de que cada pessoa deve saber e autorizar o seu uso e conhecimento, a partir disso essa maneira de se reconhecer sentimentos se torna ética e praticável. Enfatizando a importância de ser um método automático devido ao fator de ação e reação de psiquiatras e psicólogos perceberem e não se confundirem no momento de prescrever medicações e indicações a cada paciente.

Em (TORRES et al., 2020a), é apresentada uma coletânea de pesquisas e métodos utilizados pelas últimas pesquisas sobre esse tema, os algoritmos mais utilizados e de melhor desempenho. A partir da análise da bibliografia apresentada neste artigo, foram escolhidos os métodos para reafirmar as técnicas de melhor desempenho ou rejeitar determinado método em detrimento de outros mais relevantes. Já em (SUHAIMI; MOUNTSTEPHENS; TEO, 2020) e em (EGGER; LEY; HANKE, 2019), são relatadas: as formas de coleta de dados, as emoções mais utilizadas para a identificação, a disposição dos eletrodos, uma explicação biológica cerebral e emocional, analisando as melhores base de dados para a pesquisa e da mesma forma foi feita uma análise de toda sua bibliografia, observando e analisando para selecionar as melhores formas e dados para se tratar desse assunto.

Esse projeto foi pensado observando a possibilidade de servir como ferramenta auxiliar no manejo para melhoria da saúde mental dos jovens, principalmente durante o

isolamento social imposto pela mais recente pandemia.

## 1.1 Justificativa

É proposta uma pesquisa em que se analisa sinais de eletroencefalografia (EEG) para compreensão e reconhecimento de emoções humanas, a partir de uma base de dados, por meio de algoritmos de aprendizado de máquina baseados em aprendizagem profunda.

O EEG é um sinal que está relacionado a aspectos do funcionamento cerebral, e partir disso, uma interpretação mais exata de emoções poderá ser identificada. O sinal de eletroencefalografia, como já mencionado, possui uma boa resolução temporal, apesar de uma baixa resolução espacial, permitindo assim o estudo de mudanças de fase emocional, sendo um método não invasivo, rápido e barato (NIEMIC, 2004).

O estudo de reconhecimento de emoções por EEG que se baseia na interação cérebro-computador (BCI) é chamado de BCI afetivo (aBCI). Atualmente, no mercado há diferentes tipos de dispositivos de BCI, podendo se encontrar equipamentos de baixo custo e fáceis de se usar, facilitando ainda mais o estudo (BASTOS-FILHO, 2020).

O que se investiga é a possibilidade de identificar quais emoções eram prevalentes a cada momento do exame, a fim de ter uma forma de discernimento mais profunda sobre os sentimentos pessoais. O projeto visa colaborar com o estudo de emoções através do EEG, trazendo diversas alternativas para o processamento dos sinais e posterior análise a fim de promover o reconhecimento de possíveis padrões, mostrando as diferenças de tratamento de dados e os diferentes modelos e como isso influencia no resultado final de descobrir a intensidade e atividade da emoção sentida por uma pessoa.

## 1.2 Objetivo geral

Este trabalho propõe a aplicação de algoritmos de Processamento Digital de Sinais e técnicas de Aprendizagem de Máquina à sinais de eletroencefalografia, a fim de reconhecer emoções humanas, utilizando o plano Valência *vs* Atividade, mostrando as diferenças, vantagens e desvantagens de cada método utilizado.

## 1.3 Objetivos específicos

O projeto tem como objetivos específicos os seguintes tópicos:

- Extrair e processar de diversas formas o sinal;
- Avaliação de técnicas de classificação final;
- Estabelecimento de algoritmos para processamento do EEG;

- Identificar em qual quadrante do plano as emoções eram prevalentes a cada momento do EEG;
- Testes com treinamento usando uma base de EEG pré-processada em diversos domínios; e
- Comparação objetiva dos algoritmos por acurácia e precisão.

## 1.4 Organização do documento

O documento está organizado da seguinte forma: no capítulo 2 se inicia a fundamentação teórica da pesquisa, tendo como foco os conceitos e fundamentos da anatomia cerebral e seu funcionamento. O capítulo 3 apresenta a caracterização da psicologia em relação ao significado de emoção e sentimento e qual o contexto utilizado no projeto; o capítulo 4, último de fundamentação teórica, resume os conceitos de sinais e sistemas, assim como de aprendizagem de máquina (*machine learning*) e os estudos prévios encontrados na revisão bibliográfica.

No capítulo 5 é explicado o método e implementação do sistema que foi desenvolvido, o capítulo 6 mostra os algoritmos abordados no trabalho, o capítulo 7 mostra os resultados dos algoritmos e, por fim, o capítulo 8 traz a conclusão final do trabalho.

## 2 Breves Tópicos sobre Anatomia Humana

Para o estudo das emoções e seu funcionamento biológico no corpo humano é necessário um estudo de como opera a anatomia cerebral e de que maneira o sentimento vai afetar os sinais elétricos cerebrais. A partir disso terá um capítulo baseado nos livros de (BEAR; CONNORS; PARADISO, 2002), (KANDEL et al., 2014) e (WOLPAW, 2013), abordando o princípio da anatomia e funcionamento cerebral.

### 2.1 Células nervosas, seus circuitos e comportamento

O comportamento humano é influenciado por uma variedade de receptores sensoriais, a partir dos quais o sistema nervoso (SN) analisa o acontecimento, e com essa análise determina o comportamento final. O encéfalo é o órgão mais ativo na percepção, assim como na memória para referência futura e nas respostas imediatas (KANDEL et al., 2014).

Como mencionado, as unidades básicas do encéfalo são as células nervosas: o encéfalo possui cerca de  $10^{11}$  neurônios. É da organização dessas células que o comportamento humano mais depende. Há um princípio organizacional fundamental em que as células com similaridade em funções conseguem produzir diferentes ações, de acordo com a suas interconexões. Para se entender melhor o comportamento humano deve-se manter o foco e pesquisar cinco características básicas do SN: os componentes individuais das células, como eles produzem os sinais internamente, como são os padrões de conexões entre as células nervosas e entre elas e seus alvos, a relação de interconexão e suas formas de modificação (KANDEL et al., 2014).

### 2.2 Sistema nervoso

O sistema nervoso possui dois tipos de células, as nervosas e a glias. O primeiro requisito para se entender o comportamento humano é entender as estruturas: o neurônio possui quatro regiões definidas, o corpo celular, os dendritos, o axônio e os terminais pré-sinápticos. O corpo celular é considerado o centro metabólico da célula, já que possui o núcleo e o retículo endoplasmático, ele têm dois tipos de estruturas: dendritos curtos e um axônio longo e tubular. Os dendritos têm função de recepção de sinais aferentes, portanto carregam sinais a outros neurônios. Já o axônio transporta sinais elétrico a longas distâncias, ou seja, é o transmissor. No final de sua estrutura, ele se divide em ramificações, que fazem contatos com outros neurônios, utilizando da sinapse para se comunicar

(WOLPAW, 2013).

Outro conceito é o de potenciais de ação, que são sinais em que o encéfalo recebe, analisa e transmite informações, e essa informação é determinada pela maneira em que se chega ao encéfalo, e essa função é chamada de integrativa. A fim de aumentar a velocidade de ação, os neurônios possuem a bainha de mielina, uma substância lipídica que faz com que os sinais “cortem o caminho”, os fazendo “pular” entre suas pontas, aumentando sua velocidade de propagação (WOLPAW, 2013).

A célula nervosa também possui suas fases: a pré-sináptica, que é quando a célula está transmitindo o sinal (em que se transmite sinais por suas ramificações dos axônios, podendo ser chamados de terminais nervosos), e a pós-sináptica, quando a célula vira receptora, e cada tipo de célula são separados pela fenda sináptica (KANDEL et al., 2014). A partir do método de coloração com prata foi possível observar o funcionamento único de um neurônio, comprovando que não há continuidade citoplasmática entre eles, além de poder analisar as diferentes estruturas, dividindo-as em classes e observando suas conexões.

O princípio da polarização dinâmica diz que os sinais elétricos de uma célula fluem em direção única, em sentido dos receptivos neuronais para a zona de gatilho e o princípio de especificidade conectiva afirma que as conexões nervosas não são aleatórias, e sim específicas (WOLPAW, 2013). Com esses dois princípios, foi possível ampliar o estudo na comunicação.

A principal distinção entre os neurônios é o seu número de processos: neurônios unipolares, são mais simples, em que há somente um processo e que normalmente se origina de ramificações, neurônios bipolares, em que há dois processos, um que é a partir de dendritos, recebendo sinais de outras células, e outro do axônio que leva a informação para o sistema nervoso central (SNC). Dentro os bipolares há uma subdivisão, que seriam os pseudo unipolares, em que eles são inicialmente bipolares, porém os processos se unem e formam um só, tornando uma única estrutura continua, e por último os neurônios multipolares, que são os de maioria no sistema, e dentro deles há formas bastantes variadas, em que formam mais de dois processos (WOLPAW, 2013).

Neurônios também são divididos por suas funções, sendo os três principais tipos os sensoriais, os motores e os interneurônios. Os sensoriais, recebem informação vinda dos sensores do corpo, ajudando na percepção e coordenação motora, e podem ser considerados aferentes, já que transmitem para o SN. Os motores são os que obedecem às ordens do encéfalo, distribuindo essa ordem para medula espinal, músculos e glândulas, e os interneurônios são de retransmissão (WOLPAW, 2013). Lembrando que em cada classificação sempre é possível fazer subdivisões e junções de funções, sendo possível células como os interneurônios sensoriais.

Os outros tipos de células presentes no sistema nervoso são as gliais. Muito mais numerosas, elas ficam ao redor das células nervosas, sendo que elas não podem ser elétrica-

mente excitadas nem envolvidas na sinalização elétrica. Essas células também podem ser divididas a partir de vários tópicos, suas duas divisões principais são: as micróglia, que fazem parte do sistema imunológico, e as macroglia, se subdividindo em oligodendrócitos, Schwann e astrócitos (WOLPAW, 2013). As duas primeiras são consideradas pequenas e com poucos processos, formam a bainha de mielina mencionada anteriormente, suas diferenças são que os oligodendrócitos são vistos no SNC e as de Schwann no sistema nervoso periférico. Já os astrócitos também são subdivididos entre os protoplasmáticos, que são encontrados nas substâncias cinzentas, e os fibrosos, encontrados nas substâncias brancas. Suas funções ainda não são conhecidas e são vistas como não essenciais, dando apenas suporte na separação de células, sendo permeáveis a  $K^+$ , atuando em manutenção e nutrindo neurônios vizinhos.

Os comportamentos são únicos e pessoais, eles são mediados por neurônios interconectados, em que são determinados de acordo com as conexões feitas e com a interpretação do cérebro (WOLPAW, 2013). O reflexo, que é um comportamento “não pensado” é produzido por sinais elétricos em que carregam informações sensoriais e de atividades neuronais, de comando motores e inibitórios. As ações motoras podem vir das ações de um neurônio que ativa várias células, conexão divergentes, ou de uma célula motora receber informações de vários neurônios, conexões convergentes.

Muitas pessoas tendem a pensar que os sinais importantes são excitatórios, porém os sinais inibitórios são muito importantes devido a sua redução de chance de disparo. Com as conexões excitatórias, levam os músculos à contração, e com os inibitórios evitam-na, sendo chamado de pró-ação inibitória. Há também a inibição recíproca em que os dois se inibem, e a retroalimentação inibitória que limita a estimulação motora.

A forma de organização celular é não variável, ou seja, para a produção comportamental as células nervosas devem gerar quatro sinais em sequência: sinal aferente, de gatilho, condutor e eferente, além da obrigatoriedade de possuir ao menos quatro elementos: receptivo, aditivo, de sinalização e secretório.

Os sinais gerados são determinados pelas propriedades elétricas da membrana (KANDEL et al., 2014). O potencial de repouso tem como definição a célula com uma diferença de tensão interna e externa quando não está em atividade. E quando a célula está em atividade essa tensão diminui devido as trocas de  $Na^+$  e  $K^+$  entre as membranas. Sendo uma célula excitável quando seu potencial de membrana pode ser modificado de uma maneira rápida. Sua redução é chamada de despolarização, excitatória, e seu aumento de hiperpolarização, inibitória.

Com o repouso, significa que não há fluxo de corrente externo, em sensoriais esse fluxo pode começar a partir de um estímulo nos sensores, em que se ativa proteínas, transformando em um fluxo de corrente para respostas (KANDEL et al., 2014). O potencial receptor é um sinal dentro da célula em que surge a partir da alteração do potencial membrana alterado pela corrente. Quanto maior a amplitude e duração desse sinal, maior

o estiramento muscular. E potencial de ação é seu oposto, eles são excitatórios, e são encontrados na retina, sendo uma das representações do estiramento. Potencial sináptico diz a respeito à alteração do potencial de membrana da célula motora a partir do fluxo de corrente.

O potencial de ação funciona somente no limiar estabelecido, ou seja, quando é produzido um sinal abaixo não há estímulos e um sinal acima a amplitude é constante, ele não diminui com sua transmissão já que é constantemente regenerado, sendo muito estereotipados (BEAR; CONNORS; PARADISO, 2002). Suas informações se diferem de acordo com o número de potenciais e o tempo medido entre eles, ou seja, sua intensidade e sensação depende de suas frequências e a duração, do período. Podendo ser formado devido a um potencial sináptico excitatório em células não espontâneas e modulado em células ativas. Além de que, quando o sinal é potencial sináptico inibitório, esse potencial em as células ativas se torna um importante modulador. Sendo esses as diferenças nas informações desse tipo de potencial, ou seja, são similares nas formas, porém a maneira difere a função.

Os neurotransmissores são outros pontos importantes no nosso organismo, são substâncias químicas liberadas em neurônios, formando certas sensações e respostas em nosso corpo. As moléculas são mantidas em vesículas sinápticas, que esperam nas zonas ativas para sua liberação, quando comandado elas se fundem com a membrana plasmática do neurônio (exocitose) (BEAR; CONNORS; PARADISO, 2002). Lembrando que neurotransmissores tem efeitos diferentes em neurônios diferentes.

As células nervosas são de diversos tipos, e diferentes em nível molecular, alguns neurônios não geram potenciais de ações, outros não precisam de sensores para disparar os potenciais, alguns podem ter combinações de canais iônicos. Além do fator dito anteriormente, que as substâncias químicas agem de diferentes maneiras em cada neurônio e de terem doenças extremamente seletivas, como a tão conhecida de Parkinson, que ataca os interneurônios, que utilizam a dopamina de neurotransmissor (WOLPAW, 2013). Portanto, a simplicidade e similaridade da sinalização dos neurônios nos ajuda a compreender melhor seu funcionamento, mesmo cada célula ter reações e funções diferentes.

## 2.3 O básico da atividade neuronal

Como já é de conhecimento prévio, o cérebro humano pode ser eletricamente excitável, em um estudo antigo, Hitzig e Fritsch chamaram a área do cérebro conhecida como Córtex motor primário (CARLSON; DEVINSKY, 2009). Atualmente, o excitamento cerebral é utilizado para mapear o cérebro, a fim de fazer tratamentos como os de tumores e de epilepsia. Em um experimento posterior cientistas foram capazes de fazer gravações breves de spikes, que como mencionado anteriormente, são unidades básicas da comuni-



cação e transferência de informação do sistema nervoso, sendo possível, hoje em dia, a gravação de vários ao mesmo tempo.

O mapa conhecido como “motor homunculus” é uma imagem em que se associa cada parte do cérebro com as funções em que controla, no mapa certas partes do corpo são distorcidas, e isso se explica com o fato de que umas partes são mais complexas que outras, exigindo “menos” ou “mais” espaço que outras. O cérebro equivale a dois hemisférios, que são cobertos pelo córtex, o córtex ou “área cinza” do cérebro é chamado assim devido a sua quantidade de neurônios e a “área branca” devido a quantidade de fibras (WOLPAW, 2013). A pesquisa de BCI, no geral, é em relação ao córtex, pois é responsável pelo planejamento de movimentos, além de ser um lugar acessível para fins experimentais.

## 2.4 Córtex

O córtex é dividido em quatro partes: os lobos central, parietal, occipital e temporal (Figura 1). Os lobos frontal e parietal são separados pelo sulco central, que é um sulco, vindo depois o lobo occipital. O lobo central é bem desenvolvido em humanos, em que suas funções são consideradas de alta ordem, como funções de comportamento, personalidade e tomada de decisões, já o lobo occipital consiste mais em áreas visuais. O lobo posterior parietal é a região que recebe entradas visuais e auditivas (WOLPAW, 2013).

O córtex cerebral também tem divisões históricas: neocórtex, paleocórtex e arquicórtex. O neocórtex é a área mais atual, subdividido em camadas, moleculares, formada por neurônios e muitos dendritos; exterior granular, que contém células estrelas e piramidais; interior granular, que contém neurônios não piramidais e nela há várias entradas; interior piramidal, contendo células piramidais; e a multiforme, que contém uma variedade de células. Já o paleocórtex se localiza no final do cérebro e possui a função do olfato e o arquicórtex fica dentro do lobo temporal e possui uma grande participação na função de criação de novas memórias.

As fibras que saem do córtex são chamadas de corticais eferentes e as que entram no córtex, corticais aferentes. Como o córtex é uma área de mais acesso para eletrodos e é muito envolvido em funções motoras e de comunicação, se confirma mais uma vez que ele é uma área de grande interesse para o BCI. Para colocar os eletrodos, é identificadas regiões cerebrais que são providas de marcas da superfície cortical, que são utilizadas como guias (WOLPAW, 2013).

## 2.5 Áreas do subcórtex

Há também a área conhecida como subcórtex, nela estão incluídos o tálamo, tronco cerebral, cerebelo e gânglios basais. O tálamo é localizado no cérebro, servindo como ponte

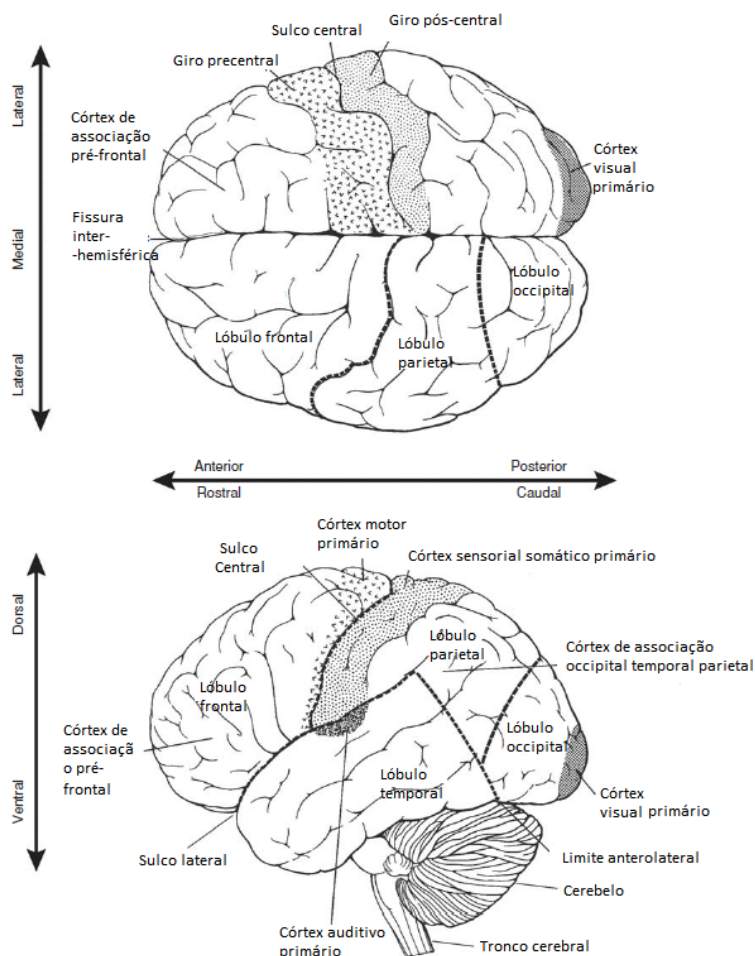


Figura 1 – Córtex cerebral, modificado de (WOLPAW, 2013)

para o córtex para entradas sensoriais da medula espinhal e outras áreas do subcórtex, sendo sua principal entrada. Formado por vários núcleos: lateral, medial, anterior, intra laminar, podendo ser subdivididos, eles podem estar envolvidos na regulação da excitação, emoção e do estado cognitivo. Seus principais núcleos, ventral anterior e ventral lateral, transmitem informações dos gânglios e do cérebro.

O tronco cerebral está na base do cérebro, entre a medula espinhal e o diencéfalo, ele possui vários nervos pela medula espinhal, além de vários sensores e neurônios (WOLPAW, 2013).

A gânglios basal é situada no fundo do cérebro, sendo extremamente ligada com o córtex e possuindo um grande papel no movimento (doença de Parkinson é relacionada a essa área). Possui núcleos interconectados, sua entrada primaria é conhecida como *striatum*, que recebe informações do córtex, tronco cerebral e do tálamo (WOLPAW, 2013). Globo pálido e substância negra também são partes do sistema e mandam fibras inibitórias para o ventral anterior e lateral do tálamo. São envolvidos com a expectativa de recompensa e predição das ações para otimizá-las, tendo como papel principal ensinar novos movimentos.

E por último o cerebelo, encontrado na parte inferior posterior do hemisfério cerebral, e é envolvido com a coordenação de movimentos e com a habilidade motora e de adaptação, conhecido por seu papel na aprendizagem dos movimentos, por sua ajuda na aquisição de informações sensoriais e na organização de funções cognitivas. Seu córtex é dividido em três camadas, com poucas diferenças, elas possuem o mesmo tipo de neurônio, mesmas proporções e interconexões. Seu núcleo recebe oxônios que são a principal fonte de saída do cerebelo, tendo como alternativa as saídas os núcleos fastigial, interpositivo e denteado (BEAR; CONNORS; PARADISO, 2002). Sua parte mais antiga, o lobo floclonodular, manda os oxônios diretamente para os núcleos do tronco cerebral e recebe as principais entradas visuais, envolvendo o equilíbrio e o movimento dos olhos. O cerebelo é muito conectado com o cérebro, porém suas lesões resultam apenas em desordem de movimento, não na sua paralisia.

## 2.6 Áreas sensoriais e motoras do córtex

O córtex motor primário (M1), é localizado no lobo frontal, tendo relação com controle de movimento e possuindo uma organização somo tópica, refletida no mapa *homunculus*. O córtex pré-motor (PM) também fica no lobo frontal, vindo antes do M1, e sendo dividido entre dorsal e ventral com cada divisão em outras duas, rostral e caudal, subdivisão feita devido as diferenças nas entradas de parietal e pré-frontal e das saídas do M1 (WOLPAW, 2013). Quando o PM é estimulado eletricamente pode-se observar um movimento no M1, apesar de ser mais singelo e poder excitar movimentos que não sejam do M1 também.

O córtex somatossensorial primário (S1) fica no final do lobo parietal, é importante nos movimentos, já que transmite a sensação de toque, temperatura, dor, posição de uma parte corporal, esse senso vem de uma combinação de receptores presente na pele. Há também o córtex posterior parietal (PPC), mencionado anteriormente, ele é envolvido com funções sensórias, combinando sensores para a formação de um mapa interno de membro e como eles se relacionam com o mundo exterior, lesões nessa parte cerebral podem causar uma doença em que você não reconhece os membros do lado oposto de seu corpo, ele pode ser dividido em área também, como a lateral intraparietal (LIP), envolvida no controle sádico, movimento dos olhos, área ventral intraparietal (VIP), possuindo neurônios com os receptores tátil/visuais, as áreas anterior e media intraparietal (AIP e MIP), que são envolvidas no movimento das mãos e braços, em que MIP alcança e AIP controla o alcance (WOLPAW, 2013).

Duas entradas importantes para o movimento são a visão e a propriocepção. Os sinais visuais podem seguir tanto pelo PPC quanto pelo lobo temporal, em que cada caminho representa funcionalmente em localização de objetos e reconhecimento de objetos, respectivamente (BEAR; CONNORS; PARADISO, 2002). A percepção é feita no córtex

somatossensorial secundário e a ação é feita no PPC, junto com sua entrada visual, sendo projetada no lobo frontal.

O córtex pré-frontal (PFC), localizado no lobo frontal, não possui função diretamente com movimento, porém ele se torna importante pois suas funções são relacionadas com isso, além do seu papel na memória de curto prazo (BEAR; CONNORS; PARADISO, 2002).

## 2.7 Áreas cerebrais corticais e controle motor

O controle motor é visto como uma serie de funções organizadas hierarquicamente, pode ser visto em quatro dimensões: tempo, decodificação, complexidade e fonte.

Seu comportamento pode ser tratado como um processo de planejamento, seguido por tempo de execução, nesse planejamento inclui a identificação do objeto, seleção do membro utilizado e especificação do caminho até o alvo, sendo na prática impossível separar o tempo de planejar e executar. São três os critérios que são considerados planejamento: a modulação do spike, a sua relação com o movimento posterior e as variações da modulação para prever a mudanças de movimento (KANDEL et al., 2014) .

Entrando para as partes cerebrais, o M1 é considera engajado na execução, sua modulação começa em 50-200ms antes do movimento, com perfis bem heterogêneos, incluindo os componentes de sustentação e transiente e variações de subida e descida. Já o PM é mais no planejamento, ele exibe a modulação ligada no início do movimento, sendo seu período de atraso maior do que o M1 (KANDEL et al., 2014). O córtex posterior parietal tem uma maior hierarquia motora que o PM, sendo sua informação visual retino tópica, podendo ser considerado que ele manda suas entradas para o M1. Já o córtex pré-frontal tem uma descarga mais fásica, começando 150ms antes da descarga do PM.

O movimento pode ser descrito de várias formas, com diferentes níveis de abstração, teorias biológicas observaram os conceitos de robótica para avaliar esses diferentes tipos de abstração, e utilizando esse modelo o plano de trajetória seria em um sistema de coordenadas egocêntricas.

O M1 representa variáveis cinemáticas, podendo ser usado para prever torque, força e atividades de eletromiografia (EMG). Apesar de não ser certeza, há muitas evidências em que o M1 pode codificar sinais que representam o movimento da mão, incluindo sua direção, estudos feitos em análises de macacos demonstraram uma grande atividade nessa área cerebral, sendo o pico da descarga a mudança de movimentos para outras direções.

A junção de vários estudos diferentes mostram o indicio do M1 de representar outros movimentos cinemáticos, a demonstração que seus neurônios podem ser combinados para prever direções de movimento, e com isso também mostrando que movimentos mais complexos possam ser decodificados, para guiar o BCI em tempo real em movimentos virtuais e robóticos, além disso esses neurônios fazem uma relação entre força e taxa, re-

presentando movimentos musculares básicos quando centrados no corpo (KANDEL et al., 2014). M1 realmente possui vários estudos e várias interpretações: podendo decodificar movimentos não descobertos e correlacionados, não ter uma área homogênea, mas possuir a taxa de representação, servir de substrato em uma implementação sensorial no sistema coordenado, resumindo, não há um consenso sobre o posicionamento do M1 junto com a dimensão abstrata.

Já o PM e o córtex posterior parietal têm representações claras, há um número de neurônios muito maior em um alvo, podem decodificar movimento de pulso e direção da posição central do corpo, além de predizer com mais acurácia a direção do alvo antes do movimento.

Os movimentos mais complexos também fazem parte do nosso dia a dia, sendo sequenciais ou simultâneos de movimentos mais simples (KANDEL et al., 2014). Muitos dizem que eles são somente uma concatenação dos simples, porém há fenômenos que sugerem que o cérebro possui áreas especializadas que relacionam e coordenam simples movimentos em movimentos complexos.

O córtex motor suplementar (SMA) é uma área importante na representação de movimentos complexos que envolvem muitos membros, estudos revelam que seus neurônios preferem uma sequência de movimentos complexos que quando comparados aos simples (KANDEL et al., 2014). Já os neurônios do M1 preferem codificar sequências simples e memorizadas de movimentos.

Um movimento inicia-se por fatores internos ou externos, ou seja, para começar a se movimentar é feita uma escolha de querer ou precisar, comandos internos ou externos, e suas diferenças são bem evidentes na geração de movimentos complexos.

SMA foi evidenciado que pode ser envolvida com movimentos internamente e externamente guiados, novamente experimentando em macacos, eles quando submetidos a essa coordenação demonstra uma área movimentada. Quando em M1, não mostra nenhuma diferença nessas condições (WOLPAW, 2013).

A ação de agarrar na perspectiva de controle é interessante, já que é um movimento complexo em que se junto as noções de proximidade, coordenação e distâncias do braço. Em um estudo sobre essa atividade em que é demonstrado que existe duas áreas responsáveis por diferentes tipos de “agarrar”, a rede dorsal que aparentemente controla os ombros e o cotovelo e a rede ventral que controla os movimentos periféricos. São muitos os neurônios do PMvr sensíveis a essa ação, neurônios canônicos descargam para alguns movimentos de compressão, mas também quando o objeto é somente observado, já outros descargam quando outro indivíduo faz o movimento.

O córtex motor primário é claramente envolvido no controle periférico do corpo e nos movimentos dos braços, seus neurônios modulam suas atividades em diversos aspectos, lesões podem causar paralisia de um membro próximo e perda de controle do pulso e dedos (WOLPAW, 2013). Apesar de ter isso claro, a existência de uma organização topo-

gráfica na área do braço ainda é bastante controversia, podendo ter duas interpretações em que os neurônios codificam componentes distantes do corpo ou que eles codificam os componentes distantes e próximos ao corpo.

O retorno do somato sensor é importante para modulação do controle de movimentos, sua sensação proprioceptiva é através de uma variedade de músculos e órgãos sensoriais (BEAR; CONNORS; PARADISO, 2002).

## 3 Interfaces Cérebro-máquina Afetivas e Análise de Emoções

A interface cérebro-máquina (BCI, do inglês Brain-Computer Interface) é uma tecnologia que estabelece uma conexão direta entre um computador e o cérebro humano (HASSANIEN; AZAR, 2015), ou seja, possui como propósito conectar os seres humanos com dispositivos eletrônicos. O BCI lê e compreende as ondas cerebrais e traduz de forma que se pode controlar pelo computador.

Suas aplicações mais popularizadas são em relação à saúde e neuro reabilitação, em pacientes que possuem má capacidade motora, a fim de que possam controlar dispositivos sozinhos. Os maiores desafios do BCI são: o sinal próprio cerebral (que tem baixas frequências, assim sendo mais difícil de extrair), o erro de transferência do sinal e a posição dos eletrodos (que podem enviar um sinal impreciso). Cumprindo quatro requerimentos: interface segura e confiável, sinais com boa resolução e suficientes, invasão não pode ser feita a não ser que seja necessária (WOLPAW, 2013). É definido dois tipos de BCI: invasiva e não invasiva (podendo ser parcialmente invasiva). A forma de como será feito o processo depende da razão pela qual será extraído o sinal.

### 3.1 BCI não-invasivo

O BCI não invasivo é o método mais econômico e seguro, em que se consiste nos sensores elétricos (eletrodos) posicionados no couro cabeludo, os mesmos que são utilizados para exames regulares de eletroencefalografia. Esses equipamentos leem os sinais e enviam para o computador, em que são processados e interpretados. Têm como maior vantagem que não é necessária uma cirurgia para utilizar, porém seus sinais não possuem boa resolução.

### 3.2 BCI invasivo

O BCI invasivo é o método que necessita de uma operação, onde os eletrodos são colocados na massa cinzenta do cérebro, permitindo uma melhor resolução do sinal, contudo com riscos. O BCI parcialmente invasivo também se utiliza de cirurgia, porém não é colocado diretamente na massa cinzenta, trazendo a vantagem da falta do bloqueio dos sinais pelo crânio e sem cicatriz na massa cinzenta, porém ainda tendo o risco de toda operação.

Todo procedimento cirúrgico possui riscos, o cérebro é uma área sensível e impor-

tante do corpo humano, sendo assim evitado uma cirurgia. Suas lesões podem ir desde sangramento, infecções e reações alérgicas até inchaço cerebral e perda de alguma função, ou seja, sendo um método nada seguro se houver uma outra escolha. Por esses motivos, o método invasivo é evitado.

### 3.3 Spikes

Como dito anteriormente, as ações potenciais neuronais são as unidades básicas de comunicação e informação do SNC. Há uma hipótese, *rate-coding*, em que a informação transmitida por neurônios através de taxas produzidas, frequência *spike* ou taxa é o mecanismo fundamental na informação do código. Os *spikes* são contados em períodos de 20 a 100 ms, o que traz muitos problemas, já que esses tempos são escolhidos arbitrariamente, além de quanto menor a duração a fim de melhorar a qualidade temporal, menor a resolução (WOLPAW, 2013).

Já a hipótese temporal é uma alternativa em que a informação é decodificada na linha temporal dos *spikes*, ou seja, um tempo preciso de ocorrência de *spikes* traz um número de informações maior que o número total de *spikes*, porém há menos evidência em nível de um único neurônio. Também há estudos que dizem que esse tempo preciso carregam informações comportamentais.

Eles são detectados por microelétrodos, em que antigamente os eletrodos eram objetos de metal cheio de fios e pontiagudos, não sendo muito queridos, atualmente esse problema foi resolvido e existem vários tipos de microelétrodos que até podem ser implantados por longo período (WOLPAW, 2013). São utilizados para gravações intracorticais, feitos de aço, tungstênio e platina, estabilizados por um conector ligado ao crânio, somente um eletrodo pode gravar vários neurônios, dificultando a análise de um único, tendo que utilizar o *spike sorting* para isso.

Há também microelétrodos com substrato de cerâmica, com propriedades de gravações melhores, apesar do movimento cerebral diminuir, também tem o substrato de silicone em que se permite a adoção de tecnologia de circuitos integrados.

O *spike sorting* é um algoritmo que reproduz a onda de um único *spike*, podendo ter pequenas escolhas arbitrárias para ajudar a projetar as formas de onda do espaço e potencializar a correspondência do único neurônio (WOLPAW, 2013). Ele é necessário visto que os eletrodos não têm como analisar somente um neurônio ou *spike*.

### 3.4 Potenciais locais de campo

Potenciais locais de campo (LFP, do inglês *Local Field Potential*) são fenômenos gravados, na escala micro, dentro do córtex. Os microelétrodos são posicionados longes o



suficiente das superfícies das membranas para evitar a dominância de alguns neurônios individuais. Para analisar suas gravações é necessário um filtro passa baixas,  $<350$  Hz, para remover as atividades de outras fontes potenciais, visto que com esse filtro passa toda a informação necessária (WOLPAW, 2013). Quando o LFP é maior pode se dizer que as fontes mostram sinais parecidos ou iguais.

### 3.5 Eletrocorticografia

Eletrocorticografia (ECoG) são fenômenos, na escala meso, em que se coloca micro-elérodos acima da superfície do cérebro, região conhecida como *arachnoid* (aracnoide). São eletrodos menos evasivos que não penetram o cérebro, onde as fontes corticais de corrente passam por diversas camadas. Sua fonte de eletrodos é maior, além de poder escolher diferentes filtros temporais, sendo essa a principal diferença entre o LFP (WOLPAW, 2013). Ele é considerado o padrão para identificar tecido cortical, o que ajuda a monitorar atividades epiléticas.

### 3.6 Gravações, resolução espacial e fontes cerebrais

A maioria das degradações espaciais da resolução do ECoG e do LFP são devidas ao crânio. Os eletrodos que ficam dentro dele podem prover uma boa/média resolução para aplicações de longo termo, como BCI (WOLPAW, 2013). Esses eletrodos são menos evasivos que os já mencionados e podem dar uma performance mais estável.

As morfologias corticais, fontes de corrente e gravações de eletrodos possuem várias escalas. No neocortex, a escala intermediária ou meso é definida pela extensão espacial dos axônios, sendo a célula piramidal a de maior estrutura comparada com um microelétron, para sua escala é fundamental que parâmetros eletro-físicos sejam separados por intra e extracelulares e membranas. A condutividade dos tecidos é extremamente dependente da densidade das células, visto que são suas membranas que provem uma alta corrente de resistência (WOLPAW, 2013). Há uma função *microsource*, na membrana em que inclui as fontes ativas nas sinapses e as passivas nas correntes.

O neocortex possui muitos neurônios e sinapses, e cada sinapse ativa produz uma corrente local na membrana, as sinapses *excitatory* produzem fontes negativas e as sinapses inibitivas produzem fontes positivas, formando um momento dipolo por unidade de volume, que é utilizado no EEG quando o volume é escolhido para combinar com a atividade coordenada, porém há duas limitações: o volume do tecido tem que ser grande o suficiente para conter micro fontes, por conta das atividades sinápticas e ao mesmo tempo tem que ser muito menor que a menor distância do eletrodo, e a segunda condição é que a escala de volume, tem que ser pequena comparada com a distância da gravação, para assegurar que o potencial do couro cabeludo seja insignificante (WOLPAW, 2013).

O momento dipolo por unidade de volume é negativo na escala macroscópica, e a densidade de volume tem sinal oposto, representando as correntes externas e internas da coluna.

### 3.7 Eletrodo de referência

A medição de tensões requer gravações de eletrodos para a efetiva captação dos sinais e também de eletrodos de referência. A localização desse eletrodo de referência é diferente para cada sinal. Para ECoG o eletrodo de referência é localizado fora do crânio e pode ser considerado quieto, já que as tensões externas são menores que as internas. As gravações bipolares medem a diferença de potencial entre dois eletrodos próximos (WOLPAW, 2013). O eletrodo de referência deve estar eletricamente distante das fontes, a escolha da localidade desse eletrodo faz muita diferença na hora da interpretação do sinal de EEG.

### 3.8 Eletroencefalografia e suas limitações

EEG tem seus problemas mais comuns que serão um pouco mais detalhados a seguir. O fato de que o EEG pode exibir diferentes frequências em diferentes locais deve-se ao peso seletivo da escala meso e dos componentes de cada *voxel*. Por muitos motivos potenciais de EEG e ECoG são gerados praticamente só por fontes corticais, são três principais pelas fontes corticais serem associadas com as funções *Green* (inverso da distância elétrica ao quadrado entre a fonte e a localização onde o potencial é obtido); pela grande separação da fonte pro coletor no tecido cortical e pela arranjo paralelo das células piramidais, seus potenciais podem ser gerados quase exclusivamente pelas fontes corticais (WOLPAW, 2013). Como resultado para EEG e ECoG as fontes gyral - giratórias - geralmente geram uma superfície potencial maior do que fontes no cortical.

O problema inverso de EEG é encontrar as localizações e as forças das fontes de corrente. Os potenciais gravados são usados para estimar potenciais nominais. Esse problema não tem solução única, já que se um dipolo prover uma superfície de entrada, dois ou mais dipolos podem prover entradas melhores (BEAR; CONNORS; PARADISO, 2002). Na ausência de informação adicional pode se fazer premissas requeridas para obter o encaixe.

A fim de interpretar os sinais de EEG é necessário fazer transformações matemáticas, para que seja visível um resultado mais claro. Uma das mais utilizadas é a transformações de Fourier, já que as frequências de EEG são associadas com estados cerebrais específicos. Há outras transformações possíveis, para saber se elas são viáveis o processo deve revelar propriedades dinâmicas importantes. Sua relação de diferença de potencial observada e fontes cerebrais devem depender da anatomia e fisiologia do tecido, a análise

quantitativa de EEG depende da transformação desses potenciais gravados com variáveis dependentes e independentes, com essa transformação pode-se fornecer estimativas consideráveis do comportamento da dinâmica das fontes.

Voltando um pouco mais para a análise de Fourier, pode ser expresso qualquer sinal arbitrário como a soma de ondas com diferentes frequências e fases, e cada forma de onda é expressa em termos de amplitude e fase de cada componente da frequência, por isso é bastante utilizado em EEG, pois sua frequência é descrita como formas de onda com cruzamentos de zero (WOLPAW, 2013).

Alguns conceitos em relação ao assunto são: a sincronia é um termo quantitativo, indicando que a fonte meso é sincronizada com relação ao tempo (conhecido como *phase-locked*), em EEG, fontes tendem a adicionar superposição linear e produzir grandes potenciais do couro cabeludo; a dessincronização é utilizado para indicar uma redução na amplitude do EEG e a coerência se refere a definição matemática, que é a normalização da função densidade, é uma medida de *phase-locked* ou a consistência de fase entre pares de canais, expressada como um função da banda de frequência (WOLPAW, 2013). Com isso podemos dizer que fontes coerentes podem ou não ser síncronas, dependem de suas saídas de fase.

Estímulos sensoriais geram potenciais evocados (EPs, do inglês *Evoked Potentials*) e são tipicamente memorizados por tempo e estímulos únicos, a fim de remover/ reduzir ruídos ou outras fontes. Os potenciais relacionados a eventos (ERPs, do inglês *Event related Potentials*) são gravados da mesma maneira que os EPs mas ocorrem em latências mais longas e são mais relacionados com estados endógenos do cérebro.

### 3.9 Atividade metabólica cerebral

Três tipos de processos estão envolvidos na atividade cerebral: químico, elétrico e metabólico. Cada processo tem suas vantagens e desvantagens. O processo elétrico, que foi já um pouco comentado, tem suas desvantagens devido ao fato de os eletrodos serem localizados longes dos neurônios, além das informações adquiridas não serem precisas. Já o processo químico é cruel, ele envolve a injeção de marcadores e tem uma resolução temporal baixa (KANDEL et al., 2014). Por essas limitações houve um investimento em medir a atividade metabólica, que envolve a utilização de energia e o aumento dessa atividade faz com que haja um aumento da demanda de nutrientes básicos como açúcar e oxigênio, e essa mudança de demanda pode ser detectada.

A distância entre dois pontos, que podem ser distinguidos, no espaço e no tempo é chamada de resolução. Os detalhes de cada método, em relação ao espaço e ao tempo são analisados por sua resolução (KANDEL et al., 2014). A imagem cerebral medida em resolução possui as três dimensões já mencionadas, elétrica, química e metabólica é comparada em *voxel*, termo equivalente ao pixel. Cada dimensão e seus processos possuem

resolução, sucesso diferentes. A resolução temporal retrata o tempo de uma medição.

### 3.10 Fluxo sanguíneo

A velocidade de captação de uma imagem pode ser extremamente alta quando se utiliza técnicas de medição de fluxo sanguíneo, mesmo tendo a complicação da mudança constante do sangue, essas técnicas podem ter uma boa resolução espacial. São quatro métodos principais: Ultrassom doppler transcranial funciona (fTCD), esse método consiste em medir as mudanças do fluxo de sangue nas maiores artérias do cérebro, é o equipamento mais barato, porém bem sensível; Tomografia por emissão de pósitrons (PET), que rastreia eventos químicos e fluxo sanguíneo, sendo lento e necessita de injeção de componentes radioativos; Espectrografia funcional de infravermelho próximo (fNIRS), ele rastreia diferentes formas da hemoglobina, chamada de resposta nível dependente sanguíneo de oxigênio (BOLD), tem pouca resolução espacial e boa temporal; ressonância magnética funciona (fMRI), também mede o BOLD rastreando as mudanças que são indicadas por diferentes formas de hemoglobina, ele é o equipamento mais sensível com a maior resolução espacial (WOLPAW, 2013). Posteriormente cada método vai ser comentado com mais detalhes.

Todas essas técnicas dão uma imagem cerebral funcional, e seus resultados dependem da tarefa feita enquanto se fazia a aquisição. Para saber que partes do cérebro performam uma função específica é necessária um design, por isso ele é importante. O mapa revela o local anatômico das regiões cerebrais, mas em um momento de saber os lugares de funções específicas podem aparecer regiões que são somente correlacionadas, e não específicas.

### 3.11 Resposta da atividade cerebral

Como o oxigênio necessita ser transportado por todo o corpo, para cada órgão funcionar adequadamente, seu transporte é de muita importância, se tornando um dos principais encargos do sangue, sendo o ciclo sanguíneo em torno de 1min. Seu deslocamento é feito por hemoglobinas, que são divididas em oxiemoglobinas, possuem oxigênio, e carboxiemoglobina, que não contém oxigênio (KANDEL et al., 2014).

Assim que aumenta o metabolismo do cérebro, o consumo de oxigênio também aumenta, e com isso vem uma sequencia de respostas corporais, os capilares pedem mais oxigênio, devido ao aumento da demanda, aumentando o volume de sangue e seu fluxo e as oxi-Hb entregam o oxigênio e viram dioxi-Hb. Os fNIRS e fMRI medem as diferenças de cor e propriedades magnéticas da Hb, oxi-Hb é vermelho e não magnética e deoxi-Hb é vermelho escuro e magnética. As mudanças de comunicação também podem ser medidas usando esses processos.

## 3.12 Emoção x Sentimento

O surgimento da emoção vêm a partir de três etapas, o sentimento inicial, a variação imediata a partir das representações, modificando e intensificando o sentimento inicial, e por último o sentimento final, podendo ser de maior ou menor período, que tende a dissipar gradativamente, assim dando origem a uma nova emoção, voltando ao estágio de sentimento inicial. (MARCELLOS; ARAUJO, 2011).

Para o conceito do projeto estar bem definido é necessário a explicação do que é uma emoção. Emoções possuem vários conceitos e foi muito discutida na filosofia, o sentimento é algo individual de interpretação própria, ou seja, o sentimento é algo incalculável sendo de caráter próprio e contextual, o que pode e irá ser calculado é a emoção, que é definida como o conjunto de respostas químicas e neurais em resposta a um estímulo externo.

Atualmente, os estudos acham diversas maneiras de tentar mensurar as emoções, psicólogos e cientistas se utilizam de técnicas como a análise facial, micro-expressões, sinais de EEG, análise de textos, tom de voz, entre outros, e a partir desse conjunto de técnicas ou da junção delas é conversado como mudar e aceitar os sentimentos propícios a elas.

## 3.13 Métodos e análises de emoções

Nesse tópico irá ser abordado um breve conceito de cada metodologia utilizada para a compreensão das emoções e o porque foi escolhido a análise a partir do EEG.

A primeira técnica é a análise facial, as macro expressões do rosto humano, normalmente, têm muito a dizer de forma superficial o sentimento individual. Desde crianças, somos ensinados a demonstrar sensações de medo, nojo, raiva, tristeza, felicidade e a reconhece-los, portanto há diversos estudos de como identificar a fisionomia humana e ter vantagem sobre isso, sendo essa vantagem de subir em empregos, ajudar um cliente, aconselhar um amigo. De acordo com (SANTOS, 2018) diz que as emoções têm propriedade e são comuns no comportamento mundial, as feições de raiva, tristeza, surpresa são comuns em todo o lugar informando em uma conversa casual informações importantes para sua continuação, sendo a sua interpretação tendo conexão com o funcionamento do Sistema Nervoso.

Já as micro expressões, são análises um pouco mais complexas e de conhecimento mais detalhado apenas para seus pesquisadores, porém ainda é um sistema mundial de identificação. Esse método mostra os verdadeiros sentimentos de uma pessoa, sendo mais difícil de desfaçar ou fingir, como os macro expressões. O canal "Metaforando" no *youtube*, o maior canal de micro expressões faciais da América Latina, tem como criador um perito de suas análises, Vitor Santos, é definido as expressões faciais emocionais são contrações

musculares momentâneas gerando a informação emocional de um indivíduo naquele momento com o tempo médio de 0.5s, não revelando algo de longo tempo, a partir dessa definição se conclui que não se pode fazer afirmações sobre um sentimento mais profundo individual.

Há um livro de micro expressões "FACTS", que nele mostra os sistemas universais e explica como desde criança ensina essas contrações faciais involuntariamente. Esses dois tipos de identificação de emoções pode ser identificado tanto por um pesquisador quanto por um código de aprendizagem de máquina que, juntamente com uma câmera, analisa e identifica cada expressão, pegando uma base de dados dos estudos já conhecidos por cientistas. Esses estudos são utilizados na montagem de filmes, em clínicas psicológicas e até mesmo na vida pessoal, evitando situações desconfortáveis (DAMÁSIO, 2012), (EKMAN, 2004), (TODOROV, 2017).

Há também a análise por texto, a maneira que cada ser humano escreve demonstra as emoções sentidas no momento em que foi escrito, um grande exemplo disso é a literatura, é dividida por fases e interpretada de forma emocional. Um grande método de análise é pela rede social twitter, há um algoritmo em que estuda o seu perfil nessa rede e identifica a maior emoção sentida naquele momento. Na pesquisa (MARTINAZO, 2010), podemos identificar que as formas mais atuais de compreensão textuais são feitas também por processamento de dados, há um pré-processamento e uma base de dados em que o código processa e no final, a partir de comparações e significados das palavras, é feito o dado final de identificação de cada texto.

O modo de comunicação de cada pessoa também é bem característico em relação à emoção sentida no momento, é possível observar o tom de choro, de alegria, de raiva. Nos estudos de (LAUKKA, 2004) é possível notar que essas expressões de fala são compartilhadas até com os animais, mudando, às vezes, por cultura de um país, inclusive a altura da fala pode significar sentimentos variados. Há uma tese em que se identifica automaticamente qual a emoção por uma base de dados retirada da Alemanha, visto em (JR et al., 2017)

Os sinais de eletrocardiograma mostram o batimento do coração, no estudo (BONOMO; ARAUJO, 2009), é contemplado que as emoções negativas afetam mais os batimentos, e por isso, são mais fáceis de identificar, emoções como raiva, ansiedade, preocupação causam um aumento e uma arritmia cardíaca que é detectada por holters, ajudando a identificar se possui algum problema de coração, já que em emoções do dia a dia não deveria ter uma mudança muito drástica.

Por fim, os sinais de EEG, as pesquisas que relacionam eletroencefalografia são muito recentes, feitos na maior parte por pesquisas de mestrado e doutorado. É um método de análise das atividades elétricas cerebrais, se obtendo por captação na cabeça, podendo ser de forma evasiva ou não evasiva (CAPARELLI et al., 2007). Assim como o ECG, os sinais cerebrais são bastante peculiares nos aspectos do sentimento de emoções

e identificação de algumas doenças, como epilepsia, precisando de um pré-processamento específico é possível enquadrar em plano 2D as classes de sentimentos, de valência *vs* excitação, visto em (RUSSELL, 1980) e na Figura 2.



Figura 2 – Plano valência *vs* excitação, retirado de (RUSSELL, 1980)

A partir dessa Figura e após o pré-processamento, será feito um programa que colocará cada sinal em um quadrante do plano, treinado por aprendizagem de máquina com aprendizado supervisionado, assim ajudando os especialistas a identificar cada emoção, primordialmente, como ela sendo positiva, negativa, com alta intensidade ou baixa.



## 4 Análise de sinais e Aprendizagem de Máquina

Por último para o pleno desenvolvimento da pesquisa, é necessária a compreensão de alguns conceitos de sinais e sistemas, como se utiliza a interface cérebro-máquina e o desenvolvimento do aprendizado por computador.

Um sinal é considerado a algo que transmite informações, e seu processamento envolve análise e modificações de sinais a partir de teorias, aplicações e algoritmos, lidando com representações, transformações e manipulações dos mesmos (SCHAFER, 2012).

O EEG é considerado um sinal bioelétrico, visto que é captado eletricamente de um ser biológico, que registra a atividade neuronal do dia a dia. Sua captação, normalmente, é feita de forma não-invasiva, com cada eletrodo colocado em um local específico do couro cabeludo, tendo em vista que a maioria dos laboratórios se utilizam do sistema 10-20, como representado na Figura 3. De acordo com esse sistema os eletrodos são posicionados na região frontal direita, central direita, occipital direita e três referenciados na M1, e de forma igual à esquerda.




Figura 3 – Sistema 10-20, retirado e autorizado por (RODRIGUES, 2018)

Como cada sinal, o EEG possui suas características e formatos de onda, possuindo frequências entre 0.5 a 30 Hz e de amplitude 5 e 300  $\mu$ V (CANTARELLI; JÚNIOR; JR, 2016), sendo considerado um sinal de baixa amplitude e rítmico. Na imagem 4 podem ser observados os tipos de onda, suas características, onde se encontram e seu formato; atributos que serão utilizados para a caracterização da classificação.

É necessário um pré-processamento para a filtragem e a melhor compreensão de cada sinal, a partir disso é possível desenvolver um programa em que usa algoritmos







Ritmo	DELTA	THETA	ALPHA	BETA
Componente em frequência	< 4 Hz	4 a 7 Hz	8 a 13 Hz	> 13 Hz
Amplitude	100 uV	Criança: 20 uV Adulto: 10 uV	Bebê: 20 uV Criança: 75 uV Adulto: 50 uV	10 a 20 uV
Principal área do escalpo	Frontal	Temporal	Occipital / Parietal	Frontal
Condição do Indivíduo	Sono Profundo	Sonolência	Repouso / Olhos fechados	Repouso/ Olhos abertos
Forma de onda				

Figura 4 – Tabela das características do EEG, modificado de (FREITAS; FILHO, 2008)

de aprendizagem de máquina para o treinamento e processamento dos sinais, por fim classificando as emoções.

Os sinais de EEG são não lineares, não estacionários, complexos e difíceis de se interpretar, por esse motivo suas aplicações em relação a aprendizagem profunda estão em fase inicial (BAO et al., 2021).

As técnicas de aprendizagem de máquina estão a cada dia sendo inovadas e mais utilizadas, visando reproduzir o comportamento cerebral. Seus algoritmos são um exemplo de inteligência artificial e aprendizagem profunda, em que a partir da base de dados e de métodos de redes neurais, conseguem replicar a conduta e pensamento humano. Seus últimos avanços mostram que é possível processar e armazenar grandes arquivos de dados.

A aprendizagem de máquina replica o funcionamento cerebral, de acordo com (ALPAYDIN, 2020), pode ser definido como um sistema inteligente que está em constante mudança e tem a habilidade de aprender e se adaptar a situações, suprindo soluções e informações para determinada pesquisa. Seus códigos são otimizados se baseando nos parâmetros encontrados nas pesquisas, o método de aprendizado pode ser por reforço, supervisionado, semi-supervisionado e não-supervisionado.

Cada modelo é estudado para determinar um estilo de resultado, podendo ser preditivo, descritivo ou os dois, utilizando de modelos matemáticos e repetições de respostas. Para todo código tem um método básico para se basear, na Figura 5 mostra o passo-a-passo, primeiramente se prepara a base de dados, coletando os sinais e fazendo seu pré-processamento, depois se desenvolve, treina e testa o modelo, são passos que estão em constante mudança e dependência um do outro, por fim tendo o resultado, lembrando que é um processo que está em sucessivas transformações.

No aprendizado supervisionado, os algoritmos são treinados a partir de exemplos rotulados, (HONDA MATHEUS FACURE, 2017), exemplos cuja resposta é conhecida. Os exemplos são compostos de características, também chamadas de variáveis indepen-




Figura 5 – Fluxo básico de algoritmo de aprendizagem de máquina.

dentos ou preditivas, enquanto que o rótulo também é chamado de variável dependente, ou alvo. O modelo é supervisionado no sentido que suas respostas para cada exemplo são comparadas com os respectivos rótulos e as diferenças são usadas para ajustar o modelo iterativamente até a convergência.

Dentre os métodos de aprendizado supervisionado podemos citar: a regressão linear, regressão logística, redes neurais artificiais, máquina de vetores de suporte, árvores de decisão, k-vizinhos mais próximos e Bayes ingênuo (YEMAM, 2021).

No aprendizado não-supervisionado, todo o sistema age sozinho, não tendo respostas para comparações. Esse sistema, normalmente fornece informações padrões de repetições da base de dados (YEMAM, 2021), assim, seu objetivo é prover informações mais precisas da base.

Suas aplicações são bastantes utilizadas no dia-a-dia, como o sistema de recomendação dos *streamings* e redes sociais, tendo como métodos as redes neurais artificiais, Esperança-Maximização, clusterização por k-médias, máquina de de vetores de suporte, clusterização hierárquica, mapas auto-organizados, máquinas de Boltzmann restritas, dentre outros (HONDA MATHEUS FACURE, 2017). O aprendizado semi-supervisionado é uma mistura dos algoritmos acima, mudando e utilizando de acordo com sua necessidade.

Por último, têm-se o aprendizado por reforço, esse algoritmo se utiliza a lógica de tentativa e erro, observando qual o melhor caminho a ser tomado (utilizado em muito jogos), sendo sua base feita de acordo com o estudo prévio (YEMAM, 2021). Esse método é baseado no behaviorismo de (SKINNER, 1972), em que ensina animais o que é certo ou errado de acordo com a recompensa ou castigo que recebe.

O melhor método depende do propósito de cada trabalho, tendo que observar e estudar as vantagens e desvantagens de cada ponto e foco do objetivo e resultado.

Na Figura 6, há um diagrama simples do contexto de inteligência artificial, apren-

dizado de máquina e *deep learning*.




Figura 6 – Diagrama inteligência artificial

## 4.1 Regressão Logística

A regressão logística é um dos algoritmos de classificação mais conhecidos de aprendizagem de máquina, em que se é utilizado, principalmente para problemas de duas classes, sendo a regressão logística binomial (JR; LEMESHOW; STURDIVANT, 2013).

Sua entrada conta com uma ou mais variáveis e o modelo calcula sua relação com a variável dependente. Esse conceito veio da estatística, no método da máxima verossimilhança, se utilizando do conceito de probabilidade do valor de cada parâmetro (SILVA, 2020).

## 4.2 K-ésimo Vizinho mais Próximo - KNN

O KNN é considerado um algoritmo de aprendizado lento ou "preguiçoso", já que não necessita de um treinamento para se ter o modelo, tendo seu treino rápido e teste lento. Ele se baseia no número de vizinhos determinado por K, seu principal parâmetro, a partir do qual determina a classe de resposta para uma determinada observação a partir da classe predominante dentre os K vizinhos mais próximos desta considerando a distância definida no espaço de características.

Pode-se observar na Figura 7, um exemplo de 5 vizinhos mais próximos, o algoritmo identificou quais eram os resultados mais próximos da incógnita, determinando, assim, que sendo um quadrado verde.




Figura 7 – Gráfico de KNN, retirado de (SAKURAI, 2020)

É um algoritmo simples de se implementar e não é necessário definir valores de diversos parâmetros, além de ser versátil podendo ser utilizado para classificação e regressão (GUO et al., 2003).

### 4.3 Florestas aleatórias

De modo geral, o algoritmo de Florestas Aleatórias (RF, do inglês *Random Forest*) é uma combinação de árvores de decisão, onde cada árvore gerada depende de um subconjunto de dados amostrados de forma independente e que apresentem a mesma distribuição para todas as árvores que formam a floresta.

Para melhor entendimento da árvore de decisão, diz-se que se assemelha a um fluxograma em que são estabelecidos nós de decisão, relacionados por ordem: o nó-raiz, que seria o original e os nós-folhas, os resultados finais. Em cada nó é determinada uma condição, e, dependendo da condição ser satisfeita ou não, escolhe-se o próximo nó, filho do atual, até que se atinja uma folha.

### 4.4 Máquina de vetores de suporte

A máquina de vetores de suporte (*Support Vectors Machine*, SVM) é um modelo que se baseia em encontrar hiperplanos de separação entre as variáveis (CERVANTES et

al., 2020), ou seja, busca uma linha de separação entre as diferentes classes, analisando os dois pontos mais próximos, se encaixando no seu meio, podendo ter os mais diversos tipos de núcleos (não somente o linear, como veremos a seguir), assim conseguindo se ajustar de acordo com a necessidade.

A SVM pode ser tanto binária quanto multi-classe. Para a classificação multi-classe há duas maneiras de se realizar essa divisão em classificações binárias, pelo método *one vs one* ou por *one vs rest*. A primeira maneira faz a divisão em grupos em pares, fazendo separações de classe por classe e no final o resultado será a classe mais votada. Já a segunda maneira faz a divisão de classe vs o resto das classes juntas, comparando cada classe individualmente com todo o grupo, e a classe que ganhar do grupo é a escolhida (ADDAN, 2019).

Para uma melhor qualidade de classificação, a SVM se utiliza das funções de *kernel*, que projeta vetores de características em outro espaço com alta dimensão, para não ter problemas em espaços não linearmente separáveis, já que aumentando a dimensão diminui a probabilidade de se encontrar uma má distribuição de dados (GONÇALVES, 2015).

Como todo método, o SVM possui seus prós e contras, possuindo como prós um bom funcionamento, eficaz em casos que a dimensão é maior que amostras e eficiente em termos de memória, e como contras é que não possui um bom desempenho quando o conjunto de dados é grande e nem quando tem muito ruído, pois as classes ficam muito sobrepostas (CHAGAS et al., 2009).

## 4.5 Técnicas

Para auxiliar e melhorar os modelos são utilizadas algumas técnicas como o *GridSearch* e validação cruzada.

O *GridSearch* é uma técnica em que dá a possibilidade de testar vários hiperparâmetros dos modelos, a fim de otimizar o desempenho do modelo com respeito a uma determinada métrica, como por exemplo no KNN, é possível fazer de 3 a 6 vizinhos, o algoritmo gera automaticamente todos os modelos de 3 a 6, e nos informa uma métrica otimizada para mínimo ou para máximo, auxiliando no momento de estudar um algoritmo.

Já a validação cruzada é utilizada para evitar o *overfitting*, um problema em que o modelo memoriza a base de dados, se ajustando muito bem ao conjunto de dados do treinamento, porém apresentando resultados ruins quando apresentado a dados nunca vistos no treinamento. Seu princípio é avaliar os modelos por meio de subconjuntos de dados,

avaliando a capacidade de generalização do modelo.

O *StandardScaler* é uma técnica que faz a padronização da base, removendo a média e a variância a uma unidade, ou seja, deixando-as iguais a 0 e 1, padronizando a base de dados.

## 4.6 Estudos prévios

A importância de identificar as emoções com novas tecnologias como o EEG é algo muito recente, portanto, os estudos pré-existentes e a maioria das bibliografias são recentes, a base da teoria, comparações e metodologia foram baseadas nos estudos de 2018 até 2021.

Para uma melhor organização, será dividido em tipos de estudo: classificações e divisões específicas, estudo sobre base de dados e estudos geral de tipos de classificação.

Em (TORRES et al., 2020b) é proposta uma base de dados para ajudar e corroborar com a tese de como provocar uma resposta emocional, o que se tornou útil e comprovado. Os dados foram retirados de pessoas trabalhando com negociações de papéis no mercado de ações, que é considerado um trabalho de alta variação de emoções.

Na pesquisa foram utilizados algoritmos de aprendizagem de máquina com extração e classificação de características. As emoções relacionadas com o *trade* são medo, tristeza esperança e calma, sendo assim classificadas em cada um dos quadrantes da Figura 2 ( valência negativa e atividade negativa; valência positiva e atividade negativa; valência positiva e atividade positiva; valência negativa e atividade negativa), para a retirada das características foi utilizada uma Transformada rápida de Fourier (FFT, do inglês *fast Fourier transform*), obtendo o domínio de frequências, dividido entre as frequências da Figura 4, entropia diferencial (DE), com suas variações de assimetria diferencial (DASM) e assimetria racional (RASM). Um capete de extração de sinais, *Ultracortex Mark IV*, foi utilizado para a gravação de gravação das ondas cerebrais.

No pré-processamento foi usado um filtro de *Butterworth* com fase 0 (preservar frequências entre 1 a 80 Hz) junto com um filtro *notch* para remover o ruído elétrico. O sistema foi dividido na fase de treinamento de modelos e de teste, utilizou dois sistemas de classificação floresta aleatória e redes neurais. Foi testados duas base de dados a da própria pesquisa e da DEAP, para efeito de comparação colocaram com e sem seleção de características.

Observou-se como resultado valores de acurácia de 78.92% com extração de características e sem 72.62% na base da DEAP, e na base da pesquisa, com floresta aleatória 82.51% e 73.22%, já em redes neurais 70.12%, e 69.02% na DEAP.

Uma pesquisa brasileira também classificou emoções a partir do EEG em (SIMÃO, 2017) foi utilizado a base de dados DEAP, utilizando algoritmos de SMOTE - uma forma de balancear uma base de dados criando amostras sintéticas ou artificiais (CHAWLA et

al., 2002) - e ADASYN - outro algoritmo que minimiza as possibilidades de sobreposição. Resolvendo os erros do SMOTE, sendo um método sistemático para criar amostras sintética (HE et al., 2008) - para balancear os dados, depois utilizando o algoritmo Análise de Componentes Principais (PCA) para extração de características. Por fim os classificadores de floresta aleatória, redes neurais e máquinas de vetor de suporte (SVM, do inglês *Support Vector Machine*) para a análise de acurácia.

Após sua realização viu-se que houve uma acurácia de 89,22% utilizando o algoritmo ADASYN e floresta aleatória, de 87,36% utilizando o algoritmo ADASYN e SVM e 68,56% utilizando o algoritmo SMOTE e redes neurais artificiais.

Outro estudo (MELO, 2018) apresenta um método para induzir emoções de ternura e angústia a partir de uma estimulação multimodal em um sistema de realidade virtual com músicas, coletando os próprios sinais EEG com redes neurais artificiais. Foi utilizado o sistema *BrainAmp MR Plus6* com taxa de amostragem de 1000 Hz e largura de banda de 0,01 Hz a 250 Hz e a touca *BrainCap MR6* de 64 canais. Foram apresentadas imagens que representam ternura e angústia, com trechos de músicas combinando de fundo, entre cada imagem havia um período neutro, não havendo música e uma imagem amarela.

Foi feito um pré-processamento utilizando primeiramente um filtro *notch* em 60 Hz, removendo interferências da rede, uma filtro passa-banda de 1,5 a 50 Hz, se baseando na Figura 5 e um filtro laplaciano para diminuir o espalhamento da atividade cerebral, devido à touca utilizada. Dividindo depois o sinal nas quatro bandas de espectro de frequência foi feito um filtro *Butterworth* passa-bandas de ordem 4, extraindo características de potência, potência relativa, dessincronização/sincronização e densidade espectral. Para o modelo foi feito um algoritmo de rede neural artificial do tipo *backpropagation* com 10 neurônios e 3 classes de saída. Como resultado em todas as condições, neutro, ternura e angústia, houve uma acurácia máxima maior que 70%, e adicionando a características ERD/ERS a acurácia chegou a ficar próxima de 100%.

Em (ZHENG et al., 2018) é feito o uso de sinais EEG combinados com rastreamento ocular. Foram classificados em quatro emoções tristeza, felicidade, medo e neutro, para a extração dos sinais foi utilizado seis eletrodos sendo mostrados vídeos de dois minutos para a estimulação da emoção desejada.

Foi feito um pré-processamento com um filtro passa-bandas de 1 a 75 Hz, para a extração de características foi feito uma FFT com uma janela de tempo de 4s para extrair DE e a densidade espectral de potência (PSD). Dividindo em bandas com as frequências já mencionadas, delta, theta, alpha, beta e gamma, retirando as frequências de interferência. Por fim, foi treinado um modelo SVM com *kernel* linear que apresentou acurácia de 58 a 70%.

## 5 Método e Implementação

Para a realização e composição do código para uma conclusão mais abrangente, foi feita uma comparação de pesquisas anteriores para decidir quais métodos demonstraram melhor performance para os dados de EEG, de forma a obter a mesma qualidade de modelos.

Em (TORRES et al., 2020b) é possível concluir que a utilização de mais de uma base de dados pode dar resultados diferentes, de acordo com o método de extração e forma de provocar o sentimento, como por música, vídeo, lembrando de experiências, filmes, imagens, simulações reais, podendo variar positivamente ou negativamente o resultado final, porém somente uma pesquisa autorizou o uso da base de dados, então será levantada um hipótese em relação as diferentes bases de dados comparando pesquisas.

Em todas as bases pesquisadas tiveram suas emoções provocadas a partir de *The International Affective Picture System* (IAPS) (LANG et al., 1997), do *the International Affective Digitized Sound System* (IADS) (YANG et al., 2018) ou de uma forma interna de pesquisa de excitação de emoções - por vídeos de música ou filmes. Os dois primeiros sistemas são fontes mais populares, que acarretam as emoções estimulando de uma maneira padrão. A IAPS é *dataset* de 1200 imagens, dividido em 20 partes de 60 fotos, tendo seu valor de valência e atividade definidos. Já o IADS fornece 167 sons naturais do dia-a-dia, os participantes das pesquisas dos *datasets* tiveram um formulário para preencher, assim identificando melhor as emoções (BRADLEY; LANG, 1994).

As pesquisas também divergem na maneira em que classificam emoções, podendo se utilizar de uma a cinco emoções básicas ou por planos 2D valência X atividade ou 3D valência X atividade X dominância (SUHAIMI; MOUNTSTEPHENS; TEO, 2020). Para a classificação neste projeto foi determinado que as emoções seriam separadas e determinadas de acordo com o modelo 2D, seguindo como base a Figura 2 para o algoritmo.

A base de dados foi dividida em dois algoritmos principais, os que possuem seleção de características e os que não possuem, em que internamente se utilizam de três domínios (tempo, frequência e tempo-frequência) e divididos tanto por canais quanto por bandas de acordo com as frequências delta, teta, alfa e beta, Figura 4.

### 5.1 Base de dados

A base de dados é um fator fundamental para essa pesquisa, dito isso, a forma e o estímulo em que os dados foram extraídos podem fazer diferenças no momento de classificar as emoções dentro do plano valência-atividade. Por isso, foram estudadas cinco



bases de dados, em que somente uma foi autorizada para essa pesquisa, porém todas as bases terão seus métodos de extração detalhados devido a final de extração da emoção.

A primeira base foi a *Database for Emotion Analysis using Physiological Signals* (DEAP) (KOELSTRA et al., 2011). O estudo dessa base se baseia em estímulos via cliques de música para provocar diferentes emoções, em que depois os participantes preencheram um teste classificando o material, em termos de valência, atividade, gosto/não gosto, dominância e familiaridade. Cada vídeo tinha 1 minuto de destaque e era selecionado automaticamente. Foram 32 participantes em que assistiram os vídeos enquanto seus sinais EEG eram gravados.

Para a seleção desses vídeos, os autores desenrolaram passo-a-passo específico a fim de selecionar os melhores e de maior variação e diferenciação das emoções. Primeiramente eles selecionaram 120 vídeos, em que metade eram semiautomáticos e a outra manual, depois disso eles determinaram o minuto de destaque de cada vídeo para assim passar para a segunda etapa do processo de estudo. Então fizeram um teste online que 60 dos 120 estímulos iniciais eram selecionados utilizando um *website* (*last.fm*), os participantes aleatórios classificavam cada vídeo a partir de 4 quadrantes: baixo atividade/baixa valência, alto atividade/baixa valência, baixo atividade/alta valência e alto atividade/alta valência. Seguindo o critério de 3 perguntas: o quão emocionalmente o vídeo e a música realmente produz, se a música encaixava com o vídeo e se a música era apropriada para o experimento. Os outros 60 vídeos foram selecionados manualmente, com 15 de cada quadrante para ter uma reação mais clara da emoção sentida, produzindo no final dessa etapa 120 candidatos para estímulo.

Para selecionar os 40 vídeos finais, utilizaram uma interface de avaliação subjetiva de emoção baseada na web. Os participantes classificavam os vídeos em uma escala 0-9 para valência, atividade e dominância. Após a classificação de pelo menos 14 voluntários, foram selecionados os 40 vídeos finais.

O experimento foi feito em dois ambientes de laboratório com controle de iluminação, utilizando como forma de gravar os sinais a *Biosemi ActiveTwo system4* em um PC dedicado (Pentium 4, 3.2 GHz) enquanto os estímulos eram passados por outro PC (Pentium 4, 3.2 GHz) em uma tela de 17" com uma resolução de 800x600 e com a música passando num auto falante *stereo Philips*, com um volume alto, porém confortável para cada participante. EEG foi gravado com uma taxa de amostragem de 512 Hz, 32 eletrodos ativos posicionados no sistema 10-20.

Os 32 participantes foram compostos por 50% de cada gênero e entre as idades 19 e 37 anos. Quando os sensores eram postos, foi feita uma checagem de sinal e cada participante praticava uma vez para se familiarizar com o sistema. O experimento começava com 2 minutos de gravação para gravar um padrão e depois os vídeos eram apresentados, por fim preenchiam um formulário de descrição dos próprios sentimentos qualificando padrões de atividade, valência, gosto e dominância, em que as escalas de valência iam de tristeza

até felicidade, de atividade de raiva até calma, de dominância de submisso até dominante e uma final se gostaram ou não do vídeo.

Há também a *Multi-Modal Physiological Emotion Database* (MPED) (SONG et al., 2019), uma base de dados multi-modal, que coletou 4 sinais fisiológicos: EEG, respiração, ECG e resposta galvânica da pele. O modo de elicitar as emoções veio de um banco de dados de mais de 1500 vídeos, dos quais foram selecionados 28 para a pesquisa. Os sinais foram gravados simultaneamente enquanto os voluntários viam os vídeos que foram categorizados em seis emoções discretas e uma neutra.

Inicialmente houve 23 voluntários chineses, sendo 10 homens com a idade média de 21.46 anos, que selecionaram cerca de 1500 vídeos da internet datados depois de 2005, com uma média de duração entre 2.5 a 5 minutos. Esses vídeos preliminares consistiam em 11 estados de emoção. Após essa primeira seleção, dois especialistas, um homem e uma mulher, e 9 assistentes, 5 homens e 4 mulheres, assistiram aos vídeos e selecionaram 170 para a próxima etapa de seleção. Para a última etapa dos vídeos, foram 162 voluntários, estudantes, sendo 86 homens e 76 mulheres, com a média de 23.21 anos. As pessoas foram divididas em 17 grupos de 7 a 11 pessoas cada, cada participante viu os vídeos por meio de um projetor e o volume foi ajustado de uma forma confortável para cada um. Para cada grupo foram mostrados 20 vídeos em ordem aleatória, e ao final de cada vídeo o grupo preenchia três questionários: PANA (WATSON; CLARK; TELLEGEN, 1988), SAM (BRADLEY; LANG, 1994) e DES (GROSS; LEVENSON, 1997), questionários padrões de pesquisa para reconhecer sentimento. Os participantes não podiam se comunicar durante a avaliação no final de cada vídeo, por fim foram selecionados os 28 vídeos finais.

Para o experimento, foram 23 participantes, assistiram os vídeos por meio de um projetor e com o volume agradável para cada um, utilizaram um EEG com 62 canais utilizando uma taxa de amostragem de 1000 Hz. Foi utilizado o equipamento *ESI NeuroScan System* no sistema internacional 10-20. Antes de cada gravação era solicitado que cada participante que limpasse e esfoliasse para ter sinais melhores.

A fim de evitar o cansaço e isso atrapalhar a aferição dos dados, o experimento foi dividido em duas partes com intervalo de 24hrs entre elas. Cada experimento continha um descanso de 120s, em que era solicitado que o participante relaxasse e deixasse seus olhos fechados e 14 ensaios.

A base SEED (ZHENG; LU, 2017) é uma base chinesa que possui 5 estilos de bases diferentes, as bases SEED e SEED V foram as estudadas para a pesquisa. Para a base SEED os estímulos foram feitos por 15 vídeos de filmes chineses, mostrando emoções positivas, negativas e neutras, para selecionar os clipes, três critérios foram seguidos: o tamanho dos vídeos, para não ser muito longo e causar cansaço; a auto-explicação dos vídeos e o vídeo por inteiro deveria elicitar somente uma emoção. A duração média era de 4 minutos.

Cada experimento teve um total de 15 triagens, sendo 5s coletados antes de co-

meçar o vídeo, 45s para responder o formulário e 15s depois de cada clipe, além de que a ordem dos vídeos nunca podia ter a mesma emoção estimulada seguida. Foram 15 participantes, sendo 7 homens e 8 mulheres, com idade média de 23 anos. O *dataset* consiste em dois arquivos, um dos sinais pré-processados, retirados os ruídos por um *downsample* de 200 Hz e um passa-bandas de 0-75 Hz e um arquivo de características extraídas que possui a entropia diferencial (DE), assimetria diferencial (DASM) e assimetria racional (RASM).

Em SEED V também foi estimulado por meio de estímulos por vídeos, porém nesse *dataset* as emoções foram felicidade, tristeza, nojo, neutro e medo. Cada participante precisou fazer o experimento 3 vezes com, pelo menos, 3 dias de distância entre eles. Foram mostradas 15 partes do material e ao menos 3 de cada emoção, para evitar o cansaço, a cada experimento eram mostrados vídeos diferentes, eram no total 50 minutos de sessão. A gravação começava 15 s antes do início dos estímulos, e depois de 15 a 30 s para responder o formulário de autoavaliação.

Foram no total de 20 participantes, sendo 10 homens e 10 mulheres, encontrados em uma plataforma social de uma universidade, tendo como características um visão e audição normais, a mão direita como dominante e uma saúde mental estável.

A ASCERTAIN - *a multimodal database for implicit personality and affect recognition* (SUBRAMANIAN et al., 2016), essa base apresenta respostas para emoções e traços de personalidade, porém só irá ser utilizado para a presente pesquisa os dados de emoções. A pesquisa avaliou primeiramente as relações dos usuários com as avaliações e escalas de personalidade em contextos de estudos lineares e não-lineares, sugerindo que as relações não-lineares são melhores estatisticamente que as lineares. Foi gravado os sinais EEG em relação às respostas de cliques utilizados em (ABADI et al., 2015), depois coletado um formulário de classificação em forma de valência, atividade, gosto, engajamento e familiaridade.

Foram 58 universitários, sendo 21 mulheres e com uma média de idade de 30 anos que participaram do estudo, sendo todos fluentes em inglês e acostumados a ver filmes de Hollywood. Para o experimento foi utilizado um PC com dois monitores, uma para a apresentação de vídeo em 1024 x 768 pixel com uma atualização de tela de 60 Hz, com o participante na distância de 1 m do equipamento, e o outro monitor para o pesquisador verificar os dados gravados. Após o consentimento, era colocado um sensor para medição de ECG e para o EEG foi colocado um único eletrodo seco na cabeça como um fone normal e o eletrodo de referência na orelha esquerda. Os dados foram gravados via *bluetooth* e uma câmera foi utilizada para gravar a reação facial.

Cada experimento durava 90 minutos, cada participante treinava duas vezes envolvendo cliques fora dos estudos para compreender o sistema e depois assistiam de forma aleatória em dois blocos de 18 ensaios, para evitar o cansaço a fim de não interferir no resultado, após cada clipe cada pessoa reportava o seu estado emocional, com limite de

30s para responder. O estímulo era composto por 36 vídeos, que possuem uma duração de 51 a 127 s.

As escalas para a classificação de cada emoção iam de -3 à 3, muito negativo à muito positivo; 0 à 6, para muito chato à muito legal ; 0 a 6, não prestei atenção à prestei atenção; 0 a 6, odiei à amei e 0 a 6, nunca vi à me lembro muito bem do vídeo.

E, por último, a base DREAMER (KATSIKIANNIS; RAMZAN, 2017) é uma base multi-modal que consiste em sinais gravados de EEG e ECG durante um estímulo de vídeos audiovisuais e suas autoavaliações em termos de valência, atividade e dominância. Foram 23 participantes, seus sinais foram gravados utilizando equipamento de baixo custo que possui um alto potencial, o *Emotiv EPOC wireless EEG headset* foi utilizado para coletar os dados de EEG e o *the Shimmer wireless ECG sensor* para coletar os dados de ECG.

O estudo teve como motivação prover um *dataset* para pesquisa de reconhecimento de emoções, comparar a performance de equipamentos de baixo custo e equipamentos médicos e para demonstrar viabilidade na integração de métodos de computação afetiva em relação à vida cotidiana. A escolha dos vídeos para estímulo foi feita por outra pesquisa (GABERT-QUILLEN et al., 2015), portanto não foi escolha e passo-a-passo dos autores. Os autores permitiram a sua utilização para a pesquisa.

É possível observar as diferenças e o resumo das bases na Tabela 1.

Tabela 1 – Resumo características das bases

Base	Estimulo	Núm.	SetUp	Espaço/Emoções
DEAP	40 Vídeos	32	32 canais em 512Hz Sinais fisiológicos periféricos Biosemi ActiveTwo system	Valência X Atividade
MPED	170 vídeos	23	62 canais em 1000Hz ESI NeuroScan System	Alegria, agradável, raiva, tristeza, nojo, medo e neutralidade
DREAMER	18 Vídeos	23	Emotiv EPOC wireless EEG headset	Valência X Atividade X Dominância
ASCERTAIN	36 vídeos	58	8 canais em 32 Hz 1 eletrodo na cabeça 1 sensor na testa eletrodo de referencia na orelha esquerda	Valência X Atividade
SEED	10 vídeos	15	62 canais em 1000Hz ESI NeuroScan System	Valência X Atividade

## 5.2 Pré-processamento dos sinais

O pré-processamento dos sinais é necessário para remoção de ruídos e artefatos e melhor classificação, principalmente os sinais de EEG, por apresentarem amplitudes consideravelmente baixas caso comparados a outros sinais eletrofisiológicos e por este motivo poderem ser facilmente contaminados por fontes externas e internas no momento de sua coleta, apesar disso, esse processo necessita ser feito de maneira cuidadosa a fim de não retirar informação importante dos sinais, podendo até afetar sua análise posteriormente (TORRES et al., 2020a), além de ser utilizado para separar as diferentes bandas pretendidas.

Suas maiores formas de contaminação são por piscadas de olho, movimento ocular ou muscular, batidas do coração e contaminações da energia (ROSA, 2019), com essas informações há uma certa quantidade de filtros possíveis para a diminuição de ruído, os mais utilizados são os filtros de baixa frequência, de alta frequência e os filtros *notch*.

Na Figura 4 é visto as frequências requisitadas do EEG, portanto a faixa dos filtros é entre 1 a 50 Hz, sendo primeiramente colocar uma faixa determinada e um segundo filtro para eliminar a linha de energia.

De acordo com (TORRES et al., 2020a), os principais algoritmos de pré-processamento utilizados são análise de componentes principais (PCA), 50.1%, análise de componentes independentes (ICA), 26.8%, e padrão espacial comum (CSP), 17.7%, sendo que os dois primeiros métodos se utilizam de uma análise que isola os sinais originais e o CSP se utiliza de filtros espaciais, sendo bons para a distinção de movimento muscular.

O PCA é uma técnica de análise que é utilizada para explorar as relações entre variáveis em termos de suas dimensões (OLIVEIRA, 2019), tendo como objetivo principal a redução dimensional, ao mesmo tempo tentando a mínima perda de informação para o sinal original. O algoritmo detecta variáveis com maior variância, e a partir disso faz uma seleção cada componente tende a ser dominada por uma variável.

O projeto se utilizará do pré-processamento PCA, visto que é o mais utilizado nas pesquisas, além de ser o algoritmo que comprime o sinal juntamente com um filtro *notch* para eliminar o ruído, pois PCA não é melhor para isso e também um filtro *butterworth*, passa-bandas, entre as frequências de 0.1 a 50 Hz. Esses dois métodos serão utilizados em algoritmos diferentes para a sua comparação.

## 5.3 Extração de características

Após a filtragem do sinal, é necessário fazer a extração de suas características para haver uma classificação. Essa extração pode ser feita no domínio da frequência, como FFT, no tempo, como Hjorth e ERP, no tempo-frequência, como as transformadas

wavelets (WT, do inglês *Wavelet transform*), e o espaço, como a superfície Laplaciana.

Alguns métodos utilizados são as wavelets, com 23.3%, PCA, com 9.3% e Hjorth, com 4%, foi escolhido o método de FFT, 27.9%, para a comparação no domínio da frequência, pois é o domínio mais utilizado nas pesquisas (TORRES et al., 2020a).

As transformadas de WT representam o sinal de forma discreta ou contínua, podendo descrever as propriedades no tempo e na frequência desejada, porém se utiliza de janelas variáveis, o ideal para este problema é uma wavelet de sete níveis, que consegue separar por bandas, a base tem taxa de amostragem de 128 Hz, com seis níveis seriam sete frequências(128 Hz, 64 Hz, 32 Hz, 16 Hz, 8 Hz, 4Hz e 2 Hz), que podem ser adaptadas às taxas de frequências mais fortes do EEG.

O PCA diminui a quantidade de características temporais, agrupando as mais correlacionadas, diminuindo a complexidade do algoritmo e com a possibilidade de melhorar o algoritmo.

Já o Hjorth é ótima para baixo custo computacional e análise de tempo real, porém contém um maior erro estatístico. E por último a FFT, possui o melhor algoritmo para baixo custo computacional e é muito utilizada nos mais diversos estilos de processamento de sinais, porém possui uma perda de resolução nas altas e baixas frequências, tendo que ser utilizada juntamente com um filtro.

A partir das informações acima, foi decidido primeiramente que irá ser utilizado três formas de extração: tempo(PCA, utilizado em 24% das pesquisas), frequência (FFT, utilizado em 38% das pesquisas) e tempo-frequência (WT, utilizado em 21% das pesquisas).

## 5.4 Seleção de características

A seleção de características é a parte do processo em que o algoritmo escolhe quais específicas irão para a classificação. O *dataset* possui uma quantidade A de características e a seleção diminui para B, em que  $A > B$ , onde B possui uma quantidade significativa e mais relevantes da base de dados (KAUSHIK, 2016), deixando o treinamento mais rápido, reduzindo a complexidade do modelo e o deixando mais sensível, de acordo com (TORRES et al., 2020a) muitos das pesquisas escolhem não utilizam um método de seleção de características, 61.3%.

Apesar disso, esse processo pode ser considerado vital devido à obtenção das melhores propriedades do sinal, reduzindo o número de entradas para o classificador, podendo deixar mais leve computacionalmente, diminuindo também o número de variáveis e atributos e aumentando sua acurácia.

A seleção pode ser baseada no número de variáveis presentes, em dois métodos numéricos uni-variada e multi-variadas, em que, respectivamente, considera as entradas uma por uma e considera as entradas como um grupo de características sendo simpli-

ficada e mede os comportamentos em conjunto das variáveis. Os métodos de filtro são normalmente utilizados para pré-processamento, porém quando utilizados para seleção eles detectam os dados intrínsecos da base de dados (KAUSHIK, 2016), já no *wrapper* é utilizado um subconjunto de dados, em que se adiciona e remove recursos dos sinais, porém possui um alto custo computacional e nos *built-in algorithms* são normalmente utilizados dentro do algoritmo dos classificadores.

Nas pesquisas (TORRES et al., 2020a) mostram que os quatro métodos mais utilizados são de algoritmos genéticos com 32.3%, *Stacked Denoising Autoencoder* (SDA) com 17.7%, *wrapper*, 15.6%, porém as características foram escolhidas através do método de extração anteriormente, cada domínio teve um conjunto de características escolhidas, para serem colocadas e postas no algoritmo. Lembrando que, metade dos algoritmos não vão possuir essa seleção devido a quantidade de pesquisas que não se utilizam, assim, conseguindo fazer mais uma comparação e conclusão sobre métodos de interpretar uma emoção.

## 5.5 Tratamento pré-classificação

Como no meio dos dados possuem dados categóricos, o gênero, foi feita uma adaptação para se colocar os dados em treinamento, o gênero masculino foi de *male* para 0 e o gênero feminino foi de *female* para 1.

Após todos os dados serem transformados para numéricos foi feita a sua normalização utilizando o *StandardScaler*, que dimensiona os dados para o algoritmo não dar mais importâncias a certas entradas que outras, removendo a média e escalando a variância, padronizando a base para os modelos.

## 5.6 Classificação

Por fim, temos a classificação de cada sinal, em termos de valência e atividade. Em (TORRES et al., 2020a) e (SUHAIMI; MOUNTSTEPHENS; TEO, 2020) mostram os métodos mais utilizados como a SVM e regressão logística, Rede neural convolucional (CNN, do inglês *Convolutional neural network*), e KNN, que apesar dos bons resultados, somente 7% das pesquisas se utilizam, floresta aleatória é utilizada em 1.1%.

Devido ao tamanho dos arquivos e a o propósito do projeto os métodos utilizados para a classificação foram a regressão logística, KNN e floresta aleatória tanto para com e sem seleção de características e a SVM a mais para o método com seleção, devido a demora do algoritmo de rodar com grandes quantidades de dados e o equipamento fornecido.

A base DREAMER fornece as *labels* de valência e atividade com notas de 1 a 5, fornecidas pelos próprios voluntários, seguindo a lógica dessa pesquisa, a partir dessas notas foi dividido em alta e baixa atividade e alta e baixa valência, sendo assim uma



classificação binária para cada eixo do plano desejado.

Todos os classificadores possuem classificação binária, assim, sendo coerente com a base de dados.

Para a determinação de cada parâmetros foram utilizados algumas ferramentas como o *gridsearch* para a busca do melhor resultado, além das comparações com as pesquisas, em que se pode observar que é feito com a maioria dos parâmetros padrões.

## 5.7 Métricas de avaliação

Como um dos objetivos dessa pesquisa é a comparação entre os métodos utilizados para a classificação do sinal, além de fornecer uma informação válida e importante, é necessário algum método de avaliação dos algoritmos, deixando, assim, claro o quão bom o modelo é e o quanto melhor ou pior que outro. Algumas das métricas como a acurácia, *recall*, especificidade, precisão e F-score.

O modelo é dividido em treinamento e validação, em que se baseia realizar uma previsão de alguma entrada e suas propriedades, para a sua classificação há duas soluções: positiva, em que o algoritmo acerta, e negativa, que o algoritmo erra.

Tendo em vista a definição de positiva e negativa acima, é possível definir quatro grupos para predições (FERRARI; SILVA, 2017):

- Verdadeiro positivo (VP): quando a resposta é positiva e, verificando, a classe era positiva;
- Verdadeiro negativo (VN): quando a resposta é negativa e, verificando, a classe era negativa;
- Falso positivo (FP): quando a resposta é positiva e, verificando, mas a classe era negativa; e
- Falso negativo (FN): quando a resposta é negativa e, verificando, mas a classe era positiva.

Um método de avaliação é a matriz de confusão, que representa os resultados de forma simples e visual, indicando a quantidade de ocorrências que houve em cada classe. Pode-se observar na Tabela 2 um exemplo de como é feita.

O total de predições é igual a um número  $N$ . A partir disso calculamos os valores preditos positivos, representado por  $\rho$  (Equação 5.1), valores preditos negativos, simbolizado por  $\eta$  (Equação 5.2), valores reais positivos, dado por  $\mu$  (Equação 5.3), valores



Tabela 2 – Matriz de confusão

		Classe de previsão	
		Positiva	Negativa
Classe original	Positiva	VP	FN
	Negativa	FP	VN

reais negativos (Equação 5.4), acertos (Equação 5.5) e erros do método, denotado por  $\tau$  (Equação 5.6) (GOLDSCHMIDT; PASSOS, 2005).

$$\rho = VP + FP \quad (5.1)$$

$$\eta = VN + FN \quad (5.2)$$

$$\mu = VP + FN \quad (5.3)$$

$$\tau = VN + FP \quad (5.4)$$

$$acertos = VP + VN \quad (5.5)$$

$$erros = FN + FP \quad (5.6)$$

A partir desses dados, podemos calcular outras métricas de avaliação: acurácia, sensibilidade, especificidade, precisão e F-score (GOLDSCHMIDT; PASSOS, 2005).

A acurácia é uma das medidas mais usadas nas pesquisas anteriores, em que se avalia o percentual de acertos, ou seja, é a razão entre a quantidade de acertos e o total, representada nesse trabalho como  $\alpha$

$$\alpha = \frac{VP + VN}{N}. \quad (5.7)$$

O *recall* ou sensibilidade detecta o sucesso dos resultados positivos, sendo calculado pela Equação 5.8 e a especificidade detecta a capacidade dos resultados negativos, mostrado pela Equação 5.9, representadas por  $\zeta$  e  $\epsilon$ , respectivamente,

$$\zeta = \frac{VP}{VP + FN} \quad (5.8)$$

$$\epsilon = \frac{VN}{FP + VN}. \quad (5.9)$$

A precisão, a segunda medida mais utilizada nas pesquisas, é uma métrica em que se faz a avaliação da quantidade de VP sobre a soma de todos os positivos, vista na Equação 5.10, representada por  $\phi$

$$\phi = \frac{VP}{VP + FP}. \quad (5.10)$$

E o F-score se utiliza da precisão e sensibilidade para obter uma média harmônica, calculada pela Equação 5.11, representado por  $\omega$

$$\omega = 2 * \frac{\phi * \zeta}{\phi + \zeta}. \quad (5.11)$$

Como é um sistema que se deseja medir os acertos do modelo, as métricas utilizadas foram a acurácia e a precisão.

## 6 Algoritmos utilizados

Nesse capítulo serão expostos os algoritmos feitos para a elaboração desse projeto, explicitando quais métodos foram utilizados, suas bibliotecas, a explicação do porquê cada método está presente, o diagrama de blocos dos sistemas propostos e as características que serão extraídas.

Para o treinamento dos modelos, o *dataset* foi dividido em 80% para o treinamento e 20% para uma validação.

### 6.1 Diagrama de blocos

O projeto foi dividido em duas frentes: a frente que foi extraída as características e a sem extração de características. Para a melhor compreensão das funções e passagens do código, foi criado um fluxograma geral do método, Figura 8, e dois fluxogramas mais detalhados de cada frente, Figura 15 e 16

Nos dois casos começam e terminam de uma forma semelhante, o pré-processamento de dados é parecido, em que é feito um filtro passa-bandas butterworth entre 0.1 e 50 Hz ou é aplicado a transformada wavelet de 7 níveis, em que são separados os sinais em faixas de frequências, vista na Figura 4. E a classificação com os métodos de avaliação também são iguais, em que se é feito quatro ou três classificações, uma regressão logística, SVM, KNN e floresta aleatória, tendo como métricas principais a acurácia e precisão.

Então os algoritmos foram divididos na seleção de características devido a 61.3% dos projetos pesquisados não fazem essa seleção.

Os detalhes de cada fluxograma serão abordados no próximo tópico.

### 6.2 Análise dos dados

Como foram feitos vários domínios e estilos de processamento dos dados, o estilo de análise foi padrão. A seguir irá ser esclarecido como foi feita uma análise inicial da base de dados, levando em conta o gênero e idade das pessoas participantes.

Primeiramente, foi plotado um gráfico que mostra a distribuição das notas de atividade e valência para cada vídeo, Figura 9 e 10 e , em que valores entre 3 a 5 são considerados altos. A partir disso, é possível supor as reações de cada vídeo, como por exemplo, no primeiro vídeo (vídeo 0) foi uma emoção com alta valência, porém baixa atividade, um sentimento de calma e relaxamento, já no vídeo 3 é o oposto, trazendo um sentimento de raiva e ansiedade. O vídeo 16 traz uma baixa valência e atividade, ou seja,

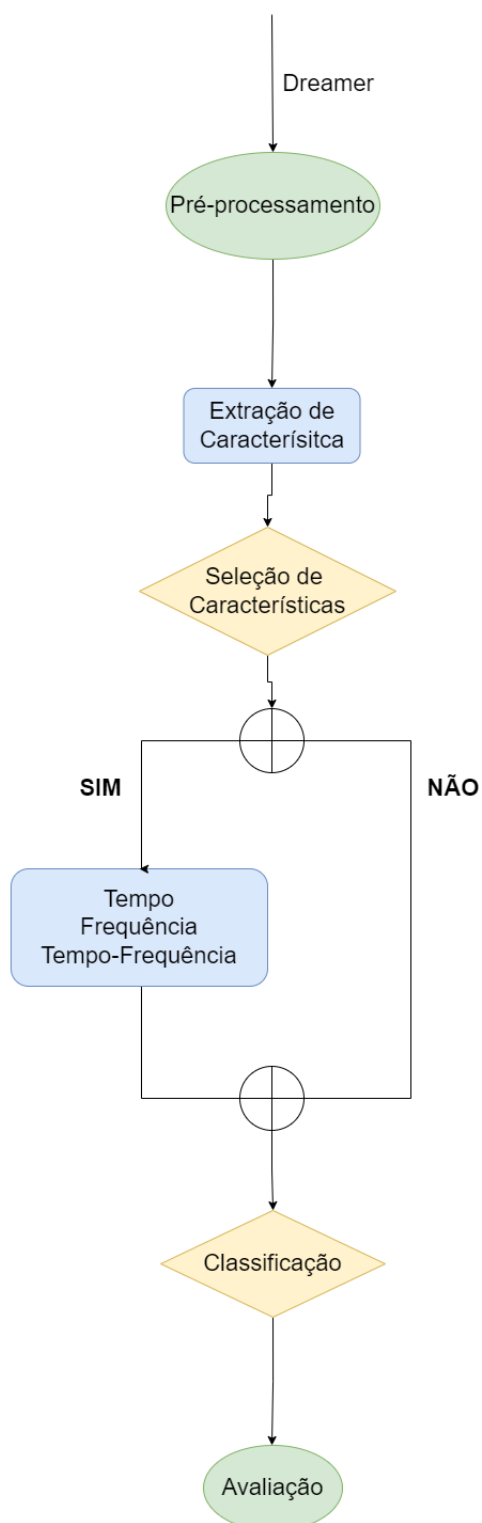


Figura 8 – Fluxograma do algoritmo proposto

um sentimento de tristeza, sendo seu oposto o vídeo 12, trazendo uma alta valência e atividade, com o sentimento de alegria.

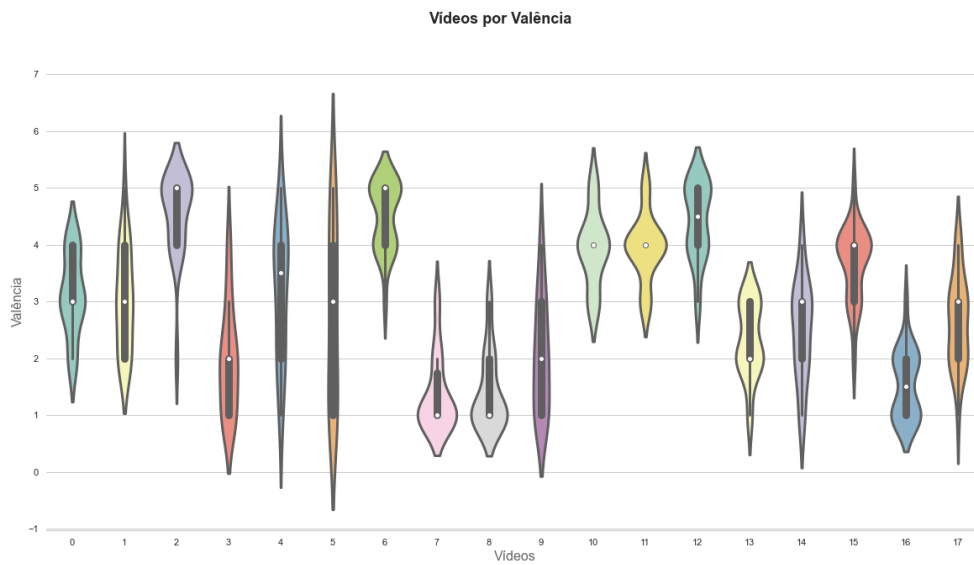


Figura 9 – Gráfico de distribuição de vídeos por valência

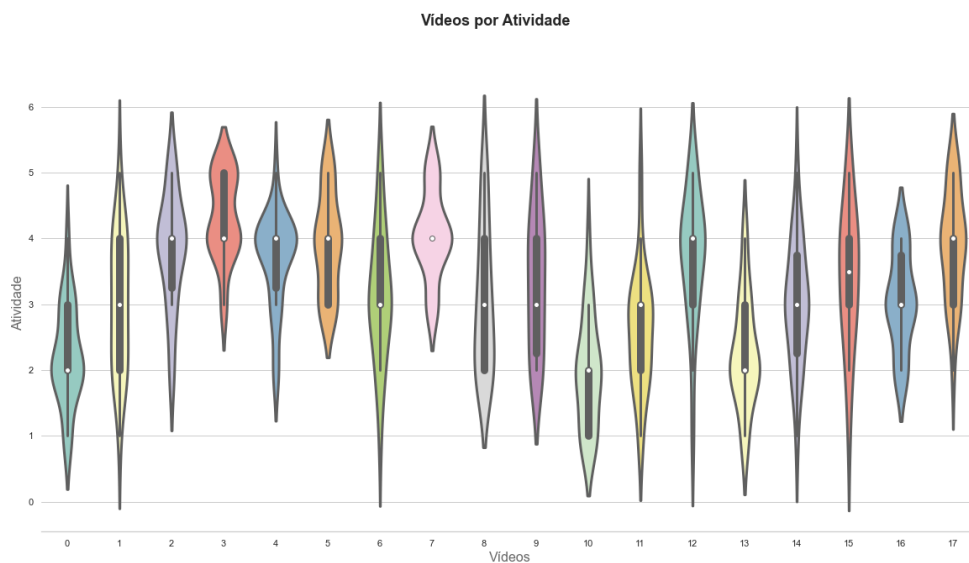


Figura 10 – Gráfico de distribuição de vídeos por valência

Então, houve a análise por gênero, a distribuição de cada eixo do plano para homens e para mulheres, Figura 13 e 14, a partir dela se pode inferir que o gênero masculino tende a ter uma valência mais alta, tendendo a ter emoções mais positivas que as mulheres, já em termos de intensidade são bem parecidos.

Por fim, foi feita a análise das distribuições pelas idades, Figuras ?? e ?? dois pontos distintos para se observar no gráfico, que entre as idade 23 e 24 anos, a tendência




Figura 11 – Gráfico de distribuição de gênero por valência

dos sentimentos positivos fica consideravelmente maior, podendo ser até feito um estudo em que se pesquisa o por quê dessa mudança tão perceptível em idades tão próximas. E a outra observação importante é a diferença entre as idades de 23 e 33 anos, os dois planos ficam também consideravelmente maiores, mostrando que sentem mais emoções positivas com uma maior intensidade, podendo mostrar o amadurecimento ou as conquistas depois dos 20, também podendo ser um estudo a se investigar.

### 6.3 Com seleção de características

De acordo com (TORRES et al., 2020a), os três métodos mais utilizados de extração de características são por tempo, frequência e tempo-frequência, analisando a literatura e feitos testes com alguns dos métodos, foram escolhidos três formas em cada uma desses domínios, a análise de componentes principais (PCA), a transformada de Fourier e a transformada Wavelet para extrair as características dos sinais de EEG.

A partir da escolha dos domínios foi determinado quais características iriam ser extraídas dos sinais para entrarem na classificação. No domínio do tempo, foram retiradas o valor eficaz (RMS), valor médio (RMV) e a energia do sinal (POW), sendo calculadas através




Figura 12 – Gráfico de distribuição de gênero por atividade

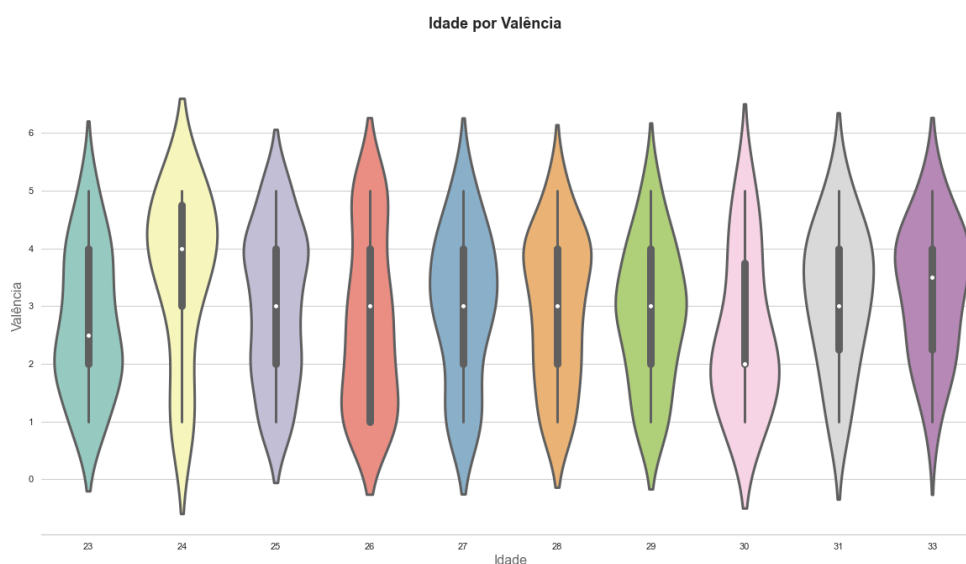


Figura 13 – Gráfico de distribuição de idade por valência

de suas fórmulas:

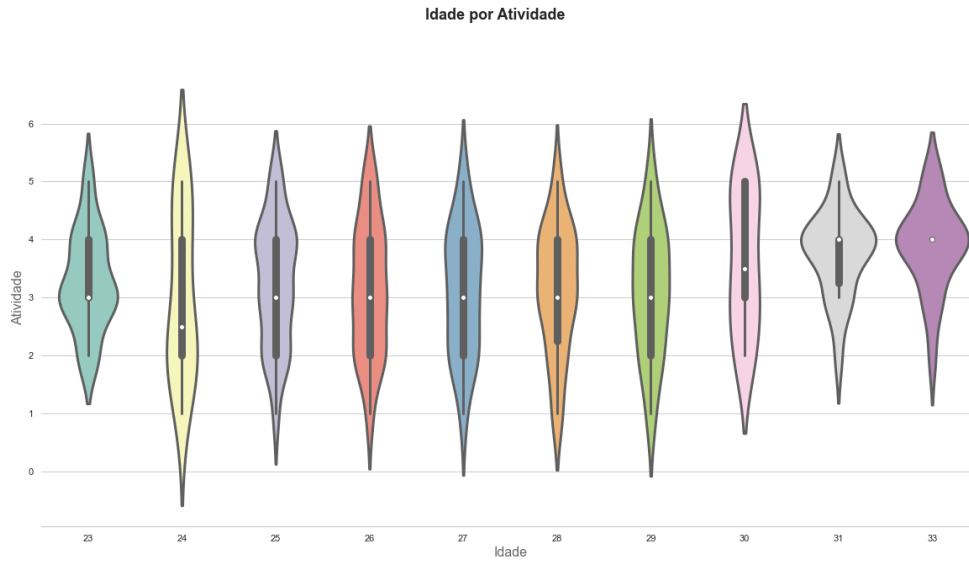


Figura 14 – Gráfico de distribuição de idade por atividade

$$RMS = \sqrt{\frac{1}{N} \sum x_t^2[n]} \quad (6.1)$$

$$RMV = \frac{1}{N} * \sum |x_t[n]| \quad (6.2)$$

$$POW = \sum x_t^2[n] \quad (6.3)$$

Com N sendo o número de amostras e

$$x_t$$

o sinal no tempo discreto.

Já no domínio da frequência foram extraídos a energia por banda de sinal, a frequência média e a mediana, calculadas pelos seus conceitos através dos cálculos:

$$Energia = \sum x_f^2[n] \quad (6.4)$$

$$MeanFreq = \frac{1}{T} * \int_0^T |x_f(t)|^2 dx \quad (6.5)$$

E por último, no domínio do tempo-frequência foram retiradas as características de energia e entropia do sinal, por bandas, através dos seus princípios por:

$$entropy = - \sum P(x_{wi}[n]) * \log_2(P(x_{wi}[n])) \quad (6.6)$$



$$energy = \int |x_w(t)|^2 dt \quad (6.7)$$

Na Figura 15, é possível verificar visualmente o fluxograma desse algoritmo.

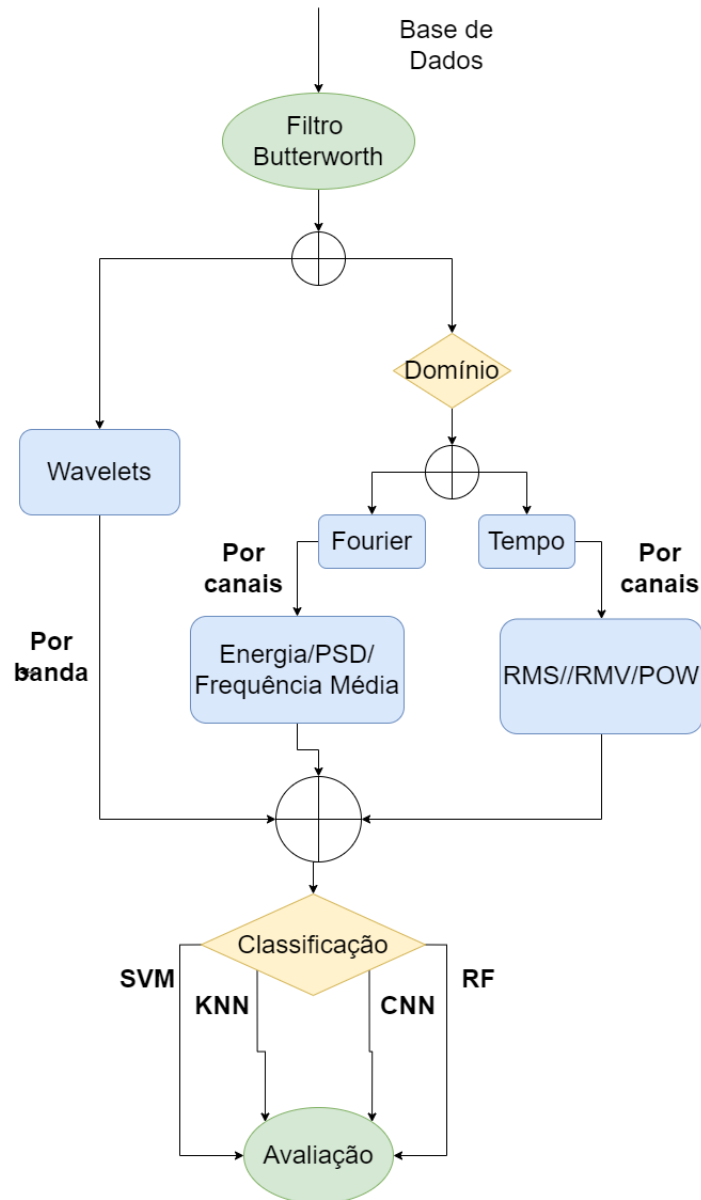


Figura 15 – Fluxograma do algoritmo com seleção de características

## 6.4 Sem seleção de características

Seguindo o mesmo pensamento da seção anterior, foram utilizados os mesmo três domínios para a linha de sem seleção de características do sinal. Assim sendo feito um filtro de *butterworth* com PCA para o domínio do tempo. O mesmo filtro de *butterworth* com a transformada de *Fourier*, ficando assim no domínio da frequência. E por último, foi feita a transformada de *wavelet* em 7 níveis para serem divididas por faixas de frequência, assim pertencendo ao domínio tempo-frequência, podendo conferir o fluxograma na Figura 16.

## 6.5 Elementos em comum

Nessa seção será abordado os detalhes do algoritmo que são comuns tanto para o método com seleção quanto para o sem seleção.

Como mostrado na Figura 8, a base de dados disponível é a DREAMER, o autor da base autorizou sua utilização mandando por email seu arquivo .mat com suas características. A partir disso, esse arquivo foi transformado através do python, em um .csv para melhor compreensão e manipulação dos dados.

Com os dados já disponíveis em um dataframe foi feito seu pré-processamento, em parte dos domínios, com um filtro butterworth, entre as faixas de frequência 0.1 a 50 Hz.

Após essa etapa foram divididas em estilos de características, nos três domínios escolhidos já explicitados e tendo o algoritmo dividido em sem e com seleção de características.

Com os arquivos salvos, foram analisados através de mapas de calor e gráficos de correlação entre o sinal e a respost preterida, em que valência foi dividido em 0 e 1, tendo que 0 são emoções negativas e 1 emoções positivas, e atividade, 0 são emoções com baixa intensidade e 1 com alta intensidade. A partir dessa análise pôde ser inferidas algumas informações como a importância de cada característica com ou sua faixa de frequência ou com seu canal.

Por fim, foram feitas as classificações, foram quatro algoritmos de base, pelo propósito de ter uma alta comparação da qualidade de cada um, foram feitas uma KNN, regressão logística (RL), floresta aleatória e SVM, com a justificativa de serem as formas de classificação mais utilizadas, utilizando-se de quatro modelos distintos para uma melhor comparação para declarar a melhor forma de se relacionar emoções com o EEG.

E por último, foram escolhidas as formas de julgar a efetividade de cada modelo, sendo escolhidas a acurácia e precisão, pois é de mais interesse saber a quantidade de acertos em relação ao total.

A Tabela 3 mostra como será realizado o método de cada um dos quatro algoritmos.

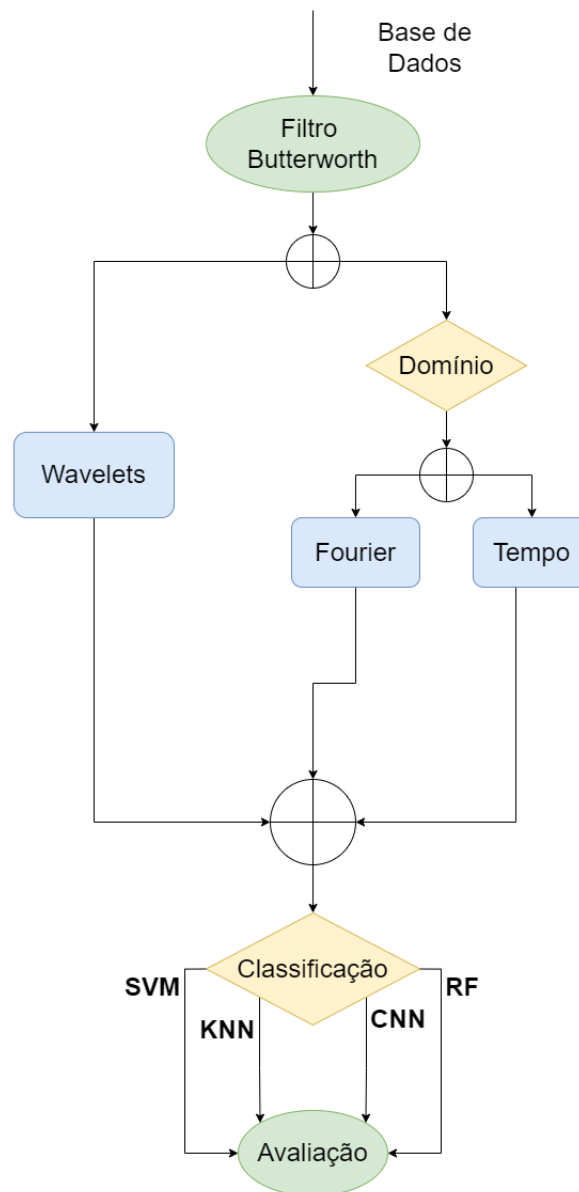


Figura 16 – Fluxograma do algoritmo sem seleção de características

## 6.6 Bibliotecas computacionais

Algumas bibliotecas foram desenvolvidas para facilitar a composição de códigos de aprendizagem de máquina. Serão explicitadas nessa seção as bibliotecas utilizadas e o

Tabela 3 – Resumo do algoritmo

Base Dreamer	#1	#2	#3
<b>Pré-processamento</b>	Filtro Butterworth	Filtro Butterworth	Rejeita Faixa
<b>Extração</b>	PCA	Tempo	Wavelet
<b>Seleção</b>	RMS RMV POW	Energia Frequência média Frequência mediana	Energia Entropia
<b>Classificação</b>	SVM Floresta aleatória KNN R. Logística	SVM Floresta aleatória KNN R. Logística	SVM Floresta aleatória KNN R. Logística
<b>Métricas</b>	Acurácia Precisão F1-score	Acurácia Precisão F1-score	Acurácia Precisão F1-score

motivo para tal.

A biblioteca pandas ([MCKINNEY, 2010](#)), também foi utilizada para auxílio. É uma biblioteca de código livre para *python* para análise e manipulação de dados, ela é bastante utilizada em aprendizagem de máquina, pois ela facilita a movimentação de *DataFrames*, permitindo várias operações de álgebra. Outras bibliotecas de assistência é a *numpy* ([HARRIS et al., 2020](#)) e a *matplotlib* ([HUNTER, 2007](#)). A *numpy* é uma biblioteca para computação científica, que suporta grandes processamentos e possui um grande número de funções matemáticas. Já a biblioteca *matplotlib* é para a criação e visualização de dados, apesar de outras bibliotecas possuírem a função de *plot*, a *matplotlib* permite um melhor desenvolvimento visual de cada gráfico.

A última biblioteca válida para citar é a *Scikit-learn* ([BUITINCK et al., 2013](#)), também de código aberto para linguagem *python*, nela inclui algoritmos de pré-processamento, classificação, regressão e agrupamento, sendo muito utilizada para classificadores SVM que será utilizado no projeto. A *Scikit-learn* interage com as bibliotecas *numpy* e *matplotlib*, ela foi desenvolvida para a aplicação de aprendizagem de máquina.

Portanto, as bibliotecas utilizadas para o algoritmo serão:

- Pandas;
- Numpy;
- Matplotlib; e
- Scikit-learn

## 7 Resultados e Discussões

Nesse capítulo será abordado o desfecho do trabalho. Será também dividido entre análise dos dados e os algoritmos com e sem seleção de características, tendo em vista uma conclusão que possa evidenciar as diferenças de cada parte do desenvolvimento.

Em todos os classificadores os dados foram testados as duplas de: 50% e 50%, 60% e 40%, 70% e 30% , 80% e 20%, para treinamento e teste de valência e atividade, o de melhor resultado e que será mostrado foi de 80% e 20%. Nos testes, 1 representa uma emoção positiva de valência e alta intensidade de atividade e 0 uma emoção negativa e baixa intensidade, em que valência e atividade não são dependentes.

Como na base DREAMER elas foram classificadas em 1 a 5, de acordo com ([KAT-SIGIANNIS; RAMZAN, 2017](#)), os dados de valência entre 3 a 5 são emoções positivas, e os dados de atividade 4 e 5 são emoções de alta intensidade.

### 7.1 Com seleção de características

Após o delineamento do algoritmo foram analisadas as métricas de cada uma das propostas. Em todos os classificadores o dataframe de teste e treino foram iguais, em que 80% para treino e 20% para teste, tendo em vista que todos os dados estavam normalizados e com dados numéricos.

Primeiramente, será evidenciada a abordagem no domínio do tempo. O tratamento de dados foi feito tanto com os sinais de estímulo quanto os sinais base, em todos os domínios, em que a partir de funções foram retiradas as suas características RMS, RMV e POW, após a análise dos dados foram estabelecidos em quatro classificadores básicos diferentes, cujos resultados foram tabelados.

A princípio foi feita uma regressão logística ,baseado em ([BROWNLEE, 2021](#)), com validação cruzada de 10, sua acurácia foi de 62.10% e 59.40%. Então foi feita uma SVM com validação cruzada de 5, sua acurácia aferida foi de 65.00%, 47.00% e precisão 66.00% 44.00%.

Já o modelo de KNN foi feito um GridSearch, que buscava entre 3 a 20 vizinhos qual seria a melhor opção com o validação cruzada de 5, tendo como resultado melhor para atividade o número de 10 vizinhos com acurácia de 67.09% e precisão de 66% e para valência 19 vizinhos com 51.32% de acurácia e 49.00% de precisão. E por último, a floresta de decisão, sem validação cruzada, teve uma acurácia de 70.89% e 47.37% e uma precisão de 70.00%, 44.00%. Sendo que os primeiros são para a classificação de atividade e os segundos para a classificação de valência, estes resultados estão resumidos nas Tabelas 4 e 5.

Tabela 4 – Resumo dos resultados para atividade no domínio do tempo com seleção de características

Classificador atividade	Acurácia	Precisão	F1-score
<b>Regressão L.</b>	62.10%	60.10%	52.18%
<b>SVM</b>	65.00%	66.00%	61.00%
<b>KNN</b>	67.09%	66.00%	67.00%
<b>Floresta de decisão</b>	70.89%	70.00%	71.00%

Tabela 5 – Resumo dos resultados para valência no domínio do tempo com seleção de características

Classificador atividade	Acurácia	Precisão	F1-score
<b>Regressão L.</b>	59.40%	60.60%	74.32%
<b>SVM</b>	47.00%	44.00%	42.00%
<b>KNN</b>	51.32%	49.00%	51.00%
<b>Floresta de decisão</b>	47.37%	44.00%	46.00%

Apresenta-se a seguir a abordagem no domínio da frequência. O tratamento de dados também foi feito tanto com os sinais de estímulo quanto com os sinais de base, em que, a partir de funções criadas, foram computadas as suas características energia, frequência média e mediana, como na análise feita no tópico anterior, e então colocados em quatro classificadores básicos diferentes. Os resultados são reportados a seguir, sendo que os primeiros referentes à classificação de atividade e os segundos à classificação de valência.

A regressão logística com validação cruzada de 10, teve uma acurácia de 55.90% e 60.70%. Após foi feita uma SVM com validação cruzada de 5, sua acurácia de 62.00%, 57.00% e precisão 69.00% 50.00%.

Já o modelo de KNN foi feito um GridSearch, que buscava entre 3 a 20 vizinhos qual seria a melhor opção com o validação cruzada de 5, tendo como resultado melhor para atividade o número de 8 vizinhos com acurácia de 55.02% e precisão de 54.00% e para valência 15 vizinhos com 55.26% de acurácia e 53.00% de precisão. E por último, a floresta de decisão, sem validação cruzada, teve uma acurácia de 61.84% e 48.68% e uma precisão de 61.00%, 44.00%. Estes dados são apresentados nas Tabelas 6 e 7

Tabela 6 – Resumo dos resultados para atividade no domínio da frequência com seleção de características

Classificador atividade	Acurácia	Precisão	F1-score
<b>Regressão L.</b>	55.90%	55.30%	40.00%
<b>SVM</b>	62.00%	69.00%	55.00%
<b>KNN</b>	55.02%	54.00%	54.00%
<b>Floresta de decisão</b>	61.84%	61.00%	61.00%

A terceira abordagem, que se refere ao domínio tempo-frequência, teve o trata-

Tabela 7 – Resumo dos resultados para valência no domínio da frequência com seleção de características

Classificador Valência	Acurácia	Precisão	F1-score
Regressão L.	60.70%	60.90%	75.29%
SVM	57.00%	50.00%	45.00%
KNN	55.26%	53.00%	52.00%
Floresta de decisão	48.68%	44.00%	41.00%

mento de dados feito tanto com os sinais de estímulo quanto com os sinais de base, para os quais foram computadas as suas características energia e entropia, de acordo com o previamente exposto. Então, foram testados os quatro classificadores.

A regressão logística com validação cruzada de 10, teve uma acurácia de 57.30% e 62.90%. Após foi feita uma SVM com validação cruzada de 5, sua acurácia de 69.00%, 60.00% e precisão 68.00%, 58.00%.

Já o modelo de KNN foi feito um GridSearch, que buscava entre 3 a 20 vizinhos qual seria a melhor opção com o validação cruzada de 5, tendo como resultado melhor para atividade o número de 18 vizinhos com acurácia de 60.00% e precisão de 57.00% e para valência 19 vizinhos com 65.00% de acurácia e 63.00% de precisão. E por último, a floresta de decisão, sem validação cruzada, teve uma acurácia de 65.00% e 60.00% e uma precisão de 64.00%, 59.00%. Sendo que os primeiros são para a classificação de atividade e os segundos para a classificação de valência. Dados apresentados nas Tabelas 8 e 9

Tabela 8 – Resumo dos resultados para atividade no domínio de tempo-frequência com seleção de características

Classificador atividade	Acurácia	Precisão	F1-score
Regressão L.	57.30%	54.30%	45.00%
SVM	69.00%	68.00%	65.00%
KNN	60.00%	57.00%	60.00%
Floresta de decisão	65.00%	64.00%	65.00%

Tabela 9 – Resumo dos resultados para valência no domínio de tempo-frequência com seleção de características

Classificador Valência	Acurácia	Precisão	F1-score
Regressão L.	62.90%	65.60%	72.52%
SVM	60.00%	58.00%	60.00%
KNN	65.00%	63.00%	62.00%
Floresta de decisão	60.00%	59.00%	59.00%

A fim de propiciar uma quarta análise, foi repetido o processo de classificação desta vez considerando as características selecionadas mais correlacionadas.

A regressão logística com validação cruzada de 10, teve uma acurácia de 61.70%

e 59.40%. Após foi feita uma SVM com validação cruzada de 5, sua acurácia apresentou valor de 69.00%, 47.00% e precisão 68.00% 44.00%.

Já o modelo de KNN foi feito um GridSearch, que buscava entre 3 a 20 vizinhos qual seria a melhor opção com o validação cruzada de 5, tendo como resultado melhor para atividade o número de 14 vizinhos com acurácia de 60.53% e precisão de 60.00% e para valência 13 vizinhos com 51.32% de acurácia e 49.00% de precisão. E por último, a floresta de decisão, sem validação cruzada, teve uma acurácia de 60.50% e 47.37% e uma precisão de 60.00%, 47.00%. Sendo que os primeiros são para a classificação de atividade e os segundos para a classificação de valência. Resultados observados nas Tabelas 10 e 11.

Tabela 10 – Resumo dos resultados para atividade com a combinação de vários domínios com seleção de características

Classificador atividade	Acurácia	Precisão	F1-score
<b>Regressão L.</b>	61.70%	59.80%	53.07%
<b>SVM</b>	69.00%	68.00%	67.00%
<b>KNN</b>	60.53%	60.00%	59.00%
<b>Floresta de decisão</b>	60.50%	60.00%	59.00%

Tabela 11 – Resumo dos resultados para valência com a combinação de vários domínios com seleção de características

Classificador atividade	Acurácia	Precisão	F1-score
<b>Regressão L.</b>	59.40%	63.40%	69.98%
<b>SVM</b>	47.00%	44.00%	43.00%
<b>KNN</b>	51.32%	49.00%	49.00%
<b>Floresta de decisão</b>	47.37%	47.00%	45.00%

É visto que o classificador, no geral, mais forte, é o mais simples, a regressão logística, isso pode ser explicado devido a característica do sinal ser contínuo no tempo, pois a regressão logística é um classificador que aproxima através de uma curva, enquanto os outros são por categoria, alocando em grupos, e pelo fato de ser um sinal contínuo, ele se adequou mais à regressão logística.

## 7.2 Sem seleção de características

De modo análogo ao método com seleção de características, após as análises feitas na base de dados final e feito seu processamento, foram divididos os sinais em 80% para teste e 20% para treino, com os dados normalizados e numéricos. Para os classificadores nesta configuração notou-se que o tempo de processamento, ainda que não aferido numericamente, foi mais elevado que no modo anterior.

De início, serão apresentados os resultados no domínio do tempo. A regressão logística resultou em uma acurácia de 52.20% para atividade e 61.50% para valência, com



validação cruzada igual a 10. Já a floresta de decisão obteve 55.34% de acurácia para atividade e 60.68% para valência, e 55.00% e 59.00% de precisão, respectivamente, com validação cruzada de 5.

Por último, a KNN, com número de vizinho variando de 3 a 20, obteve uma acurácia de 52.98% e 60.25% e precisão de 53.00% e 56.00% para atividade e valência, respectivamente. Observado nas Tabelas 12 e 13.

Tabela 12 – Resumo dos resultados para atividade no domínio do tempo sem seleção de características

Classificador atividade	Acurácia	Precisão	F1-score
<b>Regressão L.</b>	52.20%	42.00%	40.00%
<b>KNN</b>	52.98%	53.00%	53.00%
<b>RF</b>	55.34%	55.00%	54.00%

Tabela 13 – Resumo dos resultados para valência no domínio do tempo sem seleção de características

Classificador valência	Acurácia	Precisão	F1-score
<b>Regressão L.</b>	61.50%	61.60%	76.18%
<b>KNN</b>	60.25%	56.00%	58.00%
<b>RF</b>	62.68%	59.00%	59.00%

Já os resultados no domínio da frequência apresentaram os melhores resultados, o que explica ser a combinação de domínio e método mais utilizada. Para a regressão logística, apresentou uma acurácia de 58.10% e 64.10%, e uma precisão de 58.00% e 64.50%.

Já no algoritmo de vizinhos mais próximos de 93.20% e 94.80% de acurácia e 93.00% e 94.00% de precisão, com o número de vizinhos também variando de 3 a 20 com validação cruzada igual a 5. E nas florestas aleatórias obteve uma acurácia de 90.65% e 92.61%, e uma precisão de 91.00% e 92.00%, sendo atividade e valência, respectivamente, em todos os resultados que podem ser vistos nas Tabelas 14 e 15.

Tabela 14 – Resumo dos resultados para atividade no domínio da frequência sem seleção de características

Classificador atividade	Acurácia	Precisão	F1-score
<b>Regressão L.</b>	58.10%	58.00%	50.27%
<b>KNN</b>	93.20%	93.00%	93.00%
<b>RF</b>	90.65%	91.00%	91.00%

Por fim, no domínio tempo-frequência foram aplicados os mesmos classificadores, começando com a regressão com a métrica de acurácia de 57.30% e 64.10% e precisão 54.10% e 66.30%.

O algoritmo de KNN obteve como resposta 56.29% e 61.97% de acurácia, 55.00% e 57.00% de precisão, com vizinhos de 3 a 20 e validação cruzada de 5. E por último a

Tabela 15 – Resumo dos resultados para valência no domínio da frequência sem seleção de características

<b>Classificador valência</b>	<b>Acurácia</b>	<b>Precisão</b>	<b>F1-score</b>
<b>Regressão L.</b>	64.10%	64.50%	78.07%
<b>KNN</b>	94.80%	94.00%	95.00%
<b>RF</b>	92.61%	92.00%	93.00%

floresta de decisão com acurácia de 60.66% e 66.50% e precisão de 60.00% e 64.00%, sendo atividade e valência respectivamente. Resultados observados nas Tabelas 16 e 17.

Tabela 16 – Resumo dos resultados para atividade no domínio do tempo-frequência sem seleção de características

<b>Classificador atividade</b>	<b>Acurácia</b>	<b>Precisão</b>	<b>F1-score</b>
<b>Regressão L.</b>	57.30%	54.10%	57.00%
<b>KNN</b>	56.29%	55.00%	54.00%
<b>RF</b>	60.66%	60.00%	59.00%

Tabela 17 – Resumo dos resultados para valência no domínio do tempo-frequência sem seleção de características

<b>Classificador valência</b>	<b>Acurácia</b>	<b>Precisão</b>	<b>F1-score</b>
<b>Regressão L.</b>	64.10%	66.30%	75.14%
<b>KNN</b>	61.97%	57.00%	59.00%
<b>RF</b>	66.50%	64.00%	60.00%

## 8 Conclusão

Visto que o método escolhido de algoritmo foi dividido em duas partes, o desfecho desse trabalho será dividido também, em que se abordará o método de melhor métrica com seleção, sem seleção e a conclusão final englobando a melhor métrica juntamente com as hipóteses sobre a provocação de sentimento.

Na Tabela 18, podemos observar os dois melhores classificadores, sendo dos algoritmos com seleção, para cada domínio na determinação da Atividade. Os dois melhores métodos, para esse pesquisa, são no domínio do tempo com o classificador de floresta aleatória e no domínio de wavelet com a SVM, apesar de não serem métricas extremamente altas, elas estão de acordo com as pesquisas (KATSIGIANNIS; RAMZAN, 2017), (KOELSTRA et al., 2011), (TORRES et al., 2020a) em relação a base DREAMER e aos métodos com seleção de características.

Tabela 18 – Maiores resultados com seleção de características de Atividade

Classificador atividade	Acurácia	Precisão	F1-score
<b>KNN - tempo</b>	67.09%	66.00%	67.00%
<b>Floresta de decisão - tempo</b>	70.89%	70.00%	71.00%
<b>SVM - FFT</b>	62.00%	69.00%	55.00%
<b>Floresta de decisão - FFT</b>	61.84%	61.00%	61.00%
<b>SVM - WT</b>	69%	68%	65%
<b>Floresta de decisão - WT</b>	65%	64%	65%
<b>Regressão L.</b>	61,70%	59.80	53.07
<b>SVM</b>	69.00%	68.00%	67.00%

Na Tabela 19, também podemos observar os dois melhores classificadores para cada domínio na determinação da atividade. Pode-se observar que a valência tem menos correlação que a atividade quando se trata das características do EEG, é perceptível que, enquanto na atividade o classificador que mais possui métricas é a SVM, na valência é o KNN, sendo este e a regressão logística no domínio de tempo-frequência e frequência, respectivamente, as duas métricas de melhor desempenho.

Também corroborando resultados da bibliografia, em que (KATSIGIANNIS; RAMZAN, 2017), tem acurácia de valência de 62.49% e 62.17% de atividade no domínio da frequência, o domínio que foi igual nas duas *labels*.

Já para os algoritmos sem seleção de características, obteve-se resultados melhores no domínio da frequência. Na Tabela 20 observa-se as duas maiores métricas de cada domínio para atividade, sendo as duas maiores no domínio da frequência com KNN e Floresta de decisão, as duas com mais de 90% de acurácia e métrica, comprovando a pesquisa de (TORRES et al., 2020a) que KNN obtém desempenho significativo, porém

Tabela 19 – Maiores resultados com seleção de características de valência

Classificador Valência	Acurácia	Precisão	F1-score
Regressão L. - tempo	59.40%	60.60%	74.32%
KNN - tempo	51.32%	49.00%	51.00%
Regressão L. - FFT	60.70%	60.90%	75.29%
SVM - FFT	57.00%	50.00%	45.00%
Regressão L. - WT	62.90%	65.60%	72.52%
KNN - WT	65.00%	63.00%	62.00%
Regressão L.	59.40%	63.40%	69.98%
KNN	51.32%	49.00%	49.00%

só é usada em 2% das pesquisas.

Tabela 20 – Maiores resultados sem seleção de características Atividade.

Classificador Atividade	Acurácia	Precisão	F1-score
KNN - tempo	52.98%	53.00%	53.00%
Floresta de decisão - tempo	55.34%	55.00%	54.00%
KNN - FFT	93.20%	93.00%	93.00%
Floresta de decisão - FFT	90.65%	91.00%	91.00%
genRegressão L. - WT	57.30%	54.10%	57.00%
Floresta de decisão - WT	60.66%	60.00%	59.00%

Na Tabela 21 só reitera o resultado de Atividade, em que os dois melhores resultados se dão no domínio da frequência com os classificadores de KNN e Floresta de decisão, também com mais de 90% de acurácia e precisão.

Tabela 21 – Maiores resultados sem seleção de características Valência.

Classificador Valência	Acurácia	Precisão	F1-score
Regressão L. - tempo	61.50%	61.60%	76.18%
Floresta de decisão - tempo	62.68%	59.00%	59.00%
KNN - FFT	94.80%	94.00%	95.00%
Floresta de decisão - FFT	92.61%	92.00%	93.00%
Regressão L. - WT	64.10%	66.30%	75.14%
Floresta de decisão - WT	66.50%	64.00%	60.00%

Na pesquisa que culminou na composição da base de EEG usada neste trabalho, os pesquisadores utilizaram o método com extração de características no domínio da frequência, que se evidenciou um eficiente domínio para processar sinais de EEG em relação às emoções.

Nessa pesquisa, podemos afirmar que, com as condições impostas desde o equipamento de baixo custo até os algoritmos utilizados, que o domínio da frequência juntamente com o método sem seleção de características foram as estratégias de melhor desempenho para sentimento interpessoal a partir de sinais de eletroencefalografia.

Comparando com os trabalhos de (TORRES et al., 2020a), em que se observa esses tratamentos com outras bases, que se utilizam de pedaços de vídeos, em vez de videocliques, os resultados apresentam acurácia e precisão um pouco maiores que as DREAMER, chegando até 96% de acurácia. A partir dessa comparação, seria plausível inferir que o método usado para induzir a emoção em cada humano possa interferir razoavelmente no resultado.

## 8.1 Trabalhos futuros

Como parte da conclusão foi uma hipótese levando em consideração estudos de outras bases de dados, os trabalhos futuros focam em revisar e aplicar os classificadores em outras bases com outros métodos de extração de sinal, com mais canais para conseguir fazer a comparação e levar a hipótese a uma conclusão certa de como a forma de extrair as emoções afeta a forma do EEG se manifestar.

Além de pesquisar novas formas de estimular emoções e encontrar o melhor procedimento para se analisar, conseguindo assim estender a pesquisa e torná-la um aplicação viável no âmbito das interfaces cérebro-máquina afetivas.

# Referências

- ABADI, M. K. et al. Decaf: Meg-based multimodal database for decoding affective physiological responses. *IEEE Transactions on Affective Computing*, IEEE, v. 6, n. 3, p. 209–222, 2015. Citado na página 50.
- ADDAN, D. Support vector machine. 2019. Disponível em: <<https://www.inf.ufpr.br/dagoncalves/IA07.pdf>>. Citado na página 44.
- ALPAYDIN, E. *Introduction to machine learning*. [S.l.]: MIT press, 2020. Citado na página 40.
- ASSOCIATION, A. P. et al. *DSM-5: Manual diagnóstico e estatístico de transtornos mentais*. [S.l.]: Artmed Editora, 2014. Citado na página 17.
- BAO, T. et al. A deep kalman filter network for hand kinematics estimation using semg. *Pattern Recognition Letters*, Elsevier, v. 143, p. 88–94, 2021. Citado na página 40.
- BASTOS-FILHO, T. F. *Introduction to Non-Invasive EEG-Based Brain-Computer Interfaces for Assistive Technologies*. [S.l.]: CRC Press, 2020. Citado na página 18.
- BEAR, M. F.; CONNORS, B. W.; PARADISO, M. A. *Neurociências: desvendando o sistema nervoso*. [S.l.]: Artmed editora, 2002. Citado 6 vezes nas páginas 20, 23, 26, 27, 29 e 33.
- BONOMO, A. M. S.; ARAUJO, T. C. C. F. d. Psicologia aplicada à cardiologia: um estudo sobre emoções relatadas em exame de holter. *Psicologia: Teoria e Pesquisa*, SciELO Brasil, v. 25, p. 65–74, 2009. Citado na página 37.
- BRADLEY, M. M.; LANG, P. J. Measuring emotion: the self-assessment manikin and the semantic differential. *Journal of behavior therapy and experimental psychiatry*, Elsevier, v. 25, n. 1, p. 49–59, 1994. Citado 2 vezes nas páginas 47 e 49.
- BROWNLEE, J. *Multinomial Logistic Regression With Python*. 2021. Disponível em: <<https://machinelearningmastery.com/multinomial-logistic-regression-with-python/>>. Citado na página 68.
- BUITINCK, L. et al. API design for machine learning software: experiences from the scikit-learn project. In: *ECML PKDD Workshop: Languages for Data Mining and Machine Learning*. [S.l.: s.n.], 2013. p. 108–122. Citado na página 67.
- CANTARELLI, T. L.; JÚNIOR, J. M.; JR, S. S. Fundamentos da medição do eeg: Uma introdução. *SEMINÁRIO DE ELETRÔNICA E AUTOMAÇÃO*. Ponta Grossa, 2016. Citado na página 39.
- CAPARELLI, T. B. et al. Projeto e desenvolvimento de um sistema multicanal de biotelemetria para detecção de sinais ecg, eeg e emg. Universidade Federal de Uberlândia, 2007. Citado na página 37.

- CARLSON, C.; DEVINSKY, O. The excitable cerebral cortex: Fritsch g, hitzig e. über die elektrische erregbarkeit des grosshirns. *arch anat physiol wissen* 1870; 37: 300–32. *Epilepsy & Behavior*, Citeseer, v. 15, n. 2, p. 131–132, 2009. Citado na página 23.
- CERVANTES, J. et al. A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, Elsevier, v. 408, p. 189–215, 2020. Citado na página 44.
- CHAGAS, S. L. d. et al. Classificação de sinais de eletroencefalograma usando máquinas de vetores suporte. Universidade Presbiteriana Mackenzie, 2009. Citado na página 44.
- CHAWLA, N. V. et al. Smote: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, v. 16, p. 321–357, 2002. Citado na página 46.
- DAMÁSIO, A. *O erro de Descartes: emoção, razão e o cérebro humano*. [S.l.]: Editora Companhia das Letras, 2012. Citado na página 37.
- EGGER, M.; LEY, M.; HANKE, S. Emotion recognition from physiological signal analysis: A review. *Electronic Notes in Theoretical Computer Science*, Elsevier, v. 343, p. 35–55, 2019. Citado na página 17.
- EKMAN, P. Emotions revealed. *Bmj*, British Medical Journal Publishing Group, v. 328, n. Suppl S5, 2004. Citado na página 37.
- FERRARI, D. G.; SILVA, L. N. D. C. *Introdução a mineração de dados*. [S.l.]: Saraiva Educação SA, 2017. Citado na página 55.
- FREITAS, M. S.; FILHO, J. B. D. F. Abordagem qualitativa da série de fourier através da análise de sinais eletroencefalográficos. *Universidade necessária*, 2008. Citado 2 vezes nas páginas 9 e 40.
- GABERT-QUILLEN, C. A. et al. Ratings for emotion film clips. *Behavior research methods*, Springer, v. 47, n. 3, p. 773–787, 2015. Citado na página 51.
- GOLDSCHMIDT, R.; PASSOS, E. *Data mining: um guia prático*. [S.l.]: Gulf Professional Publishing, 2005. Citado na página 56.
- GONÇALVES, A. R. Máquina de vetores suporte. *Acesso em*, v. 21, 2015. Citado na página 44.
- GROSS, J. J.; LEVENSON, R. W. Hiding feelings: the acute effects of inhibiting negative and positive emotion. *Journal of abnormal psychology*, American Psychological Association, v. 106, n. 1, p. 95, 1997. Citado na página 49.
- GUO, G. et al. Knn model-based approach in classification. In: SPRINGER. *OTM Confederated International Conferences "On the Move to Meaningful Internet Systems"*. [S.l.], 2003. p. 986–996. Citado na página 43.
- HARRIS, C. R. et al. Array programming with NumPy. *Nature*, v. 585, p. 357–362, 2020. Citado na página 67.
- HASSANIEN, A. E.; AZAR, A. Brain-computer interfaces. *Switzerland: Springer*, Springer, v. 74, 2015. Citado na página 30.



- HE, H. et al. Adasyn: Adaptive synthetic sampling approach for imbalanced learning. In: IEEE. *2008 IEEE international joint conference on neural networks (IEEE world congress on computational intelligence)*. [S.l.], 2008. p. 1322–1328. Citado na página 46.
- HONDA MATHEUS FACURE, P. Y. H. *Os Três Tipos de Aprendizado de Máquina*. 2017. Disponível em: <<https://lamfo-unb.github.io/2017/07/27/tres-tipos-am/>>. Citado 2 vezes nas páginas 40 e 41.
- HUNTER, J. D. Matplotlib: A 2d graphics environment. *Computing in Science & Engineering*, IEEE COMPUTER SOC, v. 9, n. 3, p. 90–95, 2007. Citado na página 67.
- IBANEZ, G. et al. Adesão e dificuldades relacionadas ao tratamento medicamentoso em pacientes com depressão. *Revista Brasileira de Enfermagem*, SciELO Brasil, v. 67, p. 556–562, 2014. Citado na página 16.
- IMPERATORI, C. et al. Default mode network alterations in individuals with high-trait-anxiety: an eeg functional connectivity study. *Journal of Affective Disorders*, Elsevier, v. 246, p. 611–618, 2019. Citado na página 17.
- JR, D. W. H.; LEMESHOW, S.; STURDIVANT, R. X. *Applied logistic regression*. [S.l.]: John Wiley & Sons, 2013. v. 398. Citado na página 42.
- JR, J. R. et al. Reconhecimento automático de emoções através da voz. Florianópolis, SC, 2017. Citado na página 37.
- KANDEL, E. et al. *Princípios de neurociências-5*. [S.l.]: AMGH Editora, 2014. Citado 7 vezes nas páginas 20, 21, 22, 27, 28, 34 e 35.
- KATSIGIANNIS, S.; RAMZAN, N. Dreamer: A database for emotion recognition through eeg and ecg signals from wireless low-cost off-the-shelf devices. *IEEE journal of biomedical and health informatics*, IEEE, v. 22, n. 1, p. 98–107, 2017. Citado 4 vezes nas páginas 17, 51, 68 e 74.
- KAUSHIK, S. Introduction to feature selection methods with an example. 2016. Citado 2 vezes nas páginas 53 e 54.
- KOELSTRA, S. et al. Deap: A database for emotion analysis; using physiological signals. *IEEE transactions on affective computing*, IEEE, v. 3, n. 1, p. 18–31, 2011. Citado 3 vezes nas páginas 17, 48 e 74.
- LANG, P. J. et al. International affective picture system (iaps): Technical manual and affective ratings. *NIMH Center for the Study of Emotion and Attention*, Florida, FL, v. 1, n. 39-58, p. 3, 1997. Citado na página 47.
- LAUKKA, P. *Vocal expression of emotion: discrete-emotions and dimensional accounts*. Tese (Doutorado) — Acta Universitatis Upsaliensis, 2004. Citado na página 37.
- MARCELLOS, C. F.; ARAUJO, S. de F. A questão da consciência na psicologia de wilhelm wundt. *Estudos e pesquisas em psicologia*, Universidade do Estado do Rio de Janeiro, v. 11, n. 1, p. 311–332, 2011. Citado na página 36.
- MARTINAZO, B. Um método de identificação de emoções em textos curtos para o português do brasil. *PUCPR, Curitiba*, 2010. Citado na página 37.



- MCKINNEY Wes. Data Structures for Statistical Computing in Python. In: WALT Stéfán van der; MILLMAN Jarrod (Ed.). *Proceedings of the 9th Python in Science Conference*. [S.l.: s.n.], 2010. p. 56 – 61. Citado na página 67.
- MELO, B. R. P. de. Identificação de estados emocionais complexos com base em ressonância magnética e eletroencefalografia: Uma abordagem com cenário de realidade virtual. UFRJ, v. 2018, 2018. Citado na página 46.
- MÉDICA, S. B. de C. Depressão será a doença mais comum do mundo em 2030. 2009. Disponível em: <<https://www.sbcm.org.br/v2/index.php?catid=0&id=1317>>. Citado na página 16.
- NIEMIC, C. Studies of emotion: A theoretical and empirical review of psychophysiological studies of emotion. 2004. Citado na página 18.
- OLIVEIRA, B. Análise de componentes principais. 2019. Citado na página 52.
- RACINE, N. et al. Global prevalence of depressive and anxiety symptoms in children and adolescents during covid-19: a meta-analysis. *JAMA pediatrics*, 2021. Citado na página 16.
- RODRIGUES, P. G. Extração de características em interfaces cérebro-máquina utilizando métricas de redes complexas. 2018. Citado 2 vezes nas páginas 9 e 39.
- ROSA, A. B. L. Exploração de técnicas para eliminação de artefatos oculares em sinais de eeg baseado em sistemas adaptativos. 2019. Citado na página 52.
- RUSSELL, J. A. A circumplex model of affect. *Journal of personality and social psychology*, American Psychological Association, v. 39, n. 6, p. 1161, 1980. Citado 2 vezes nas páginas 9 e 38.
- SAKURAI, R. *Classificação usando KNN*. 2020. Disponível em: <<http://www.sakurai.dev.br/classificacao-usando-knn/>>. Citado 2 vezes nas páginas 9 e 43.
- SANTOS, F. A. d. Comunicação não verbal: identificação de emoções através de expressões faciais na prática da psicologia clínica. 2018. Citado na página 36.
- SAÚDE, A. O. P.-A. da. Saúde mental dos adolescentes. Disponível em: <<https://www.paho.org/pt/topicos/saude-mental-dos-adolescentes>>. Citado na página 16.
- SAÚDE, A. O. P.-A. da. Transtornos mentais. Disponível em: <<https://www.paho.org/pt/topicos/transtornos-mentais>>. Citado na página 16.
- SCHAFER, A. V. O. e R. W. *Processamento em tempo discreto de sinais*. Kindle edition. [S.l.]: Pearson, 2012. (3rd ed). ISBN 9788581431024; 858143102X. Citado na página 39.
- SILVA, R. G. da. Desenvolvimento de uma solução de aprendizado de máquina automatizado integrável a múltiplos ambientes virtuais de aprendizagem. 2020. Citado na página 42.
- SIMÃO, V. O. Classificação de emoções em sinais de eeg utilizando técnicas de aprendizado de máquina. UFLA, v. 2017, 2017. Citado na página 45.
- SKINNER, B. Humanismo e behaviorismo. *Humanist*, 1972. Citado na página 41.

- SONG, T. et al. Mped: A multi-modal physiological emotion database for discrete emotion recognition. *IEEE Access*, IEEE, v. 7, p. 12177–12191, 2019. Citado 2 vezes nas páginas 17 e 49.
- SUBRAMANIAN, R. et al. Ascertain: Emotion and personality recognition using commercial sensors. *IEEE Transactions on Affective Computing*, IEEE, v. 9, n. 2, p. 147–160, 2016. Citado na página 50.
- SUHAIMI, N. S.; MOUNTSTEPHENS, J.; TEO, J. Eeg-based emotion recognition: A state-of-the-art review of current trends and opportunities. *Computational intelligence and neuroscience*, Hindawi, v. 2020, 2020. Citado 3 vezes nas páginas 17, 47 e 54.
- TODOROV, A. *Face value*. [S.l.]: Princeton University Press, 2017. Citado na página 37.
- TORRES, E. P. et al. Eeg-based bci emotion recognition: a survey. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 20, n. 18, p. 5083, 2020. Citado 7 vezes nas páginas 17, 52, 53, 54, 61, 74 e 76.
- TORRES, E. P. et al. Emotion recognition related to stock trading using machine learning algorithms with feature selection. *IEEE Access*, IEEE, v. 8, p. 199719–199732, 2020. Citado 2 vezes nas páginas 45 e 47.
- VANITHA, V.; KRISHNAN, P. Real time stress detection system based on eeg signals. *Biomedical Research*, 2017. Citado na página 17.
- WATSON, D.; CLARK, L. A.; TELLEGEN, A. Development and validation of brief measures of positive and negative affect: the panas scales. *Journal of personality and social psychology*, American Psychological Association, v. 54, n. 6, p. 1063, 1988. Citado na página 49.
- WOLPAW, J. R. Brain–computer interfaces. In: *Handbook of Clinical Neurology*. [S.l.]: Elsevier, 2013. v. 110, p. 67–74. Citado 15 vezes nas páginas 9, 20, 21, 22, 23, 24, 25, 26, 28, 30, 31, 32, 33, 34 e 35.
- YANG, W. et al. Affective auditory stimulus database: An expanded version of the international affective digitized sounds (iads-e). *Behavior Research Methods*, Springer, v. 50, n. 4, p. 1415–1429, 2018. Citado na página 47.
- YEMAM, H. *Machine Learning with Jupyter: Solving the Workflow Management Problem using Open-platforms*. 2021. <<https://towardsdatascience.com/machine-learning-with-jupyter-solving-the-workflow-management-problem-using-open-platforms-e1>> Citado na página 41.
- ZHENG, W.-L. et al. Emotionmeter: A multimodal framework for recognizing human emotions. *IEEE transactions on cybernetics*, IEEE, v. 49, n. 3, p. 1110–1122, 2018. Citado na página 46.
- ZHENG, W.-L.; LU, B.-L. Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks. *IEEE Transactions on Autonomous Mental Development*, IEEE, v. 7, n. 3, p. 162–175, 2015. Citado na página 17.

---

ZHENG, W.-L.; LU, B.-L. A multimodal approach to estimating vigilance using eeg and forehead eeg. *Journal of neural engineering*, IOP Publishing, v. 14, n. 2, p. 026017, 2017. Citado na página [49](#).