

**Universidade de Brasília - UnB**  
**Faculdade UnB Gama - FGA**  
**Engenharia Eletrônica**

**Identificação de esforço cognitivo através de  
processamento de sinais de EEG utilizando  
SVM e RF**

**Autor: Lucas Rocha Figueredo Santana e Barros**  
**Orientador: Gerardo Antonio Idrobo Pizo**

**Brasília, DF**  
**2021**



Lucas Rocha Figueredo Santana e Barros

## **Identificação de esforço cognitivo através de processamento de sinais de EEG utilizando SVM e RF**

Trabalho de conclusão 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: Gerardo Antonio Idrobo Pizo

## **CIP – Catalogação Internacional da Publicação**

Lucas Rocha Figueredo Santana e Barros

Identificação de esforço cognitivo através de processamento de sinais de EEG utilizando SVM e RF.

58p., 210 x 297 mm (FGA/UnB Gama, Engenharia Eletrônica, 2021)

Trabalho de graduação em engenharia eletrônica

Universidade de Brasília, Campus Gama – FGA/UnB

- |                             |         |
|-----------------------------|---------|
| 1. Processamento de sinais. | 2. EEG. |
| 3. Esforço Cognitivo.       | 4. SVM. |
| 5. RF.                      |         |



## **Identificação de esforço cognitivo através de processamento de sinais de EEG utilizando SVM e RF**

**Lucas Rocha Figueredo Santana e Barros**

Monografia submetida como requisito parcial para obtenção do Título de Bacharel em Engenharia Eletrônica da Faculdade UnB Gama - FGA, da Universidade de Brasília, em 05/11/2021 apresentada e aprovada pela banca examinadora abaixo assinada:

---

**Dr. Gerardo Antonio Idrobo Pizo, UnB/ FGA**

Orientador

---

**Dr. Renato Coral Sampaio, UnB/ FGA**

Membro Convidado 1

---

**Dr. Jones Yudi Mori Alves da Silva, UnB/ FGA**

Membro Convidado 2

Brasília, DF

2021

Dedico este trabalho à minha família  
que é tudo pra mim, que é a minha base.

## AGRADECIMENTOS

Agradeço especialmente aos meus pais por sempre estarem ao meu lado e me ajudado das mais diversas formas, sem eles eu não seria nada. Aos professores por trilharem meu caminho nessa jornada. Aos meus amigos da graminha por terem feito presença em diversos momentos, tanto em momentos de descontração, quanto de ajuda acadêmica. À minha namorada e companheira Amanda por ter feito a diferença nesse momento da minha vida, já não me imagino sem ela.

## RESUMO

A atenção é altamente desejável em diversas situações e até vital em outras. No dia a dia é imprescindível que o sujeito esteja plenamente atento para que tenha o melhor rendimento possível na atividade que está fazendo. Para tanto, esse trabalho objetiva fazer uma detecção de esforço cognitivo utilizando processamento de sinais de eletroencefalografia (EEG) e por meio de dois algoritmos de aprendizagem de máquina: Máquinas de Vetores de Suporte (SVM) e Floresta Aleatória (RF). A proposta deste trabalho é usar como base um banco de dados de sinais de EEG em que os candidatos passaram parte do tempo de aquisição em descanso com olhos fechados e outra parte realizando contas aritméticas. Para realizar a detecção, foi feita a extração da energia, e segmentação no domínio da frequência dos sinais adquiridos para ser feito uso como parâmetros de entrada nos algoritmos de aprendizagem de máquina citados. Neste trabalho, um objetivo foi comparar acurácia e precisão dessas duas técnicas, e foi adquirida uma acurácia de 90% e 97% para os classificadores de SVM e RF, respectivamente; e uma precisão para a categoria de esforço cognitivo de 81% e 94% para esses dois classificadores, respectivamente. O outro objetivo deste estudo foi averiguar se há regiões encefálicas com maior ativação durante o esforço cognitivo em comparação ao estado de descanso, e foi constatada uma energia maior adquirida, para o espectro de ondas Theta, nos eletrodos das partes frontal polar, frontal e occipital se comparada à adquirida em outros eletrodos.

**Palavras-chave:** Processamento de sinais. EEG. Esforço Cognitivo. SVM. RF.

## ABSTRACT

Attention is highly desirable in uncountable situations and even vital in others. On daily basis it is essential that the subject is fully aware so that he has the best possible performance in the activity he is doing. To do so, this work goal is to make a cognitive effort detection using electroencephalographic signal processing and making use of two machine learning algorithms: Support Vector Machine (SVM) and Random Forest (RF). This paper base will be a EEG signals dataset, in which candidates passed a fraction of the acquisition time in rest with their eyes closed, and a fraction making mental arithmetic. To accomplish the detection, energy extraction, and segmentation in the frequency domain of the acquired signals were performed to be used as input parameters in the cited machine learning algorithms. In this work, one goal was to compare accuracy and precision of these two techniques, and it performed with an accuracy of 90% and 97% for SVM and RF classifiers, respectively; and a precision for the cognitive effort category of 81% and 94% for these two classifiers, respectively. The other goal of this study is to find out if there are encephalic regions with more activation during the cognitive effort if compared to the rest state, and it was found a bigger energy, for the Theta waves spectrum, acquired in the frontal polar, frontal and occipital region electrodes if compared to the acquired in other electrodes.

**Keywords:** Signal Processing. EEG. Cognitive Effort. SVM. RF.



# Lista de Figuras

Figura 1: Exemplo de potencial de ação.....	6
Figura 2: Representação dos sinais de EEG com exemplos de estados mentais.....	7
Figura 3: Representação do padrão 10/20.....	8
Figura 4: Representação de duas classes separadas por hiperplanos.....	11
Figura 5: Representação visual para que possa ser feita separação linear de classes.....	13
Figura 6: Agrupamento de classes conforme os parâmetros $C$ e $\gamma$ variam.....	15
Figura 7: Representação da estrutura de uma ANN.....	16
Figura 8: Representação da estrutura de uma ELM.....	16
Figura 9: Esquema do classificador Floresta Aleatória: Passo 1: .....	18
Figura 10: Esquema do classificador Floresta Aleatória: Passo 2: .....	19
Figura 11: Esquema do classificador Floresta Aleatória: Passo 3: .....	21
Figura 12: Representação da planilha de dados a serem utilizados: .....	25
Figura 13: Esquema geral do projeto de identificação de esforço cognitivo: .....	28
Figura 14: Esquema do primeiro algoritmo: .....	29
Figura 15: Esquema do segundo algoritmo: .....	30
Figura 16: Demonstração de parâmetros de eletrodos 5 bandas de frequência: .....	31
Figura 17: Comparativo da Energia média em $\text{Volt}^2.\text{Hz}$ de todos eletrodos do sistema 10-20 para espectro Theta: .....	34
Figura 18: Comparativo de Energia média em $\text{Volt}^2.\text{Hz}$ para o eletrodo FP1: ...	35
Figura 19 Comparativo de Energia média em $\text{Volt}^2.\text{Hz}$ para o eletrodo FP2: ....	35
Figura 20: Comparativo de Energia média em $\text{Volt}^2.\text{Hz}$ para o eletrodo F7: .....	35
Figura 21: Comparativo de Energia média em $\text{Volt}^2.\text{Hz}$ para o eletrodo F8: .....	36
Figura 22: Comparativo de Energia média em $\text{Volt}^2.\text{Hz}$ para o eletrodo F9: .....	36

## Lista de Tabelas

Tabela 1: Trabalhos que utilizaram extração de características em frequência e técnicas de aprendizagem de máquina para identificar esforço cognitivo: .....	2
Tabela 2: Exemplo de estados mentais para cada espectro de sinal de EEG: .....	7
Tabela 3: Representação de Matriz de Confusão: .....	22
Tabela 4: Eficiência dos classificadores com o afinamento de Hiper parâmetros: .....	32

## Lista de Quadros

Quadro 1: Representação de uma estrutura de ELM: .....	17
Quadro 2: Hiper Parâmetros utilizados nos dois modelos: .....	32
Quadro 3: Hiper Parâmetros selecionados nos dois modelos: .....	32

# Lista de símbolos, nomenclaturas e abreviações

## **ABREVIACÕES:**

ANN	Redes Neurais Artificial
DFT	Transformada Discreta de Fourier
DWT	Transformada Discreta de Wavelets
EEG	Eletroencefalografia
ELM	Aprendizado Extremo de Máquina
FFT	Transformada Rápida de Fourier
HHT	Transformada de Hilbert-Huang
RF	Floresta Aleatória
SVM	Máquina de Vetores de Suporte
TDAH	Transtorno de Atenção e Hiperatividade

## NOMENCLATURAS:

Alpha ( $\alpha$ )	Espectro de frequência entre 7,5 Hz e 14 Hz
Beta ( $\beta$ )	Espectro de frequência entre 14 Hz e 30 Hz
Delta ( $\delta$ )	Espectro de frequência entre 0,5 Hz e 4 Hz
Gamma ( $\gamma$ )	Espectro de frequência entre 30 Hz e 60 Hz
Theta ( $\theta$ )	Espectro de frequência entre 4 Hz e 7,5 Hz
FP1, FP2, FP3, FP4	Eletrodos Frontais Polar de 1 a 4, respectivamente
F3, F4, F7, F8	Eletrodos Frontais 3, 4, 7 e 8, respectivamente
C3, C4, CZ	Eletrodos Centrais 3, 4, e Z, respectivamente
C3, C4, PZ	Eletrodos Parietais 3, 4, e Z, respectivamente
O1, O2	Eletrodos Occipitais 1 e 2, respectivamente
T3, T4, T5, T6	Eletrodos Temporais 3, 4, 5 e 6, respectivamente
A1, A2	Eletrodos de Referência 1 e 2, respectivamente
CSV	Formato de arquivo típico de planilha de valores separados por vírgula
EDF	Formato de arquivo de dados do tipo europeu
Python	Linguagem de programação interpretada
MNE	Biblioteca em Python para manipulação de arquivos
Numpy	Biblioteca em Python para manipulação de dados
Pandas	Biblioteca em Python para manipulação e visualização de dados
Scipy	Biblioteca para manipulação de dados e de operações matemáticas
Sklearn	Biblioteca utilizada para treinamento de modelos de aprendizagem de máquina
ensemble	Nome dado tanto ao tipo de algoritmo de aprendizagem de máquina quanto à biblioteca usada para implementar tais algoritmos

## SÍMBOLOS:

### Tópico 2.3 (pp. 9)

$X_k$	Coeficientes decompostos em domínio de transformação
$x$	Sinal no domínio original ou dados de entrada
$\varphi_k$	Função de base ortonormal de índice $k$
$\hat{x}[k]$	Coeficientes no domínio discreto da frequência
$x[n]$	Sinal no domínio do tempo discreto
$k$	Índices do domínio de transformação
$E$	Energia da banda de um sinal

### Tópico 2.4.2 (pp. 11)

$w$	Direção do plano para o SVM
$b$	Constante que determina a posição do plano para o SVM
$x_i$	Variáveis do exemplo de treinamento $i$ ou o $i$ -ésimo vetor de suporte para o SVM
$y_i$	Classificação desses exemplos de treinamento $i$ para o SVM
$m$	Margem do hiperplano do SVM
$\mathcal{L}$	Função de Lagrange
$h$	Função de Hipótese para o SVM
$\alpha_i$	Multiplicadores de Lagrange para o vetor de suporte $i$
$\varepsilon_i$	Distância entre o vetor de suporte e a amostra $i$
$C$	Critério de penalidade para o afastamento entre uma amostra fora do enquadramento
$\varphi(x)$	Transformação dos exemplos de treinamento $x$ para um domínio não linearmente separável no modelo de SVM
$K$	Kernel do modelo SVM

### Tópico 2.4.3 (pp. 15)

$X_i$	Dados do exemplo de treinamento $i$ que servem como parâmetro para o modelo de ELM
-------	--

$j$	Nós da camada de entrada
$n$	Nós da camada escondida
$m$	Nós da camada de saída
$N$	Número para distinguir parâmetros
$a_i$	Pesos que conectam os dados de entrada $i$ com a camada escondida
$b_j$	Bias do nó $j$ da camada escondida
$V_j$	Pesos que conectam o nó $j$ da camada escondida com a camada de saída
$Y_i$	Saída da camada de saída
$h$	Saída da camada escondida
$g$	Função de ativação de Sigmoid
$H$	Pseudo inversa de Moore-Penrose

#### **Tópico 2.4.4 (pp. 18)**

GI	Ganho de Informação
$Y_i$	Classe do $i$ -ésimo exemplo de treinamento
E	Entropia
$p_i$	Proporção ou probabilidade de uma amostra da classe $i$
G	Índice Giny

#### **Tópico 2.5 (pp. 21)**

VP	Verdadeiro Positivo
VN	Verdadeiro Negativo
FP	Falso Positivo
FN	Falso Negativo
A	Acurácia
P	Precisão

# SUMÁRIO

<b>1. INTRODUÇÃO.....</b>	<b>1</b>
1.1 Contextualização.....	1
1.2 Objetivos.....	3
1.2.1 Objetivo Geral.....	3
1.2.2 Objetivo Específico.....	3
1.3 Justificativa.....	3
1.4 Organização da dissertação.....	5
<b>2. FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>6</b>
2.1 Sinal Eletroencefalográfico .....	6
2.2 Identificação de Estado de Atenção.....	8
2.3 Transformada Rápida de Fourier .....	9
2.4 Técnicas de Classificação .....	10
2.4.1 Afinamento de Hiper Parâmetros .....	10
2.4.2 Máquina de Vetores de Suporte (SVM) .....	11
2.4.3 Extremo Aprendizado de Máquina (ELM).....	15
2.4.4 Floresta Aleatória (RF).....	18
2.5 Eficiência dos Classificadores.....	21
2.6 Considerações Finais .....	21
<b>3. METODOLOGIA .....</b>	<b>24</b>
3.1 Banco de Dados .....	24
3.2 Processamento de sinais.....	26
3.3 Classificação.....	26
3.4 Considerações finais .....	27
<b>4. RESULTADOS .....</b>	<b>29</b>
<b>5. CONCLUSÃO .....</b>	<b>39</b>
<b>6. HIPÓTESE E TRABALHOS FUTUROS .....</b>	<b>40</b>
<b>7. REFERÊNCIAS.....</b>	<b>41</b>



# Introdução

## 1.1. Contextualização

A Carga cognitiva é compreendida como a composição de vários fatores que estão relacionados com o desempenho mental em uma atividade sendo convertido em aprendizado. Esse conceito reflete a proporção do aprendizado como consequência da tarefa em questão, podendo ser observada carga mental, esforço mental e eficiência. Existe uma relação entre atenção e esses parâmetros, de forma que se diminuída, os influencia negativamente (Paas, 2003). Durante as atividades acadêmicas a atenção é consideravelmente requisitada. A performance durante uma aula está diretamente relacionada com o nível de atenção (Zhang et al., 2021).

É importante reforçar como os transtornos de atenção estão presentes no cotidiano. Se usado, como exemplo, o Transtorno de Atenção e Hiperatividade (TDAH), estatísticas (Fayyad, 2017) mostram que, se considerado como uma adversidade infantil, TDAH é reconhecido por persistir em 50-65% em indivíduos adultos. Em média, 2,2% da população mundial prevalece com esse transtorno.

É possível aferir o estado mental de um indivíduo por meio de sinais de Eletroencefalografia (EEG), que é um método normalmente feito de forma não invasiva, cujo objetivo é capturar e registrar a atividade cerebral por meio de eletrodos colocados no couro cabeludo. A atividade é registrada como mudanças no potencial elétrico na superfície da pele que surge da atividade cerebral dos neurônios (Sanei, 2007). Essa análise pode aferir comportamentos e analisar prognóstico de estados neuropsiquiátricos. O sinal de EEG reflete a atividade eletrofisiológica do cérebro em um intervalo de tempo, ajudando a entender uma patologia escondida (Peng et al., 2020).

Existem diversas aplicações a partir de sinais de EEG como por exemplo sistema para detectar convulsões epiléticas (Abdelhameed e Bayoumi, 2019), classificação de estágios de sono (Acharya et al., 2005), diagnóstico de doença de Alzheimer (Adeli et al. 2008), detecção de alcoolismo (Acharya, 2012), diagnóstico de TDAH (Ahmadlou e Adeli, 2010; Ahmadloue Adeli, 2011; Loo e Barkley, 2005 e Fayyad, 2017), detecção e classificação de atenção (Aziz, 2017; Purnamasari e Junika, 2019; Peng et al., 2020; Aziz, 2017 e Bird et al., 2018 e Zhang et al., 2021).

Identificação de esforço cognitivo é a motivação deste trabalho, e ainda utilizando algoritmos de inteligência artificial, cujas aplicações conseguem uma satisfatória generalização. Existem diversos trabalhos que utilizaram tal metodologia para detecção de esforço cognitivo e utilizando segmentação em frequência de sinais de EEG, demonstrando resultados satisfatórios (Purnamasari e Junika, 2019; Peng et al., 2020; Aziz, 2017; Bird et al., 2018 e Edla, 2018). As transformadas utilizadas para extração de características em frequência e as técnicas de aprendizagem de máquina que esses autores utilizaram em seus trabalhos estão descritos na Tabela 1.

**Tabela 1:** Trabalhos que utilizaram extração de características em frequência e técnicas de aprendizagem de máquina para identificar esforço cognitivo.

<b>Referência bibliográfica</b>	<b>Transformada utilizada</b>	<b>Técnica de classificação</b>	<b>Acurácia</b>
Aziz, 2017	DFT	ELM	71,75%
	HHT	ELM	72,16%
Peng et al., 2020	DFT	SVM	75,87%
	HHT	ELM	72,10%
Purnamasari e Junika, 2019	DFT	SVM	72%
	DWT	SVM	90%
Edla, 2018	DFT	RF	75%
Bird et al., 2018	DFT	SVM	75,14%
	DFT	RF	87,16%

Conforme será visto no Tópico 4, este trabalho utilizou a DFT como transformada e fez uso de SVM e RF para identificar empenho mental e foi possível obter uma acurácia de 90% e 97% para os dois métodos, respectivamente, porém não é possível comparar diretamente os resultados deste trabalho com os obtidos nas referências da Tabela 1, pois o banco de dados utilizados foram todos distintos entre si. Ou seja, todas as condições impostas aos sujeitos de cada experimento são diferentes, como as características específicas

dos aparelhos de EEG e a forma de como foi realizado o experimento. Porém a metodologia dos experimentos utilizados como base no trabalho de (Edla, 2018) foi realizada se aproxima à forma como foi feita no experimento utilizada como base neste trabalho. Em ambas os sujeitos devem realizar operações aritméticas em um dado tempo e permanecer descansando de olhos fechados em um outro intervalo de tempo.

Além de apenas realizar a identificação de esforço cognitivo, este trabalho também visa fornecer detalhadamente informações para replicação de todo o projeto para identificação de empenho mental, com o intuito de simplificar a continuação desta aplicação para trabalhos futuros. Para tal, também será investigado se há regiões do cérebro com uma ativação maior que outras durante a atividade mental em questão que se deseja identificar. Saber de tal informação poderá servir de auxílio para um trabalho futuro cuja a aplicação é similar a este projeto.

## 1.2 Objetivos

### 1.2.1 Objetivo Geral

Realizar identificação de esforço cognitivo através de processamento de sinais eletroencefalográficos utilizando SVM e RF, comparando acurácia e precisão desses dois métodos. Além disso, verificar se há regiões encefálicas com maior estimulação que outras durante uma atividade de empenho mental se comparar uma aquisição durante descanso.

### 1.2.2 Objetivo Específico

- Pesquisar e escolher um banco de dados de EEG binário, em que se possa diferenciar as duas situações: esforço cognitivo e descanso;
- Desenvolvimento de um algoritmo de processamento de sinais, realizando extração de bandas de frequência para utilizar como parâmetro de dois classificadores;
- Utilizando as características em frequência, aplicar dois algoritmos de classificação supervisionada (SVM e RF) com o intuito de aferir se o candidato está durante estado de esforço cognitivo ou de descanso;
- Fornecer o passo a passo de todo o projeto aqui implementado para facilitar a replicação ou uso para trabalhos futuros;
- Comparar acurácia e precisão que os dois métodos obtiveram para identificar o esforço cognitivo;

- Identificar se houve eletrodos que capturaram maior energia que outros durante o estado de esforço cognitivo.

### 1.3 Justificativa

Um exemplo de ambiente em que o esforço cognitivo é altamente requisitado é no contexto educacional. Ocorrem na maioria do tempo situações em que se faz necessária a concentração, e seria útil saber se os estudantes estão tendo um desempenho satisfatório nesse sentido. Para isso se faz necessário, inicialmente, saber se há características de ativação elétrica que diferenciem um estado de empenho mental de um estado de relaxamento.

Feito isso, em um trabalho futuro, poderia ser estudada a possibilidade de desenvolvimento de um indicador de rendimento voltado ao esforço cognitivo de estudantes. Para contribuir com esse projeto póstero é útil saber se há regiões encefálicas mais ativas que outras durante a atuação de empenho cognitivo, e essa é, portanto, uma das justificativas deste trabalho.

Com relação à extração de características, a FFT tem sido comprovadamente um algoritmo que auxilia satisfatoriamente para identificação/classificação de atenção utilizando sinal de EEG de acordo com (Balasubramanian, 2014; Purnamasari e Junika, 2019; Peng et al., 2020; Aziz, 2017; Bird et al., 2018; Edla, 2018 e Zhang et al., 2021) em que a segmentação em bandas de frequência foi utilizada como parâmetros de entrada para classificadores.

No que se refere a efetivamente reconhecer um estado de esforço cognitivo, métodos de inteligência artificial foram satisfatoriamente utilizados, e tratando especificamente de SVM e RF, os dois métodos foram efetivamente impostos à aplicação em questão, e com a motivação a mais por terem baixa complexidade, podem ser colocados em aplicações de sistemas embarcados segundo (Edla, 2018 e Fraiwan, 2012).

O algoritmo de SVM é classicamente utilizado para tarefas de separação de duas classes, sendo muito bem aplicável a essa situação e tendo produzido bons resultados de acordo com (Purnamasari e Junika, 2019 e Peng et al., 2020). Outra característica favorável do SVM para o contexto é o fato de esse tipo de modelagem apresentar bons resultados para uma situação em que o dado de entrada possui relativamente uma baixa quantidade de exemplos se comparada ao número de parâmetros (Pinheiro, 2015).

Já RF é habitualmente utilizado em tarefas binárias também e produziu resultados satisfatórios para aplicações similares de acordo com (Bird et al., 2018 e Edla, 2018). Adicionalmente, por ser um classificador do tipo ensemble (mais detalhes sobre um classificador desse tipo serão mostrados no Tópico 2.4.3)

produz uma robustez maior e se aplica bem à uma situação que conta com poucos exemplos para treinamento, porém muitos parâmetros, exemplo que teria uma chance considerável de underfitting.

A justificativa deste trabalho é utilizar segmentação em frequência juntamente com classificadores SVM e RF para discernir empenho mental de estado de descanso, e comparar a eficiência desses dois algoritmos. Essas duas técnicas juntamente com análise no domínio da frequência obtiveram resultados satisfatórios para a aplicação de identificação de esforço cognitivo, conforme mostrado no Tópico 1.1. Além disso, é desejado verificar se há regiões encefálicas onde há maior estimulação durante a atividade cognitiva, visto que, nessa hipótese, os eletrodos postos nessas regiões iriam captar uma energia maior se comparada a adquirida em eletrodos de outras regiões, conforme será melhor contextualizado no Tópico 2.2.

## 1.4 Organização da dissertação

Os capítulos deste trabalho estão organizados da seguinte forma:

**Capítulo 2:** Neste capítulo são introduzidos os aspectos iniciais do problema de identificação de esforço cognitivo baseado em sinais de EEG. Primeiramente são fundamentadas as características de um sinal de EEG e sua relação com o estado de esforço cognitivo. Posteriormente são apresentadas as ferramentas utilizadas para a solução, que são a extração de características em frequência e posteriormente o uso de tais elementos como entrada de dois algoritmos de aprendizagem de máquina: Máquina de Vetores de Suporte e Floresta Aleatória.

**Capítulo 3:** Neste capítulo é abordado como exatamente será o projeto de identificação de esforço cognitivo. Será mostrado o banco de dados a ser utilizado, posteriormente como lidar com as características do sinal de EEG no domínio da frequência e por fim quais ferramentas serão utilizadas para poder dispor de classificadores de Máquina de Vetores de Suporte e Floresta Aleatória.

**Capítulo 4:** Neste capítulo é abordado com mais detalhes como foi a implementação do projeto de identificação de esforço cognitivo através de sinal de EEG. Será feita a demonstração por meio de esquemas do fluxo dos algoritmos e dos resultados alcançados com tal implementação, tanto em relação a eficiência dos classificadores de aprendizagem de máquina, quanto de apresentação visual do comportamento da energia das bandas para cada eletrodo a fim de verificar padrões que possam diferenciar o estado de esforço cognitivo do estado de descanso.

**Capítulo 5:** Conclusões

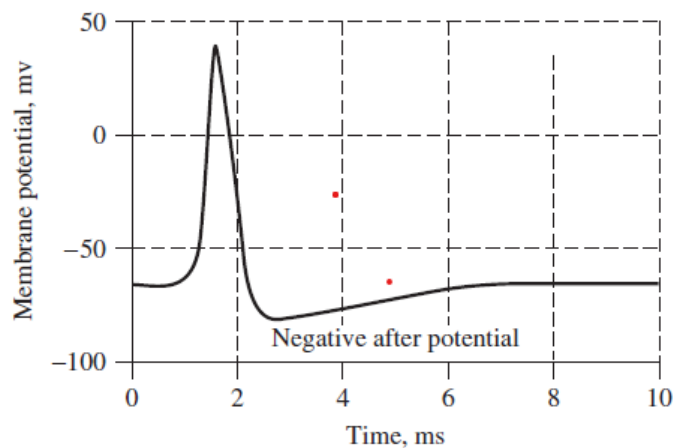
**Capítulo 6:** Referências Bibliográficas

## 2. Fundamentação Teórica

### 2.1. Sinal Eletroencefalógrafo

Os sinais de EEG são a representação da atividade neural. Sua aquisição é feita por múltiplos eletrodos, normalmente de forma não invasiva, colocados sob o couro cabeludo.

As atividades no Sistema Nervoso Central estão principalmente relacionadas às correntes sinápticas transferidas entre as junções de axônios e dendritos. Um potencial de polaridade negativa com valor em torno de 60 mV é encontrado sob a membrana do corpo celular neural. Esse potencial muda com variações na atividade sináptica (Sanei, 2007).



**Figura 1:** Exemplo de potencial de ação (Sanei, 2007).


Um sinal de EEG é uma medida de correntes que fluem durante as excitações sinápticas dos dendritos de muitos neurônios piramidais no córtex cerebral. Quando as células cerebrais (neurônios) são ativadas, as correntes sinápticas são produzidas dentro dos dendritos. Esta corrente gera um campo elétrico sobre o couro cabeludo mensurável por sistemas EEG (Attwood e MacKay, 1989).

A atividade elétrica cerebral se manifesta de maneira rítmica relativamente padronizada de cinco principais formas: alpha ( $\alpha$ ), theta ( $\theta$ ), beta ( $\beta$ ), delta ( $\delta$ ), e gamma ( $\gamma$ ). Ainda existem autores como (Purnamasari e Junika, 2019) que fazem uma segmentação um pouco diferente, dividindo o intervalo beta em baixo (14-20 Hz) e alto (20-30 Hz) e caracterizando como estados mentais distintos para os dois intervalos. Portanto, segmentar o espectro de mais de uma forma é uma estratégia para investigar aspectos do sinal e podendo ser usada

para gerar diferentes características como entrada aos algoritmos de classificação. Uma representação típica pode ser observada na Tabela 2:

**Tabela 2:** Exemplo de estados mentais para cada espectro de sinal de EEG

Onda	Intervalo típico	Estado
delta ( $\delta$ )	0,5 – 4 Hz	Sono profundo
theta ( $\theta$ )	4 – 7,5 Hz	Sonolência
alpha ( $\alpha$ )	7,5 – 14 Hz	Relaxamento, consciência
beta ( $\beta$ )	14 – 30 Hz	Atenção ativa, foco no mundo externo
gama ( $\gamma$ )	30 – 60 Hz	Alto processamento cognitivo




**Figura 2:** Representação dos sinais de EEG com exemplos de estados mentais. Fonte: <http://aumagic.blogspot.com/2018/11/ondas-cerebrais-gama-ciencia-das.html>

Existe uma indicação feita para o posicionamento dos eletrodos pela Federação Internacional de Sociedades de Eletroencefalografia e Neurofisiologia Clínica. O nome dessa convenção é denominado de Sistema 10-20, que recebeu



essa nomenclatura devido à medida de distância ser posicionada entre 10 e 20% do tamanho disponível do couro cabeludo. Normalmente os eletrodos A1 e A2 são conectados próximos, respectivamente, à orelha esquerda e à direita. Os eletrodos restantes são frontal-polar (Fp1, Fp2), frontal (F3, F4, Fz, F7, F8), central (C3, C4, Cz) parietal (P3, P4, Pz), occipital (O1, O2) e temporal (T3, T4, T5, T6). Um exemplo de posicionamento pode ser observado na Figura 3.



**Figura 3:** Representação do padrão 10/20 (Sanei, 2007).

## 2.2. Identificação de Esforço Cognitivo

Em indivíduos saudáveis e adultos, o sinal de EEG apresenta uma diferenciação, no que se refere à amplitude e frequência, quando por exemplo estão acordados ou dormindo. Ondas Alfa podem ser associadas a estado de relaxamento e vigília, porém sem atenção ou concentração. Por outro lado, ondas Beta têm sido relacionadas a pensamento ativo, como foco no mundo externo e resolução de problemas concretos (Purnamasari e Junika, 2019).

Também as ondas Theta podem ser relacionadas ao estado de relaxamento, e ainda que o estado de vigília tende a ter uma maior amplitude característica em frequências altas (como Beta e Gama, que são relacionadas à alta atividade cognitiva) se comparado ao estado de relaxamento (Sanei, 2007; Aziz, 2017). Portanto é possível que utilizando amplitude e bandas frequência do sinal de EEG o estado de atenção seja indetectável.

Em contrapartida, segundo (Rodriguez-Larios, J., et al., 2020 e Winnie, 2017), uma amplitude de sinal de EEG maior no espectro de ondas Theta foi adquirida em eletrodos da parte frontal da cabeça quando sujeitos executavam atividades que exigiam esforço cognitivo, se comparada à amplitude adquirida em outras regiões quando a situação exigia menos esforço.

Além disso, no trabalho de (Katahira, K., et al., 2018) foi encontrada uma maior atividade elétrica nos eletrodos da parte frontal, no espectro de ondas Theta para quando os sujeitos estavam realizando operações aritméticas.

## 2.3. Transformada Rápida de Fourier

Existe um conceito denominado projeção, que significa representar um sinal matemático em função de outros sinais, chamados sinais base. A Transformada de Fourier expressa uma função em relação a funções base senoidais, e com isso o sinal original é decomposto para ser representado no domínio da frequência. Portanto, agora serão evidenciadas características em frequência dessa expressão (Vetterli M., et al., 2014).

A decomposição em funções ou vetores bases ortonormais pode ser descrita como na Equação (1):

$$X_k = \langle x, \varphi_k \rangle, \quad k \in \mathbb{Z}, \quad (1)$$

onde  $X_k$  são os coeficientes decompostos de índice  $k$  pela projeção do sinal original  $x$  sobre os vetores (ou funções) base  $\varphi_k$ . O sinal original pode ser reconstruído como mostrado na Equação (2):

$$x = \sum_{k \in \mathbb{Z}} X_k \varphi_k. \quad (2)$$

A Transformada de Fourier é a projeção do sinal original sobre funções de base exponenciais complexas. Como a projeção é feita sobre uma função imaginária, o produto interno é feito pelo conjugado da função base. Da relação de Euler a exponencial complexa pode ser escrita como uma senóide complexa. Daí portanto fica explícito que a Transformada de Fourier projeta o sinal sobre funções base senoidais e, portanto, projetando-o para o domínio da frequência.

No caso de a Transformada ser discreta, e o domínio original também, dá-se o nome de Transformada Discreta de Fourier (DFT) e pode ser definida como no caso, por exemplo, de um sinal de tempo discreto  $x[n]$  tendo como resultado os coeficientes na frequência discreta  $\hat{x}[k]$  como mostrado na Equação (3)

$$\hat{x}[k] = \sum_{n=0}^{N-1} x[n] e^{-j2\pi \frac{k}{N} n}, \quad (3)$$

onde  $N$  é o tamanho total da amostra no tempo discreto.

Existe uma família de algoritmos para o cálculo eficiente da DFT, e essa implementação recebe o nome de Transformada Rápida de Fourier (FFT). Algumas técnicas para esse cálculo eficiente são a dizimação no tempo e a dizimação na frequência.

Vale ressaltar que existem também diversas transformadas, cada qual com diferentes ênfases. Algumas evidenciam propriedades frequência-temporais, como a Transformada de Hilbert-Huang (HHT) e Transformadas de Wavelets, como a Transformada Discreta de Wavelets (DWT). A primeira é útil para aplicações cujo sinal tem características não lineares, por exemplo. A segunda é utilizada, por exemplo, para compressão de dados.

Outro aspecto útil para este trabalho é Energia. Para calcular a energia ( $E$ ) em uma banda de um sinal a seguinte relação é utilizada conforme mostra a Equação (4):

$$E = \sum_N |\hat{x}[k]|^2, \quad (4)$$

onde  $N$  é o tamanho discreto da banda.

## 2.4 Técnicas de Classificação

O objetivo central do contexto de aprendizagem de máquina se apoia no sentido de enquadrar dados a uma determinada classe. Se essa divisão de grupos for previamente bem definida, o algoritmo de classificador é definido como supervisionado. É notório que essa linha se encaixa no contexto descrito, visto que o dado usado como base é do tipo rotulado.

No caso do sinal do EEG, a subdivisão em bandas de frequências vinculadas a sua energia é a característica central para possibilidade de classificação do estado mental de um indivíduo. Portanto o processamento é essencial para a extração de características que podem levar o classificador a ter um desempenho desejado.

Diferentes amplitudes de ondas Theta, Alfa, Beta e Gama podem ser relacionadas como indicadores de um estado mental de esforço cognitivo, segundo (Sanei, 2007; Aziz, 2017; Purnamasari e Junika, 2019). Existe a tendência a crer, portanto, que o problema se encaixa bem ao paradigma de aprendizagem de máquina.

### 2.4.1 Afinamento de hiperparâmetros

Segundo (Yang e Shami, 2020), existem dois tipos de parâmetros para modelos de aprendizagem de máquina: os que são aprendidos e atualizados durante o treinamento e os que são estimados e definidos antes do treinamento. De acordo com (Schratz, 2019), hiperparâmetros de configuração padrão provavelmente não asseguram um ótimo modelo de aprendizagem de máquina.

Aos tipos de parâmetros que são definidos antes do treinamento dá-se o nome de Hiper Parâmetros. A exemplo prático para este trabalho, o critério de penalidade C e o tipo de Kernel em um modelo de Máquina de Vetores de Suporte são Hiper Parâmetros que serão explorados e utilizados. E para fins de detalhamento, melhor analisados no Tópico 2.4.2. Para o modelo de Floresta Aleatória, exemplos que serão explorados são o método de seleção de amostra e número de dimensões a considerar, que serão melhor detalhados no Tópico 2.4.4.


## 2.4.2 Máquina de Vetores de Suporte (SVM)

O classificador Máquina de Vetores de Suporte (SVM em inglês) é um algoritmo de caráter supervisionado que objetiva diferenciar duas classes, podendo ser um ótimo classificador caso os tipos possam ser muito bem separáveis. O princípio do SVM é treinar um hiperplano que consiga fazer essa divisão, sendo que os três planos têm a mesma inclinação, e quanto maior a distância entre eles, maior a robustez do sistema (Balasubramanian, 2014).

A divisão por hiperplano é tal que satisfaça a Equação (5):

$$\langle w, x \rangle + b = 0, \quad (5)$$

onde  $\langle w, x \rangle$  é um produto interno, sendo  $w$  a direção do plano e  $b$  é uma constante que determina a posição.



**Figura 4:** Representação de duas classes (verde e azul) separadas por hiperplanos. Na imagem,  $x_1$  e  $x_2$  são exemplos de características. Fonte: [https://en.wikipedia.org/wiki/Support-vector\\_machine](https://en.wikipedia.org/wiki/Support-vector_machine)

Na Figura 4, a linha mais forte representa a maior margem que separa as duas classes. Os outros planos cuja distância deve ser maximizada possuem as seguintes Equações (6) e (7) :

$$\langle w, x \rangle + b = 1, \quad (6)$$

e

$$\langle w, x \rangle + b = -1. \quad (7)$$

Feita essa otimização, o objetivo do algoritmo é encontrar os vetores paralelos ao hiperplano central, os hiperplanos mais externos, conhecidos como Vetores de Suporte. Conhecendo-os, torna-se possível fazer a separação de classes.

A equação do hiperplano pode ser generalizada na forma da Equação (8):

$$y_i(w^T \cdot x_i + b) \geq 1, \quad (8)$$

onde  $x_i$  são as variáveis dos exemplos de treinamento e  $y_i$  a classificação desses exemplos.

E utilizando as Equações (2) e (3) é possível chegar na relação entre margem ( $m$ ) e o vetor  $w$  conforme mostra a Equação (9):

$$m = \frac{2}{\|w\|}. \quad (9)$$

A tarefa se torna agora maximizar essa margem ou também pode ser considerado minimizar  $\frac{1}{2}w^T w$ . Isso se torna extremamente caro computacionalmente conforme aumenta a dimensão dos dados de entrada. Porém, felizmente, encontrar essa minimização com respeito a sujeição da Equação (4) pode ser feita aplicando a solução com função de Lagrange conforme mostra a Equação (10):

$$\mathcal{L}(\omega, b, \alpha) = \frac{1}{2}w^T w - \sum_{i=1}^n \alpha_i (y_i(w x_i + b) - 1), \quad (10)$$

sendo  $i$  um identificador para vetores de suporte e  $a_i$  os multiplicadores de Lagrange para o vetor de suporte  $i$ . Agora, então, a tarefa passa a ser minimizar essa função de Lagrange descrita, para o nosso problema, pela Equação (6). Com isso serão geradas as Equações (11) e (12):

$$\frac{\partial \mathcal{L}}{\partial w} = w - \sum_{i=1}^n y_i \alpha_i x_i = 0, \quad (11)$$

$$\frac{\partial \mathcal{L}}{\partial b} = \sum_{i=1}^n y_i \alpha_i = 0. \quad (12)$$

E com isso a função de hipótese ficará em função dos multiplicadores de Lagrange e do produto interno entre os vetores de suporte e um ponto de teste  $x$ , da forma da Equação (13):

$$h = \sum_{i=1}^n a_i y_i x_i \cdot x + b. \quad (13)$$

É possível substituir as Equações (6) e (7) para obter os multiplicadores  $a_i$  sem depender de  $w$  conforme mostra a Equação (14):

$$\mathcal{L} = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{j=1}^n \sum_{i=1}^n \alpha_i \alpha_j y_i y_j x_i x_j. \quad (14)$$

Essa foi a resolução para margens rígidas, ou seja, todos os pontos ficam perfeitamente incluídos nas classes. Porém na prática é provável que amostras não se enquadrem na parte espacial que deveriam. Para isso deve ser incluída uma forma matemática para esses pontos fora do esperado. Essa denominação se chama Margens Suaves. Será inserido agora um critério de penalidade  $C$ . Essa constante é classificada como um Hiper Parâmetro. Agora o problema de minimização será conforme a Equação (15):

$$\min \left[ \frac{1}{2} \omega^T w + C \sum_{i=1}^n \varepsilon_i \right], \quad (15)$$

sujeito a Equação (16):

$$(\langle w, x_i \rangle + b) y_i \geq 1 - \varepsilon_i, \quad \varepsilon_i \geq 0, \quad (16)$$


sendo  $\varepsilon_i$  as distâncias entre o vetor de suporte e a amostra fora do enquadramento.

A função de Lagrange considerando essa modelagem agora fica de acordo com a Equação (17):

$$\mathcal{L} = \frac{1}{2} \omega^T w + c \sum_{i=1}^n \varepsilon_i + \sum_{i=1}^n \alpha_i [1 - \varepsilon_i - y_i (w x_i + b)]. \quad (17)$$

Quando o problema não for linearmente separável é feita uma transformação do domínio para  $\varphi(x)$ . A ideia é mapear os dados para um domínio em que seja possível fazer uma separação linear das classes, conforme é mostrado na Figura 5. Corriqueiramente essa transformação será feita para um domínio de dimensão maior que o original. A função de hipótese ficaria de acordo com a Equação (18):

$$h = \sum_{i=1}^n \alpha_i y_i \varphi(x_i) \cdot \varphi(x) + b. \quad (18)$$



**Figura 5:** Representação visual de uma mudança de domínio para que possa ser feita a separação linear de classes. Fonte: <https://www.valpolinux.cl/o-que-sao-maquinas-de-vetores-de-suporte-svm/>

Mas existem formas de fazer um mapeamento generalizado, de forma que não precisa mais ser feito especificamente para um problema. A isso se dá o nome de Kernel, também conhecido como Produto Interno Generalizado. E uma outra importante vantagem dessa abordagem é que, ao utilizá-la, não é necessário mais transformar os vetores de suporte para o domínio desejado. O Kernel também substitui o produto interno da operação. Acerca disso ocorre a diminuição a complexidade do problema de forma importante.

Um Kernel interessante de ser utilizado é um denominado Função de Base Radial Gaussiano (Gaussian RBF). Para demonstrar sua função de transformação é feita a expansão por Série de Taylor como mostrado na Equação (19):

$$\varphi(x) = e^{-\gamma x^2} \left[ 1, \sqrt{\frac{2\gamma}{1!}} x, \sqrt{\frac{(2\gamma)^2}{2!}} x^2, \dots, \sqrt{\frac{(2\gamma)^n}{n!}} x^n \right], \quad (19)$$

ou também pode ser escrito da forma da Equação (20):

$$\varphi(x) = e^{-\gamma x^2} \sum_{i=0}^{\infty} \sqrt{\frac{(2\gamma)^i}{i!}} x^i. \quad (20)$$

O parâmetro  $\gamma$  define a influência de uma amostra sobre a modelagem. Um  $\gamma$  alto resulta numa alta adequação do modelo aos exemplos, e um  $\gamma$  baixo caracteriza uma rigidez menor em relação às amostras. Também pode ser traduzido como a área de influência radial que uma amostra possui para a modelagem.

E o Kernel expandido é da seguinte maneira resultando na Equação (21):

$$K(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2} = e^{-\gamma(x_i - x_j)^2}$$

$$K(x_i, x_j) = e^{-\gamma x_i^2 - \gamma x_j^2} \cdot \sum_{i=0}^{\infty} \sqrt{\frac{(2\gamma)^i}{i!}} x_i^i \sqrt{\frac{(2\gamma)^i}{i!}} x_j^i$$

$$K(x_i, x_j) = \varphi(x_i)^T \cdot \varphi(x_j). \quad (21)$$

Por fim, a função de hipótese agora levando em consideração o kernel fica conforme a Equação (22):

$$h = \sum_{i=0}^n \alpha_i y_i K(x_i, x_j). \quad (22)$$

A título de visualização, a Figura 6 mostra como fica o agrupamento de amostras ao variar os Hiper Parâmetros.

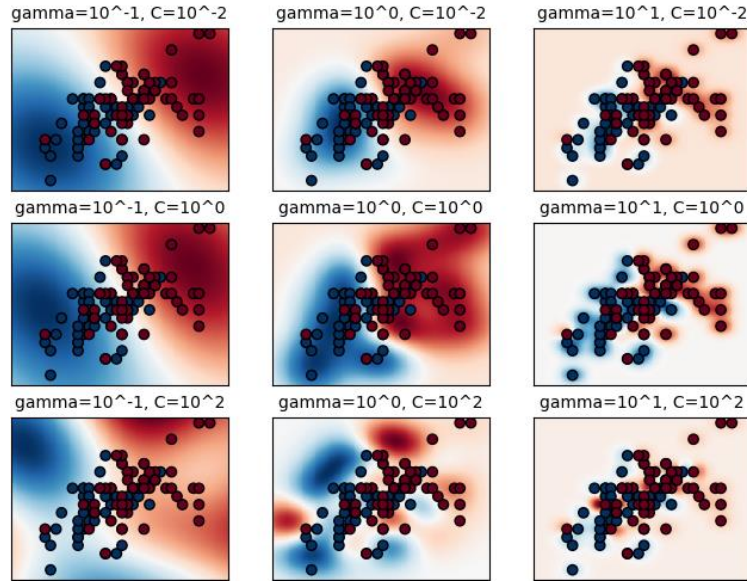


Figura 6: Agrupamento de classes conforme os Hiper Parâmetros C e  $\gamma$  variam

### 2.4.3 Extremo Aprendizado de Máquina (ELM)


Algoritmos de Redes Neurais são algoritmos consagrados para classificação e regressão. A sua capacidade de aprendizagem e generalização a um cenário desejado é o que justifica o seu uso para aplicações. Porém para uma robustez satisfatória é necessário que não haja poucas amostras de entrada: se for relativamente pequeno o número de exemplos, a capacidade de generalização da rede será rasa (Mehrotra K. G., et al., 1990).

Não levando necessariamente em conta os aspectos brevemente citados, a ELM, um tipo de rede neural, obteve resultados satisfatórios para aplicação de identificação de concentração baseado em sinal de EEG, segundo (Aziz, 2017). Ou seja, embora não venha a ser utilizado na aplicação deste trabalho por conta da menor probabilidade de êxito devido ao número reduzido de amostras, vale a pena explicar brevemente sobre a implementação deste algoritmo.

A motivação para uso de ELM ao invés de uma rede neural como Rede Perceptron Multicamadas (exemplificada na Figura 7), por exemplo, é devido

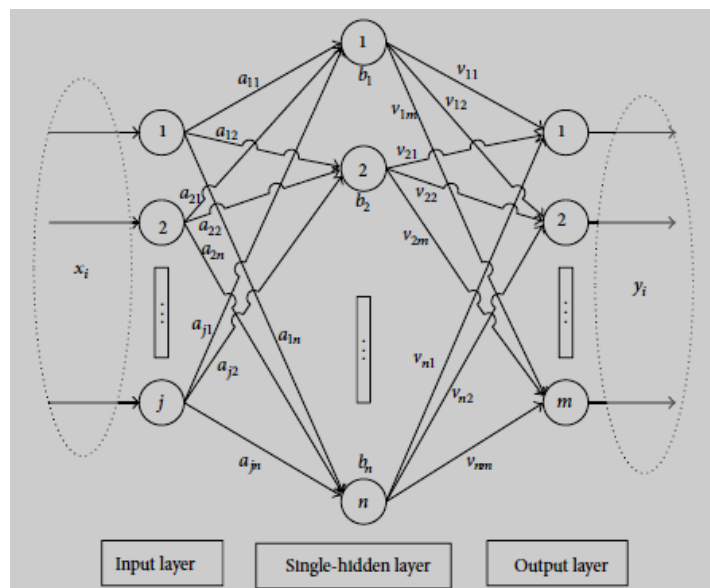


principalmente a: complexidade algorítmica menor, levando a um menor tempo de computação para o treinamento; performance melhor em determinados caso por não enfrentar problemas como taxa de aprendizado exagerada ou muito pequena, improbabilidade de overfitting e conclusão de algoritmo em mínimo local (Huang e Siew, 2006).



**Figura 7:** Representação de uma estrutura da Rede Perceptron Multicamadas, com  $n$  entradas na camada de entrada ( $i$ ),  $n$  camadas escondidas ( $h$ ) e  $n$  saídas na camada de saída ( $o$ )

ELM é um algoritmo de rede neural do tipo feedforward, tipicamente utilizado para tarefas de regressão e classificação segundo (Huang, 2006). No caso de ela possuir apenas uma camada escondida, o esquema típico de uma rede ELM pode ser visualizada na Figura 8.



**Figura 8:** Representação de uma estrutura de ELM. Fonte: <https://towardsdatascience.com/introduction-to-extreme-learning-machines-c020020ff82b>

Baseado nas nomenclaturas da Figura 8, o modelo ELM consiste em:

**Quadro 1:** Representação de uma estrutura de ELM

Componentes	Descrição
$X_i$	Dados de entrada que servem como parâmetro para o modelo
$j$	Nós da camada de entrada,
$n$	Nós da camada escondida
$m$	Nós da camada de saída
$N$	Número para distinguir parâmetros
$a_i = [a_{i1}, a_{i2}, \dots, a_{in}]^T$	Pesos que conectam os dados de entrada $i$ com a camada escondida
$b_j$	Bias do nó $j$ da camada escondida
$V_j = [V_{j1}, V_{j2}, \dots, V_{jn}]^T$ ; $V = H^*Y$ (23)	Pesos que conectam o nó $j$ da camada escondida com a camada de saída
$Y_i$	Saída da camada de saída
$h = g(ax + b)$ (24)	Saída da camada escondida
$g(a,b,x) = \frac{1}{1 + \exp(-(ax+b))}$ (25)	Função de ativação de Sigmoid
$H^* = (H^T H)^{-1} H^T Y$ (26)	Pseudo inversa de Moore-Penrose

O algoritmo de ELM segue os três passos:

- Os pesos de entrada  $a_{ij}$  e os biases  $b_j$  são inicializados randomicamente com valores entre 0 e 1;

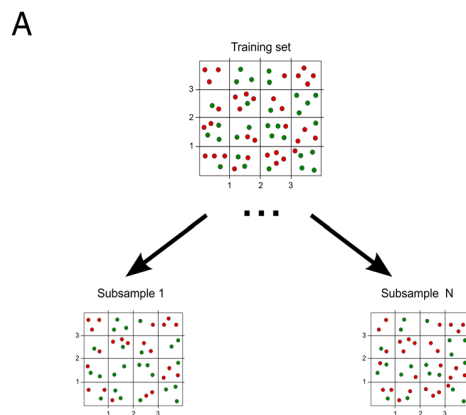
- Cálculo da saída da camada escondida H;
- Cálculo da saída da camada de saída V;

#### 2.4.4 Floresta Aleatória (RF)

O classificador RF é a implementação de várias árvores de decisão, por isso é nomeado como um algoritmo do tipo *ensemble*, que é uma combinação de classificadores. Essa junção fornece robustez podendo aumentar a eficácia do resultado (Fraiwan, 2012).

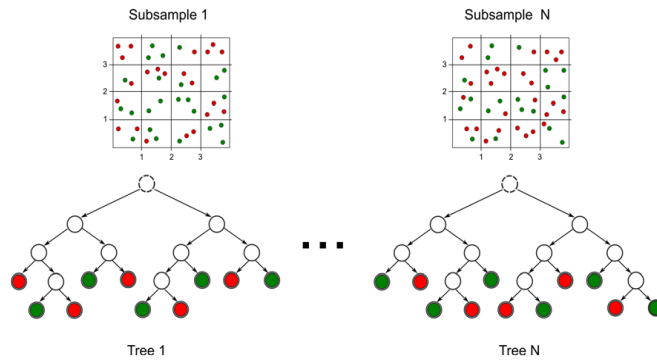
Cada árvore individual faz uma escolha randômica das características a serem utilizadas, sendo o número de escolhas menor que o número total de características. Toda árvore é uma classificação em si, sendo a escolha do nó inicial e dos nós subsequentes de cada árvore feita de maneira aleatória.

Conforme mostra a Figura 9, o primeiro passo é preparar o dado de treinamento para cada árvore por meio de um método chamado *bootstrap* ou *bagging* (*bootstrap aggregating*) em uma parte das amostras, qualificadas como in-bag. É um jeito de diminuir a variância gerando novos dados a partir dos originais usando combinações com repetições. As amostras que não fizeram parte dessa porção são chamadas de out-of-bag e serão utilizadas para verificar a performance da classificação da árvore.



**Figura 9:** Esquema do classificador Floresta Aleatória: **Passo 1** (Fraiwan, 2012).

No segundo passo será feita a seleção do atributo no nó do topo e separar os dados de treinamento em subconjuntos para cada valor do atributo (Figura 10 auxilia na visualização desse passo). O número de atributos a ser utilizado em cada árvore pode ser definido, mas selecionados aleatoriamente. E para ser feita a divisão nos nós existem duas métricas: Impureza Giny (ou Índice Giny - G) e Ganho de Informação (GI).



**Figura 10:** Esquema do classificador Random Forest: **Passo 2** (Fraivan, 2012).

Caso utilize a primeira métrica, o Índice Giny é aplicado a todo banco de dados. Posteriormente é aplicado às tentativas de divisão. Posteriormente é subtraído o Índice aplicado a todo banco de dados pelo aplicado às tentativas separadamente. A divisão que melhor separa as classes terá o valor maior.

Caso seja utilizada a segunda métrica, a melhor separação de classes se dará quanto maior (e mais positivo) for o Ganho de Informação.

O ganho de informação é calculado da seguinte forma:

$$GI = - \sum_i^n \frac{|Y_i|}{Y} E(Y_i). \quad (27)$$

Sendo  $E(Y_i)$  a Entropia do conjunto,  $n$  é o número de classes, que no caso deste trabalho será 2,  $p_i$  é a probabilidade ou proporção de ser selecionado uma amostra da classe  $i$ . A entropia pode ser calculada da seguinte forma:

$$E(Y_i) = - \sum_{i=1}^n p_i \log_2 p_i. \quad (28)$$

E o Índice Giny utiliza a seguinte métrica:

$$G = \sum_{i=1}^n p_i (1 - p_i). \quad (29)$$

Essas métricas revelam uma vantagem a esse método, pois ele dará destaque, a esse exemplo específico deste trabalho, a quais eletrodos e quais bandas tiveram maior magnitude para a classificação.

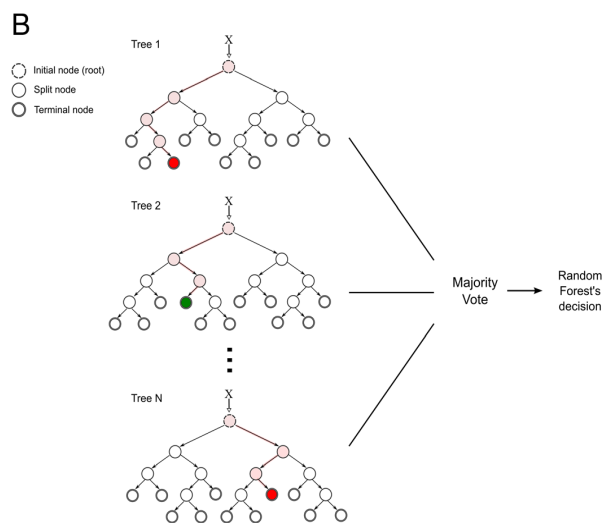
O processo é repetido recursivamente para os nós subsequentes para os atributos remanescentes. A seleção do próximo atributo é definida pelas métricas

citadas acima, e o processo posteriormente se repete para as próximas árvores. O número de vezes que o processo é repetido determina a altura da árvore, um fator indicador da complexidade do algoritmo.

O número de parâmetros por separações que será realizado durante o processo algorítmico é um parâmetro a ser introduzido e existem métricas para tal. Aumentando muito o número de separações acaba levando o classificador ao overfitting, por isso exemplos são: a raiz quadrada e o  $\log_2$  do número de características. Também pode ser usado como medida o número de amostras restantes.

O número mínimo de amostras por folha e amostras por separação são critérios que podem ser considerados indicadores de complexidade do algoritmo. Eles são, respectivamente, o número de amostras no final da árvore (na parte mais inferior) e o número de amostras necessárias para fazer uma separação. Se o número de amostras por separação for alto, significa que o modelo conseguiu generalizar com baixa complexidade, sem ter que separar classes baseado em um número pequeno de exemplos. Se o número de amostras por folha for alto, significa que ele não precisou ir muito além na altura da árvore. Porém para o problema deste trabalho não será eficiente deixar esses números mínimos como um valor relativamente alto por conta do número reduzido de amostras da situação.

No terceiro e último passo a saída individual de cada árvore é usada para determinar a saída total. Para isso a escolha pode ser por voto majoritário ou realizar uma média, como é possível visualizar na Figura 11. Nesse intuito serão utilizadas as amostras out-of-bag, podendo ajustar os pesos dos votos para cada árvore (Edla, 2018 e Fraiwan, 2012).



**Figura 11:** Esquema do classificador Random Forest: **Passo 3** (Fraivan, 2012).

## 2.5 Eficiência dos Classificadores

Para analisar a eficiência dos classificadores será efetuada a verificação de desempenho baseado no modelo de classes positivas e negativas e preenchimento de Matriz de Confusão, que é uma métrica comumente utilizada para aferir a performance de algoritmos de classificação. Esse mapeamento possui as seguintes possibilidades (Visa et al., 2011)

- Se a amostra é classificada como positiva e ela é realmente positiva, se qualifica um Verdadeiro Positivo (VP);

- Se a amostra é classificada como negativa e ela é realmente negativa, se qualifica um Verdadeiro Negativo (VN);

- Se a amostra é classificada como positiva mas na realidade ela é negativa, se qualifica um Falso Positivo (FP);

- Se a amostra é classificada como negativa mas na realidade ela é positiva, se qualifica um Falso Negativo (FN);

Após esse mapeamento a Matriz de Confusão é populada de acordo como o seguinte exemplo:

Tabela 3: Representação de Matriz de Confusão

<b>PREDIÇÃO</b> <b>REALIDADE</b>	<b>POSITIVA</b>	<b>NEGATIVA</b>
<b>POSITIVA</b>	Verdadeiro Positivo (VP)	Falso Negativo (FN)
<b>NEGATIVA</b>	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Feito isso podem ser calculadas as métricas de desempenho do classificador. A acurácia (A) define a porcentagem de acerto efetivo.

$$A = \frac{VP+VN}{VP+VN+FP+FN} \quad (30)$$

Também será calculada a Precisão (P) para as duas categorias

$$P = \frac{VP}{VP+FP} \quad (31)$$

$$P = \frac{VN}{VN+FN} \quad (32)$$

## 2.6 Considerações Finais

Neste capítulo foram feitas análises sobre: aspectos gerais do sinal de EEG; o que alguns autores relatam sobre padrões de sinal de EEG para diferentes estados mentais, inclusive durante o estado de esforço cognitivo; a Transformada de Fourier; e também algumas técnicas de aprendizagem de máquina interessantes para a aplicação deste trabalho.

O sinal de eletroencefalografia representa a atividade elétrica do cérebro e é adquirido por meio de eletrodos, podendo ser da forma não invasiva ou invasiva. Uma maneira usual, que foi abordada neste capítulo, é o Sistema 10-20.

Essa atuação elétrica encefálica ocorre de maneira rítmica e normalmente é subdividida entre os intervalos: alpha ( $\alpha$ ), theta ( $\theta$ ), beta ( $\beta$ ), delta ( $\delta$ ), e gamma ( $\gamma$ ). Existem autores que fazem uma segmentação um pouco diferente, dividindo o intervalo beta em baixo (14-20 Hz) e alto (20–30 Hz).

Também foi visto que dois estados mentais podem ter atividades elétricas bem distintas um do outro, e partindo desse pressuposto, se torna possível diferenciar entre um estado de esforço cognitivo e de descanso. Essa diferenciação pode se dar tanto por amplitude elétrica maior em determinadas áreas do cérebro, se comparada à observada em outras regiões, quanto por energia maior constatada em uma banda do espectro para um estado mental se comparado ao outro.

Para serem obtidas características em frequência dos sinais de EEG é necessário realizar a Transformada de Fourier. Neste trabalho foi utilizada a Transformada Discreta de Fourier, mais precisamente a Transformada Rápida de Fourier.

Por fim, para ser realizada a identificação de esforço cognitivo, serão utilizadas as características em frequência calculadas pela Transformada Discreta de Fourier como parâmetros e serão utilizadas técnicas de aprendizagem de máquina. Máquina de Aprendizagem Extrema, Máquina de Vetores de Suporte e Floresta Aleatória foram os métodos que seriam interessantes para o problema

em questão, porém apenas os dois últimos serão aplicados neste trabalho. E ainda, para aumentar a eficiência desses classificadores será aplicado afinamento de Hiper Parâmetros.



## 3. Metodologia

Primeiramente foi feito a aquisição de um banco de dados cuja natureza da pesquisa seja semelhante com a que é proposta neste trabalho. O banco de dados escolhido foi o que será melhor descrito no Item 3.1. Nesse experimento em questão, os participantes ficaram parte do tempo descansando de olhos fechados e na outra parte do tempo realizando subtrações aritméticas. Essa situação serviu como parâmetro em que possa ser feita a distinção entre estados de descanso e estado de atenção, respectivamente.

Posteriormente foi feito o processamento de sinais, transformando para o domínio da frequência, remoção de ruído e segmentação em bandas de frequência. Com isso, essas características foram utilizadas para realizar a distinção entre esforço cognitivo e descanso utilizando SVM e RF.

A implementação do sistema de um modo geral foi feita utilizando *Python3* que conta com uma grande quantidade de bibliotecas úteis para aplicações de processamento de sinais (como *Scipy* e *Numpy*), de algoritmos de classificação (como *Scikit Learn*), e de análise gráfica (como *Pandas*, *Seaborn* e *Matplotlib*). Além disso, a facilidade e popularidade da plataforma torna mais próxima a possibilidade de um trabalho posterior.

### 3.1 Banco de Dados

O banco de dados utilizado como referência para este trabalho foi o dos pesquisadores (Zyma et al., 2019), e nesse experimento foi utilizado o Neurocom EEG de 23 canais. Os eletrodos foram colocados no couro cabeludo de acordo com o padrão internacional 10/20. A referência para todos os eletrodos foi a posição dos ouvidos interconectados.

O experimento foi realizado com 66 participantes sendo que 30 gravações foram eliminadas por terem baixa qualidade de sinal, como sendo um alto comportamento miográfico e ocularográfico. O roteiro do ensaio foi de 3 minutos de adaptação para o participante, seguido de 3 minutos de descanso com olhos fechados e posteriormente mais 4 minutos com o sujeito fazendo subtrações aritméticas, sendo que os 3 minutos de descanso e o primeiro minuto do sujeito realizando a conta foram efetivamente extraídos pelo eletroencefalógrafo. Além disso nessa base de dados é possível encontrar o número de operações aritméticas feitas corretamente pelos sujeitos.

Então cada planilha original em que o sujeito estava descansando (3 minutos de aquisição) terá 12 planilhas menores. E cada planilha original em que o sujeito estava realizando a conta aritmética (1 minuto de aquisição terá 4 planilhas menores.

A taxa de amostragem foi de 500 Hz, o que inviabiliza a possibilidade de sobreposição da transformada do sinal. Um filtro passa-altas e um passa-baixas com frequências de corte de 0,5 Hz e 45 Hz, respectivamente, foram aplicados, bem como um filtro notch de frequência central igual a 50 Hz, que é a frequência da rede elétrica do local (Zyma et al., 2019).

A planilha tem portanto a seguinte estrutura: a que tiver no nome o índice 1 é referente ao intervalo em que o candidato está descansando, portanto ela tem em torno de 90 mil amostras; e a que tiver no nome o índice 2 é referente ao intervalo em que o candidato está realizando a conta aritmética, portanto ela tem em torno de 30 mil amostras. Portanto os datasets terão respectivamente 90 mil e 30 mil linhas.

As colunas do banco de dados são 21, sendo referentes às seguintes características: frontal-polar (Fp1, Fp2), frontal (F3, F4, Fz, F7, F8), central (C3, C4, Cz) parietal (P3, P4, Pz), occipital (O1, O2) e temporal (T3, T4, T5, T6). Ainda existe uma coluna A1-A2, a subtração dos dois eletrodos de referência e uma coluna referente a um sinal de eletrocardiografia, também extraído pelos participantes.

Conforme mostra a Figura 12, como estão divididos os dados na planilha.

1	# EEG Fp1	EEG Fp2	EEG F3
2	-3.647937628137634766e-06	-3.581866322728314057e-06	-4.081246631876108467e-06
3	-4.236481676661325242e-06	-4.279388286106661906e-06	-4.766219340199904494e-06
4	-4.954218321202409328e-06	-5.020848640878920039e-06	-5.783454929427035117e-06
5	-5.703854372167542914e-06	-5.656124549782560132e-06	-7.079280164950037837e-06
6	-6.370551966430150512e-06	-6.04607773403525822e-06	-8.518234026092936882e-06
7	-6.847448092469672399e-06	-6.124800724650950622e-06	-9.903514652628376817e-06
8	-7.067553996795603949e-06	-5.901447235065233689e-06	-1.102298497444115009e-05
9	-7.024489798123139836e-06	-5.469386386358434751e-06	-1.171562528770886752e-05
10	-6.767699576409551192e-06	-4.965925651636531018e-06	-1.190475954299230494e-05

**Figura 12:** Retratação da planilha de dados a serem utilizados. Nessa imagem é mostrada uma planilha de dados em que o sujeito estava descansando

O banco de informações em questão ainda conta com uma planilha que informa se o sujeito acertou mais de 10 subtrações em média por minuto, sendo portanto um parâmetro para definir o parâmetro do candidato.

O formato do banco de dados é *EDF* e para melhor manipulação será feita a conversão para o formato *CSV* por meio da biblioteca *Mne*. Para fazer a extração, segmentação e visualização dos dados dos algoritmos será utilizada a biblioteca *Pandas* e *Csv*. Para eventuais manipulações de dados também será utilizada a biblioteca *Numpy*.

## 3.2 Processamento de sinais

Primeiramente foi feito um fatiamento da quantidade de dados a fim de ter mais parâmetros para serem utilizados no treinamento. O tempo realizado em cada experimento é mais que o suficiente para adquirir características em frequência. O tempo escolhido foi de 30 segundos, então haverá em média 30 ciclos de ondas Theta, ou pelo menos 200 ciclos de ondas Alfa, por exemplo. Via de regra, em média 10 segundos já são suficientes para extrair características de sinal de EEG (Sanei, 2007). No trabalho de (Carrión-Ojeda, D., et al., 2019) foi constatado uma eficiência de 90% para identificação de uma pessoa por meio de sinal de EEG e DWT, tendo utilizado apenas 2 segundos.

Assim como em metodologias dos trabalhos referenciados, a extração de características foi baseada na Transformada de Fourier. Foi usado em outras dissertações as Transformadas de Hilbert Huang e a Transformada de Wavelet Discreta, que permitem uma melhor extração de características no âmbito tempo-frequência. Porém neste trabalho o intuito é testar a eficácia da Transformada Discreta de Fourier, sobretudo da FFT, que apresenta uma complexidade relativamente menor que as demais extrações de características em frequência. Para que seja extraída a energia da banda do sinal a DFT por definição já é suficiente. Para isso foram utilizados pacotes *fft* da biblioteca *Scipy*, e para efetivamente realizar a transformada foi chamada a função *rfft()*, visto que o sinal utilizado é real.

Em relação ao tratamento do sinal, o padrão utilizado, e que também será aplicado nesse desenvolvimento, as técnicas que serão apresentadas são:

- Segmentação em cinco bandas do sinal: Theta (de 0,5 Hz a 7,5 Hz, incluindo portanto o espectro de ondas Delta nessa segmentação, e nomeando de Theta apenas por preferência), Alfa (de 7,5 Hz a 14 Hz), Beta Baixa (14 Hz a 20 Hz), Beta Alta (20 Hz a 30 Hz) e Gama (30 Hz a 60 Hz).
- Cálculo das energias dessas bandas, para que essas sejam utilizadas como características para os classificadores;

## 3.3 Classificação

Inspirado em teses similares como para (Balasubramanian, 2014; Purnamasari e Junika, 2019; Peng et al., 2020; Aziz, 2017; Bird et al., 2018; Edla, 2018 e Zhang et al., 2021) é buscado nesse trabalho utilizar as técnicas de aprendizagem de máquina SVM e RF. Uma justificativa para a escolha desses dois métodos é por conta da eficiência bem como foi observada com os autores acima.

Além disso, conforme foi descrito no Tópico 1.3, esses dois algoritmos de aprendizagem de máquina são eficientes para situações em que há poucos exemplos de treinamento se comparado ao número de parâmetros.

Outra motivação é a baixa complexidade desses algoritmos, podendo levar a replicação desse trabalho para o contexto de eletrônica embarcada em algum trabalho futuro como fez (Edla, 2018 e Pinheiro, 2014).

Para implementação do algoritmo de SVM e de RF também será utilizado o pacote *svm* e *ensemble* da biblioteca *sklearn* (Pedregosa F., et al. 2011), respectivamente.

### 3.4 Considerações Finais

Para implementação deste projeto foram feitos os seguintes passos: Primeiramente a aquisição de um banco de dados que possa ser feita a distinção entre o estado mental de esforço mental e de descanso. Posteriormente, um processamento em frequência desses sinais adquiridos e utilizar as informações resultantes dessa segunda etapa para realizar a identificação de empenho mental.

O banco de dados escolhido para esta aplicação foi o realizado pelos pesquisadores (Zyma et al., 2019), e o eletroencefalógrafo que foi utilizado para a aquisição estava de acordo com o padrão internacional, o Sistema 10-20, e nessa pesquisa o aparelho tinha 23 canais. O contexto desse estudo era de sujeitos que ora estavam descansando com os olhos fechados, ora realizando contas aritméticas mentalmente. Vale ressaltar que foi implementado um filtro notch de 50 Hz (frequência de rede elétrica do local aonde o experimento foi realizado).

Após aquisição do banco de dados foi realizada a Transformada de Fourier, posteriormente foi feita a segmentação em 5 bandas de frequência e calculada a energia dessas bandas.

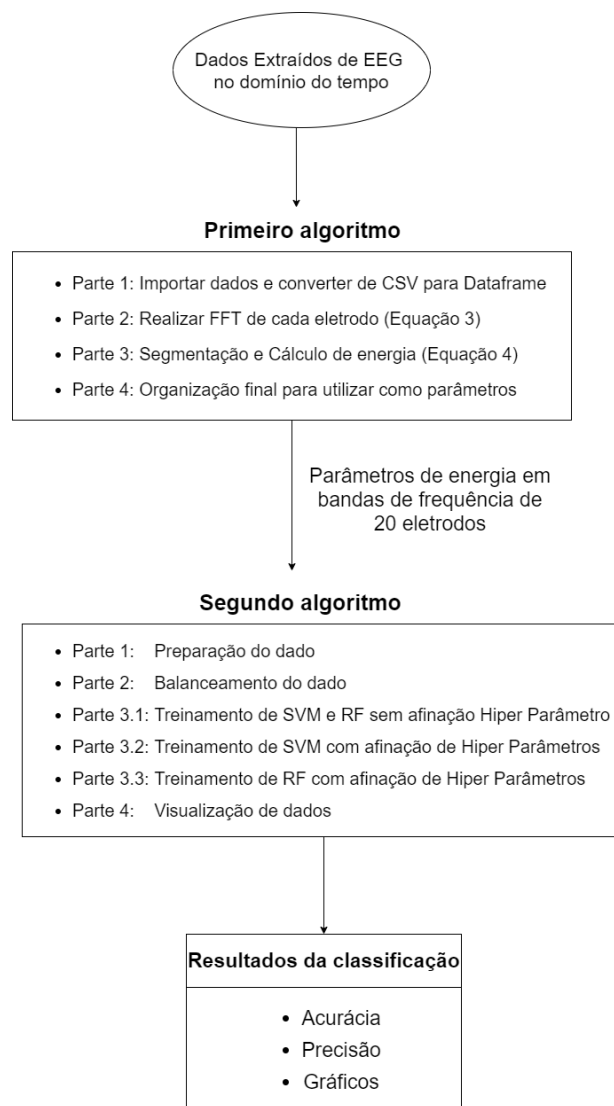
E por fim, com essas informações de energias das bandas foi feita a classificação utilizando as técnicas de Máquinas de Vetores de Suporte e Floresta Aleatória, primeiramente sem o afinamento de Hiper Parâmetros e posteriormente com o afinamento.

Além disso, foi feita a contemplação de visualização gráfica das energias das bandas por eletrodos, para que fossem observados se alguns eletrodos adquiriram uma energia maior do que eletrodos de outras regiões. Primeiramente foi feita a geração de gráficos para que fosse visualizada a energia de todos eletrodos para uma banda de frequência por vez e posteriormente da energia para todas as bandas de cada eletrodo. Tanto a eficiência dos classificadores quanto visualização gráfica das energias poderão ser melhor observados no Tópico 4.

## 4. Resultados

O esquema geral do projeto de detecção de esforço cognitivo pode ser observado na Figura 13.

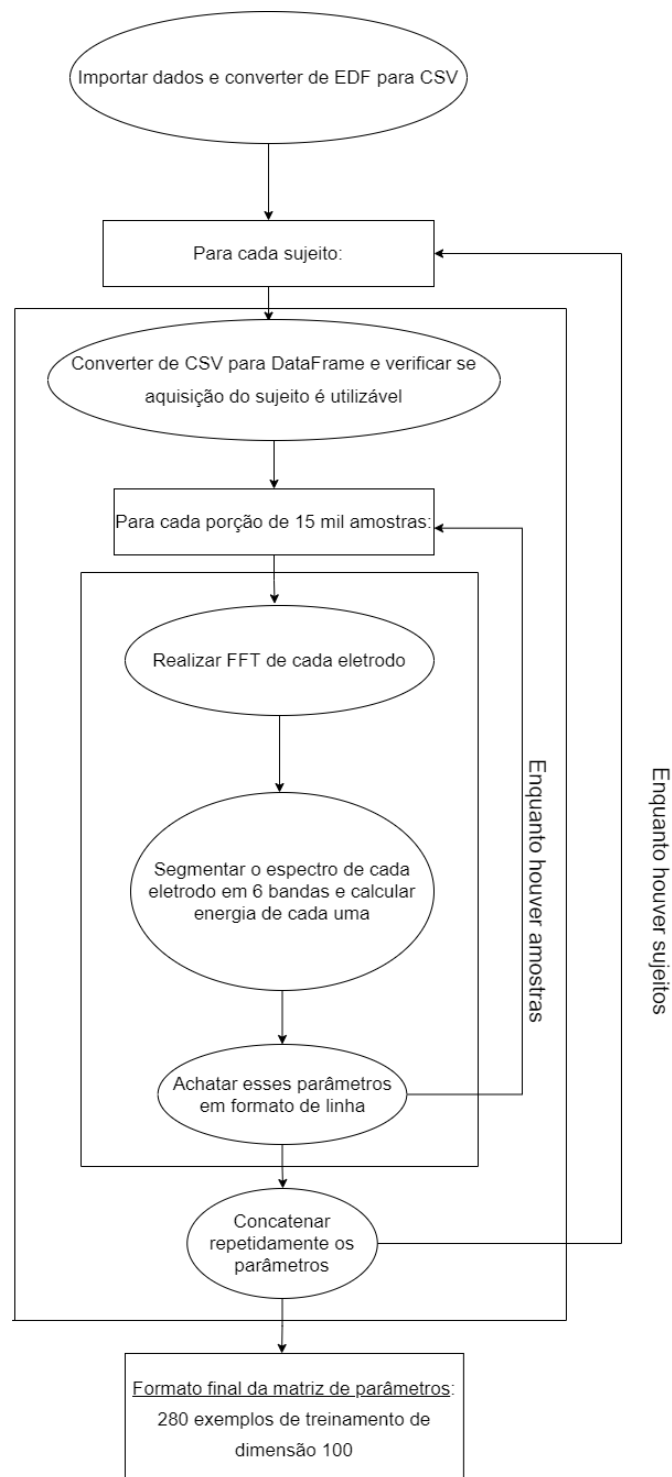
A legenda para esse esquema é: elipse para dados do banco de dados, retângulo para implementação de algoritmos e retângulo com título sublinhado para resultado final.



**Figura 13:** Esquema geral do projeto de identificação de esforço cognitivo.

O esquema do primeiro algoritmo, cujo objetivo é transformar dados temporais detectados por EEG em energias por bandas de frequência pode ser observado na Figura 14. A legenda para esse esquema é: elipse para o resumo de uma parte do algoritmo, retângulo indicando um laço de repetição, expressão em

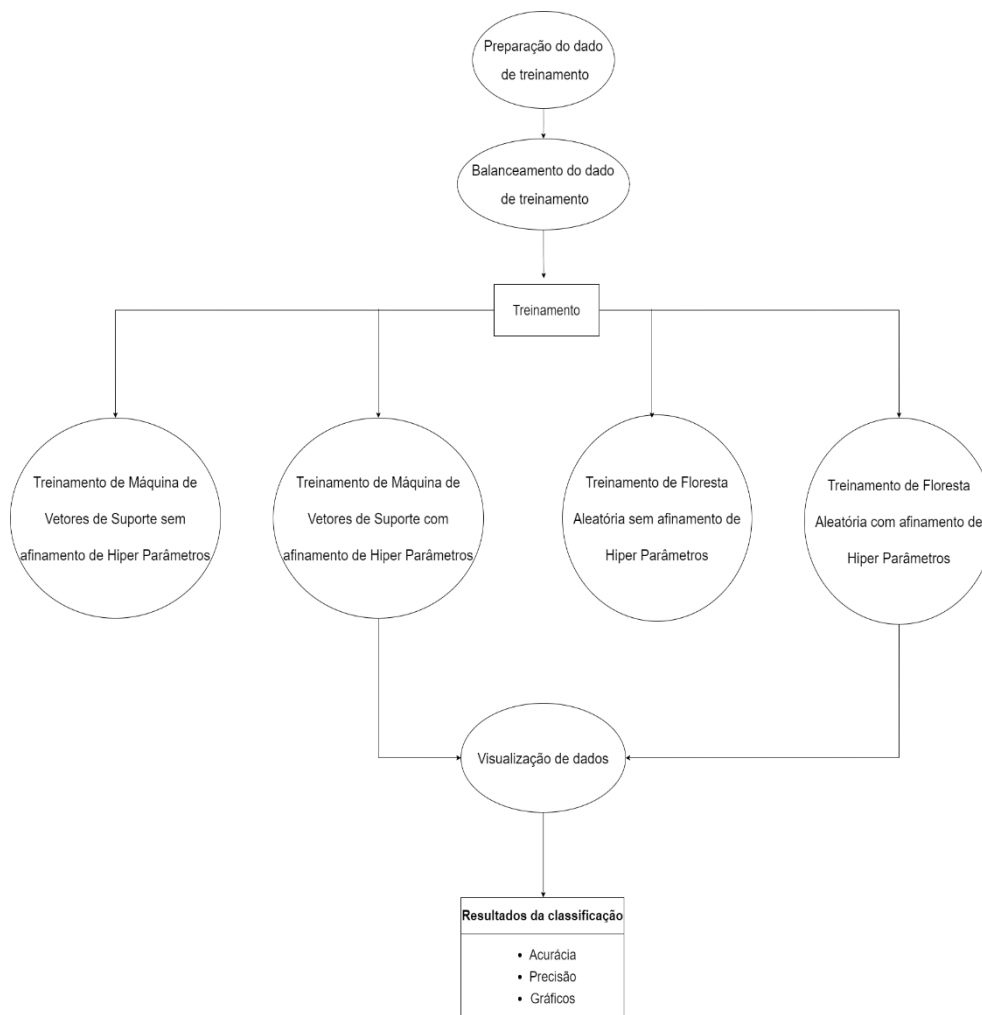
cima de seta para condição de parada de laço, e retângulo com título sublinhado para resultado final.



**Figura 14:** Esquema do primeiro algoritmo.

O código para o primeiro algoritmo pode ser encontrado em: [https://github.com/lucasrfsb/EEG\\_Attention/blob/dev/EEG\\_ENERGY.py](https://github.com/lucasrfsb/EEG_Attention/blob/dev/EEG_ENERGY.py)

E por fim, o esquema do segundo algoritmo pode ser observado na Figura 15. Seu objetivo é, a partir dos dados de treinamento, que são a saída do primeiro algoritmo, calcular acurácia, precisão e mostrar visualmente informações sobre as energias em bandas dos eletrodos. A legenda para esse esquema é: elipse para o resumo de uma parte do algoritmo, retângulo representando que será iniciado o treinamento, e retângulo com título sublinhado para resultado final.



**Figura 15:** Esquema do segundo algoritmo.

O código do segundo algoritmo pode ser encontrado em: [https://github.com/lucasrfsb/EEG\\_Attention/blob/dev/Attention\\_EEG\\_SVM\\_RF.ipynb](https://github.com/lucasrfsb/EEG_Attention/blob/dev/Attention_EEG_SVM_RF.ipynb)

Na Figura 16 pode ser visualizada uma prévia de como ficaram os parâmetros a serem utilizados pelos algoritmos de classificação.

	FP1_THETA	FP1_ALFA	FP1_LOW_BETA	FP1_HIGH_BETA	FP1_GAMMA	FP2_THETA	FP2_ALFA	FP2_LOW_BETA	FP2_HIGH_BETA	FP2_GAMMA	F3_THETA	F3_ALFA	F3_LOW_BETA
0	0.003122	0.000746	0.001290	0.003108	0.000984	0.005411	0.001114	0.001699	0.003875	0.001397	0.007081	0.001243	0.002075
1	0.003605	0.000666	0.001151	0.003855	0.001076	0.006041	0.000956	0.001577	0.004728	0.001484	0.005199	0.001226	0.001922
2	0.003238	0.000703	0.001059	0.003332	0.001057	0.006116	0.001001	0.001324	0.004140	0.001483	0.004321	0.001103	0.001612
3	0.002924	0.000697	0.001280	0.003898	0.001035	0.005723	0.000899	0.001609	0.004823	0.001454	0.004187	0.001242	0.002095
4	0.002708	0.000764	0.001208	0.003596	0.001209	0.004032	0.000965	0.001529	0.004449	0.001588	0.004251	0.001402	0.001964
...	...	...	...	...	...	...	...	...	...	...	...	...	...
275	0.017603	0.001304	0.000946	0.000722	0.000534	0.026915	0.001756	0.000780	0.000780	0.001292	0.011065	0.001165	0.001000
276	0.012351	0.001250	0.000720	0.000617	0.000463	0.024394	0.001063	0.000664	0.000588	0.000297	0.004792	0.001229	0.000637
277	0.010578	0.001124	0.000813	0.000886	0.000451	0.017699	0.001011	0.000729	0.000940	0.000322	0.005207	0.001073	0.000747
278	0.008294	0.000932	0.001500	0.000572	0.001109	0.002390	0.000732	0.002013	0.000458	0.001094	0.002618	0.001049	0.001456
279	0.011787	0.001186	0.001903	0.000585	0.001153	0.004362	0.001039	0.002633	0.000625	0.001022	0.004459	0.001450	0.002224

280 rows x 101 columns

**Figura 16:** Demonstração de parâmetros de eletrodos 5 bandas de frequência

Primeiramente foi feito o treinamento com os hiperparâmetros de valor padrão, ou seja, que as bibliotecas disponibilizam como padrão. Como o afinamento de hiperparâmetros sempre irá gerar resultados melhores, não serão mostrados os resultados da eficiência dos classificadores sem o afinamento.

Posteriormente foi feita, para ambos os modelos, a Otimização de hiperparâmetros, que foram os que estão no Quadro 2. Os modelos foram treinados, separadamente, com a combinação de todas as possibilidades de hiperparâmetros, sendo que a escolha dos intervalos para cada hiperparâmetro foi feita de maneira estocástica.

**Quadro 2:** Hiper Parâmetros utilizados nos dois modelos

Support Vector Machine	Random Forest
Parâmetro C: 0,1; 1; 10; 100	Bootstrap: <b>Ativado e Desativado</b>
	Altura máxima: 10, 20, 30, 40, 50, 60, 70, 80, 90, 100
Parâmetro $\gamma$ : 1,0; 0,1; 0,01; 0,001	Máximo de parâmetros por separação: <b>Raiz quadrada e log2</b>
	Mínimo de amostras por folha: <b>1, 2, 4</b>
Kernel: RBF; Polinomial; Sigmoid	Mínimo de amostras por separação: <b>2, 5, 10</b>
	Número de estimadores: 200, 400, 600, 800, 1000, 1200, 1400, 1600, 1800, 2000



Para cada modelo foram executadas as opções descritas no Quadro 2 e com isso foram gerados os resultados descritos na Tabela 4. Os hiperparâmetros escolhidos algoritmicamente estão descritos no Quadro 3.

**Tabela 4:** Eficiência dos classificadores com o afinamento dos Hiper Parâmetros

	VP	VN	FP	FN	A	P
<b>Support Vector Machine</b>	13	50	3	4	90%	Atento 81%
						Desatento 93%
<b>Random Forest</b>	16	52	1	1	97%	Atento 94%
						Desatento 98%

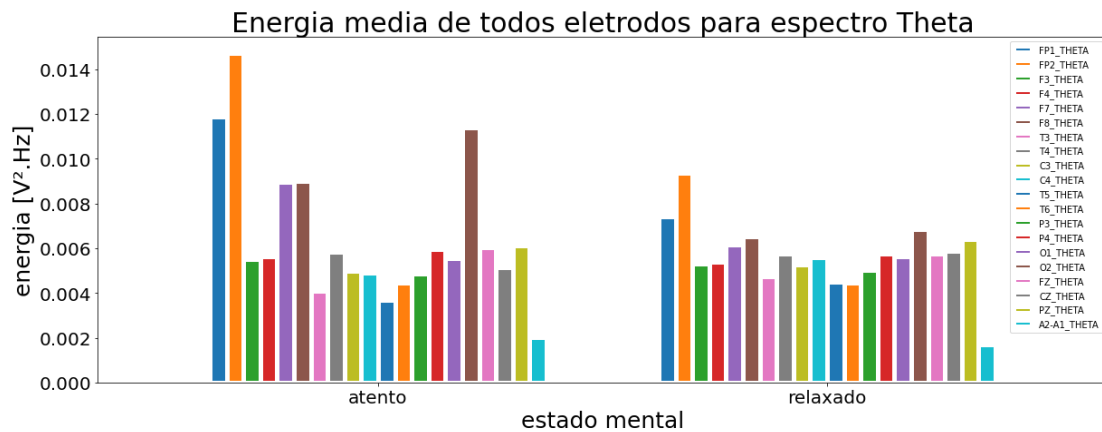
**Quadro 3:** Hiper Parâmetros selecionados nos dois modelos

<b>Máquina de Vetores de Suporte</b>	<p>C: 100</p> <p><math>\gamma</math>: 0,01</p> <p>Kernel: RBF</p>
<b>Floresta Aleatória</b>	<p>Bootstrap: <b>Ativado</b></p> <p>Altura Máxima: 50</p> <p>Máximo de parâmetros por separação: <b>Raiz quadrada</b></p> <p>Mínimo de amostras por folha: 1</p> <p>Mínimo de amostras por separação: 2</p> <p>Número de estimadores: 1000</p>

Com base no valor dos parâmetros que foram selecionados na Máquina de Vetores de Suporte é possível concluir que: devido ao parâmetro C com um valor alto, o algoritmo penalizou bastante amostras que não estavam de acordo com o enquadramento. Em razão de um baixo valor de  $\gamma$ , o modelo não ficou muito complexo, ou seja, cada amostra não influenciou um espaço pequeno ao seu redor (área de influência do raio). Foi eleito como Kernel o RBF Gaussiano, como já foi discutido anteriormente no Tópico 2.4.2, ele possui uma boa capacidade de generalização.

Observando os parâmetros indicados pelo modelo de Floresta Aleatória resulta-se que: o bootstrap ativado aumenta a variabilidade das amostras de entrada, o que faz sentido para o problema deste trabalho, por ter um baixo número de amostras. A altura máxima não foi até a poda máxima da árvore, parâmetro que poderia levar ao overfitting. O mínimo de amostras por folha e por separação foi um número pequeno devido ao reduzido número de amostras do problema deste trabalho e da complexidade do modelo resultante, se esse número mínimo fosse alto significaria que o algoritmo não iria precisar de muita especificidade.

Conforme mostram as Figuras 17 e 18 foi observado que para a maioria dos eletrodos houve uma maior energia para a banda Theta quando os sujeitos estavam atentos em relação à quando eles estavam descansando. Isso denota uma maior ativação encefálica nesse espectro de frequência para uma atividade que necessite de um maior esforço cognitivo.



**Figura 17:** Comparativo da Energia média em Volt<sup>2</sup>.Hz de todos eletrodos do sistema 10-20 para espectro Theta

Existem ainda eletrodos que tiveram destaque na diferença de energia observada para esse espectro de frequência, conforme mostram as Figuras 16 a 20. Esses eletrodos foram os da parte frontal (FP1, FP2, F7 e F8) e occipital, O2 principalmente. Resultados similares foram relatados por (Lim S., et al., 2019), em que foi descrito uma maior ocorrência de ondas Theta no estado de imersão para os eletrodos FP1, FP2 e O2. Também para (Rodriguez-Larios, J., et al., 2020

e Winnie, 2017) ondas Theta na parte frontal foram relacionadas com alto nível cognitivo.




Figura 18: Comparativo de Energia média em Volt².Hz para o eletrodo FP1




Figura 19: Comparativo de Energia média em Volt².Hz para o eletrodo FP2






Figura 20: Comparativo de Energia média em Volt².Hz para o eletrodo F7



**Figura 21:** Comparativo de Energia média em Volt<sup>2</sup>.Hz para o eletrodo F8



**Figura 22:** Comparativo de Energia média em Volt<sup>2</sup>.Hz para o eletrodo O2

Ressalta-se que houve uma discrepância maior para os eletrodos da parte frontal polar, frontal e occipital, levando a crer que para discernir entre os estados mentais de atenção e relaxamento bastariam esses eletrodos, e não todos como proposto no Sistema 10-20. Mais especificamente, como houve essa disparidade maior no espectro de ondas Theta, bastaria a análise nesse intervalo de frequência para que se possa discernir o estado mental de esforço cognitivo do estado de descanso.

## 5. Conclusão:

Neste trabalho foi comparada a energia em frequência de sinais de EEG para os estados mentais de descanso com olhos fechados e ao realizar conta aritmética. Para isso foi feita a segmentação em cinco bandas de frequência e utilização dessas informações como parâmetros a serem utilizados nos classificadores Máquina de Vetores de Suporte e Floresta Aleatória. Como resultado foi possível obter, para o primeiro modelo, uma acurácia de 90%, precisão de 81% para o estado de esforço cognitivo e precisão de 90% para estado de descanso. E para o segundo modelo foi possível obter uma acurácia de 97%, precisão de 94% para o estado de esforço cognitivo e precisão de 98% para o estado de descanso. Além disso, houve destaque para uma diferença significativa de energia para o grupo de eletrodos das partes frontal polar, frontal e occipital no segmento de ondas Theta. Essa importância encontrada para discernir os estados mentais conclui que é possível fazer essa identificação de esforço cognitivo em relação ao estado de descanso com apenas esse grupo reduzido de eletrodos e fazendo análise apenas do espectro Theta.

## 6. Hipótese e trabalhos futuros:

A extração de sinal de eletroencefalografia da forma não invasiva não influenciaria a presença de um aluno em uma aula significativamente. Portanto, os dados de sinal de EEG daquela situação podem ser adquiridos e posteriormente analisados para identificar se o aluno estava realmente em um estado de esforço cognitivo adequado.

Como na base de dados pesquisada e utilizada neste trabalho é possível ter acesso ao número de operações aritméticas realizadas corretamente pelos sujeitos, hipoteticamente em um projeto futuro pode ser feita a relação entre um bom rendimento em esforço cognitivo com a atividade elétrica obtida em determinadas regiões encefálicas

Um suposto projeto como esse descrito na hipótese teria como base este trabalho. Além disso, poderia haver o desenvolvimento da análise para que fosse feita uma identificação de alguma anomalia cognitiva utilizando a abordagem de estudo no domínio frequência e técnicas de Inteligência Artificial.

## 7. REFERÊNCIAS:

Abdelhameed, A. M.; Bayoumi, M. Semi-supervised EEG signals classification system for epileptic seizure detection. *IEEE Signal Process Lett* 26(12):1922–1926 (2019). Acessando em: <https://doi.org/10.1109/LSP.2019.2953870>.

Acharya U. R.; Faust, N. O.; Kannathal, T. C. and S. Laxminarayan, Nonlinear analysis of EEG signals at different sleep stages, *Computer Methods and Programs in Biomedicine* 80(1) (2005).

Acharya, U. R., Sree, S.; Chattopadhyay, S.; Suri J. *Automated Diagnosis of Normal and Alcoholic EEG signals* (2012).

Acharya U. R.; Sree, S.; Suri, J. S. Automatic detection of epileptic EEG signals using higher order cumulant features, *International Journal of Neural Systems* 21(4) (2011).

Adeli H.; Ghosh-Dastidar, S.; Dadmehr, N. A Spatio-temporal wavelet-chaos methodology for EEG-based diagnosis of Alzheimer's disease, *Neuroscience Letters* 444(1) (2008).

Ahmadlou and. M.; Adeli, H. Fuzzy synchronization likelihood with application to attention-deficit/hyperactivity disorder, *Clinical EEG and Neuroscience* (2011).

Ahmadlou and. M.; Adeli, H. Wavelet-synchronization methodology: A new approach for EEG-based diagnosis of ADHD, *Clinical EEG and Neuroscience* (2010).

American Psychiatric Association. *Diagnostic and Statistical Manual of Mental Disorders* (5th ed.). Arlington: American Psychiatric Publishing (2013).

Attwood, H. L.; and MacKay, W. A.; *Essentials of Neurophysiology*, B. C. Decker, Hamilton, Canada, (1989).

Aziz F. A. A., Setiawan N. A., Shapiai M. I., Yasue M. *Classification of Human Concentration in EEG Signals using Hilbert Huang Transform*. Eletronic System Engineering, MJIT, Center of Artificial Intelligence and Robotics (CAIRO), (2017).

- Balasubramanian P. *Automated Classification of EEG Signals Using Components Analysis and Support Vector Machines*. MastersTheses 779, (2014).
- Bird J. J.; Manso L. J.; Ribeiro E. P.; Ekart A. *A Study on Mental Classification using EEG-based Brain-Machine Interface*. International Conference on Intelligent System, (2018).
- Carrión-Ojeda, D.; H. Mejía-Vallejo, R.; Fonseca-Delgado, P.; Gómez-Gil and M. Ramírez-Cortés. "A method for studying how much time of EEG recording is needed to have a good user identification," *2019 IEEE Latin American Conference on Computational Intelligence (LA-CCI)*, pp. 1-6, doi: 10.1109/LA-CCI47412.2019.9037054 (2019).
- DuPaul, G.J.; Hoff, K.E. *Attention/Concentration Problems*. In: Watson T.S., Gresham F.M. (eds) *Handbook of Child Behavior Therapy. Issues in Clinical Child Psychology*. Springer, Boston, MA, (1998). Acessando em: [https://doi.org/10.1007/978-1-4615-5323-6\\_6](https://doi.org/10.1007/978-1-4615-5323-6_6).
- Edla, D. R.; Mangalorekar, K.; Dhavalikar G.; Dodia, S. *Classification of EEG data for human mental state analysis using Random Forest Classifier*. International Conference on Computational Intelligence and Data Science, (2018).
- Fayyad, J.; Sampson, N.A.; Hwang I, et al. *The descriptive epidemiology of DSM-IV Adult ADHD in the World Health Organization World Mental Health Surveys. Atten Defic Hyperact Disord*, (2017).
- Fraiwan, L.; Lweesy, K.; Khasawneh, N.; Wenz, H.; & Dickhaus, H. *Automated sleep stage identification system based on time–frequency analysis of a single EEG channel and random forest classifier. Computer Methods and Programs in Biomedicine*, 108(1), 10–19. doi:10.1016/j.cmpb.2011.11.005, (2012).
- Fred, P.; Juhani, E.; Tuovinen, Huib, T.; & Pascal, W. M.; Gerven, V. *Cognitive Load Measurement as a Means to Advance Cognitive Load Theory*, *Educational Psychologist*, 38:1, 63-71, (2003).
- Goldberger, A.; Amaral, L.; Glass, L.; Hausdorff, J.; Ivanov, P. C.; Mark, R., ... & Stanley, H. E. *PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals*. *Circulation* [Online]. 101 (23), pp. e215–e220, (2000).
- Horta E. G. *Aplicação de Máquinas de Aprendizado Extremo ao Problema de Aprendizado Ativo*, CDU: 621.3(043), (2015).
- Huang, G.-B., Zhu, Q.-Y.; and C.-K. Siew, "Extreme learning machine: Theory and applications," *Neurocomputing*, vol. 70, no. 1, pp. 489–501, (2006).



Katahira, K., Yamazaki, Y., Yamaoka, C., Ozaki, H., Nakagawa, S., Nagata, N. *EEG Correlates of the Flow State: A Combination of Increased Frontal Theta and Moderate Frontocentral Alpha Rhythm in the Mental Arithmetic Task*, (2018).

Lawrence D.; Houghton S.; Dawson V., Sawyer M.; Carrol A. *Trajectories of academic achievement for students with attention-deficit/hyperactivity disorder*. *British Journal of Education Psychology*, (2020)

Lim S, Yeo M, Yoon G. *Comparison between Concentration and Immersion Based on EEG Analysis*. *Sensors* (Basel). Apr 8;19(7):1669. doi: 10.3390/s19071669. PMID: 30965606; PMCID: PMC6479797, (2019).

Loo, S. K., & Barkley, R. A. *Clinical Utility of EEG in Attention Deficit Hyperactivity Disorder*. *Applied Neuropsychology*, 12(2), 64–76. doi:10.1207/s15324826an1202\_2, (2005).

Mehrotra, Kishan G.; Mohan, Chilukuri K.; and Ranka, Sanjay, "Bounds on the Number of Samples Needed for Neural Learning". *Electrical Engineering and Computer Science - Technical Reports*. 94, (1980).

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, D., Brucher, M., Perrot, M., & Duchesnay, E. *Scikit-learn: Machine Learning in Python*. *Journal of Machine Learning Research*, 12, 2825–2830, (2011).

Peng C., Chen Y., Chen C., Chen S., Cagneau B., Chassagne L. *An EEG- Based Attentiveness Recognition System Using Hilbert-Huang Transform and Support Vector Machine*. *Journal of Medical and Biological Engineering*, (2020).

Pinheiro, V. C. *Desenvolvimento e Avaliação de um Sistema de Análise de Equilíbrio Postural Humano com Base em Sinais de Inclínômetros e Máquinas de Suporte Vetorial*. *Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Biomédica, Universidade de Brasília, Campus Gama* (2014).

Purnamasari, P. D.; Junika, T. W. *Frequency-based EEG Human Concentration Detection System Methods with SVM Classification*. *IEEE CYBERNETICSCOM*, (2019).

Rodriguez-Larios, J., Faber, P., Achermann, P. et al. *From thoughtless awareness to effortful cognition: alpha - theta cross-frequency dynamics in experienced meditators during meditation, rest and arithmetic*. *Sci Rep* 10, 5419. Acessado em: <https://doi.org/10.1038/s41598-020-62392-2> (2020).

Sanei S., Chambers J. A. *EEG Signal Processing*. p. 1-30 (2007).

Schratz P.; Muenchow J.; Iturritxa E.; Richter J.; Brenning A. *Hyperparameter tuning and performance assessment of statistical and machine-learning algorithms using*

*spatial data*. *Ecological Modelling*, Volume 406, (2019), pp. 109-120, ISSN 0304-3800. Acessado em: <https://doi.org/10.1016/j.ecolmodel.2019.06.002>.

Speckmann, E.-J.; and Elger, C. E. 'Introduction to the neurophysiological basis of the EEG and DC potentials', in *Electroencephalography Basic Principles, Clinical Applications, and Related Fields*, Eds E. Niedermeyer and F. Lopes da Silva, 4th edn, Lippincott, Williams and Wilkins, Philadelphia, Pennsylvania, (1999).

Tan, P.; W. Sa and L. Yu, "Applying Extreme Learning Machine to classification of EEG BCI," *2016 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER)*, pp. 228-232, doi: 10.1109/CYBER.2016.7574827 (2016) .

Vetterli M.; Kovacevic J.; Goyal V. K. *Foundations of Signal Processing* (2014).

Visa S., Ramsay B., Ralescu A., Knaap E. V. D. *Confusion Matrix-based Feature Selection*. MAICS, (2011).

Winnie, K. Y. So.; Savio, W. H. Wong.; Joseph, N. Mak.; Rosa, H. M. Chan .*An evaluation of mental workload with frontal EEG*. PLOS ONE 12(4): e0174949. Acessado em: <https://doi.org/10.1371/journal.pone.0174949> (2017).

Yang L.; Shami A. *On hyperparameter optimization of machine learning algorithms: Theory and practice*. *Neurocomputing*, Volume 415, (2020), Pages 295-316, ISSN 0925-2312, <https://doi.org/10.1016/j.neucom.2020.07.061>.

Zhang YN.; Dong R.; Wu Y.; Cheng X.; Cheng C.; Xu L. Research on Classroom Attention Analysis Based on Multi-source Data Correlation. In: Wang Y., Xu L., Yan Y., Zou J. (eds) *Signal and Information Processing, Networking and Computers*. *Lecture Notes in Electrical Engineering*, vol 677. Springer, Singapore. [https://doi.org/10.1007/978-981-33-4102-9\\_108](https://doi.org/10.1007/978-981-33-4102-9_108) (2021).

Zyma, I., Tukaev S., Seleznov I., Kiyono K., Popov A., Chernykh M., Shepenkov O. *Eletroencephalograms during mental arithmetic task performance*, (2019). Acessado em: <https://doi.org/10.3390/data4010014>