

EDUARDO GIANNI DI BATTISTA

**Processamento e classificação do eeg visando a identificação do estado mental com
aplicações em *neurofeedback***

Guaratinguetá
2023

Eduardo Gianni Di Battista

Processamento e classificação do eeg visando a identificação do estado mental com aplicações em *neurofeedback*

Trabalho de Graduação apresentado ao Conselho de Curso de Graduação em Engenharia Mecânica da Faculdade de Engenharia e Ciências do Campus de Guaratinguetá, Universidade Estadual Paulista, como parte dos requisitos para obtenção do diploma de Graduação em Engenharia Mecânica.

Orientador(a): Prof.^(a) Dr.^(a) Samuel Euzedice de Lucena

Guaratinguetá
2023

D543p	<p>Di Battista, Eduardo Gianni</p> <p>Processamento e classificação do egg visando a identificação do estado mental com aplicações em <i>neurofeedback</i> / Eduardo Gianni Di Battista - Guaratinguetá, 2023.</p> <p>53 f : il.</p> <p>Bibliografia: f. 45-48</p> <p>Trabalho de Graduação em Engenharia Mecânica – Universidade Estadual Paulista, Faculdade de Engenharia e Ciências de Guaratinguetá, 2023.</p> <p>Orientador: Prof. Dr. Samuel Euzedice de Lucena</p> <p>1. Processamento de sinais. 2. Aprendizado do computador. 3. Eletroencefalografia. I. Título.</p> <p style="text-align: right;">CDU 621.381</p>
-------	-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

Luciana Máximo
Bibliotecária/CRB-8 3595

EDUARDO GIANNI DI BATTISTA

ESTE TRABALHO DE GRADUAÇÃO FOI JULGADO ADEQUADO COMO PARTE
DO REQUISITO PARA OBTENÇÃO DO DIPLOMA DE
“GRADUADO(A) EM ENGENHARIA MECÂNICA”

APROVADO EM SUA FORMA FINAL PELO CONSELHO DE CURSO DE
GRADUAÇÃO EM ENGENHARIA MECÂNICA

Prof.(^a) Dr.(^a) CELSO EDUARDO TUNA
Coordenador(a)

BANCA EXAMINADORA:



Prof.(^a) Dr.(^a) SAMUEL EUZEDICE DE LUCENA
Orientador(a)/UNESP-FEG



Prof.(^a) M^e. SOFIA GLYNIADAKIS
UNESP-FEG



Prof.(^a) Dr.(^a) EVALDO CHAGAS GOUVÊA
UNESP-FEG

AGRADECIMENTOS

Agradeço imensamente ao meu orientador, professor Samuel, pelo suporte durante o processo de elaboração do meu TCC e principalmente por ter acreditado nessa ideia. Também agradeço aos membros da banca, professores Evaldo e Sofia, pelas contribuições que enriqueceram o trabalho. Agradeço também a minha família e amigos, pela compreensão e apoio incondicional. Este trabalho não teria sido possível sem a ajuda de todos vocês.

“...saiba bem o que te apetece, e não recue
ante nenhum pretexto...”;

Friedrich Nietzsche

RESUMO

A eletroencefalografia tem sido utilizada para a análise de sinais cerebrais e desenvolvimento de sistemas *Brain Computer Interface* (BCI) por meio da medição da atividade elétrica dos neurônios a partir de eletrodos fixados no couro cabeludo humano (escalpo). Essa medição pode ser utilizada com objetivo de modular a atividade cerebral por meio de técnicas de condicionamento em uma forma de autorregulação neurofisiológica, conhecida como *neurofeedback*, a fim de produzir alterações cognitivas, motoras ou comportamentais benéficas ao indivíduo. Este trabalho promoveu analisar, em ambiente MATLAB, um sistema de classificação dos estados mentais a partir dos dados de EEG adquiridos de um paciente em repouso e seguindo um protocolo de atividade de atenção seletiva e em estado de relaxamento. Para a análise e processamento dos sinais foi utilizada a ferramenta de processamento de sinais eletrofisiológicos *EEGLab* para filtrar e caracterizar as atividades cerebrais do sinal elétrico adquirido, a ferramenta matemática Transformada *Wavelet* Discreta para a extração das características da atividade cerebral do sinal de EEG, a ferramenta de aprendizado de máquina supervisionado *Support Vector Machine* (SVM) para treinamento e classificação dos dados. Com a metodologia proposta foi possível verificar resultados em que o sistema foi capaz de adquirir, processar e classificar os sinais de forma coerente, apresentado acurácia acima de 99% para classificação dos estados de atenção e relaxamento propostos. Estes resultados sugerem a possibilidade da aplicação da metodologia proposta em um sistema de *neurofeedback* para prosseguimento em estudos sobre a eficácia da ferramenta como solução terapêutica.

PALAVRAS-CHAVE: *Neurofeedback*; EEG; Aprendizado de máquina supervisionado; *Support Vector Machine* (SVM); Transformada *Wavelet* Discreta (DWT).

ABSTRACT

Electroencephalography has been used for the analysis of brain signals and development of Brain Computer Interface (BCI) systems by measuring the electrical activity of neurons from electrodes attached to the human scalp (scalp). This measurement can be used with the aim of modulating brain activity through conditioning techniques in a form of neurophysiological self-regulation, known as neurofeedback, to produce cognitive, motor, or behavioral changes beneficial to the individual. This work promoted the analysis, in a MATLAB environment, of a mental states classification system based on EEG data acquired from a patient at rest and following a protocol of selective attention activity and in a state of relaxation. For the analysis and processing of the signals, the tool for processing electrophysiological signals EEGLab was used to filter and characterize the brain activities of the acquired electrical signal, the mathematical tool Discrete Wavelet Transform for extracting the characteristics of brain activity from the EEG signal, and the Support Vector Machine (SVM) tool of supervised machine learning for data training and classification. With the proposed methodology, it was possible to verify results in which the system was able to acquire, process and classify the signals in a coherent way, presenting accuracy above 99% for classification of the proposed states of attention and relaxation. These results suggest the possibility of applying the proposed methodology in a neurofeedback system for further studies on the tool effectiveness as therapeutical solution.

KEYWORDS: Neurofeedback; EEG; Supervised machine learning; Support Vector Machine (SVM); Discrete Wavelet Transform (DWT).

LISTA DE FIGURAS

Figura 1 – Típico sinal de EEG (a) no domínio do tempo e (b) no domínio da frequência..	19
Figura 2 – Disposição de eletrodos no Sistema Internacional 10-20.....	20
Figura 3 – Bandas características de sinais de EEG.....	21
Figura 4 – Demonstração do funcionamento de um sistema <i>neurofeedback</i>	22
Figura 5 – Visualização da Transformada de Fourier para obtenção do espectro do sinal...	25
Figura 6 – Exemplo de divisão da série temporal em uma janela de tempo.....	26
Figura 7 – Transformada de Fourier aplicada em segmentos da série temporal.....	27
Figura 8 – Exemplos de famílias de wavelets.....	29
Figura 9 – Exemplo de obtenção da primeira aproximação por filtragem do sinal com downsampling.....	30
Figura 10 – Exemplo de análise multiresolução em um sinal amostrado em 500 Hz.....	31
Figura 11 – Exemplo de hiperplanos separáveis em R^2	33
Figura 12 – Vetores suportes localizados nos hiperplanos suportes.....	33
Figura 13 – Ilustração do fluxo do sistema utilizado.....	35
Figura 14 – Posição dos eletrodos.....	36
Figura 15 – Cartas do jogo <i>Color Addict</i> utilizado no treinamento.....	37
Figura 16 – Análise de componentes independentes para remoção dos artefatos indesejados.....	38
Figura 17 – Sinal após o pré-processamento dos dados de EEG.....	39
Figura 18 – Exportação do sinal após pré-processamento dos dados.....	39
Figura 19 – Menu principal do <i>Wavelet Toolbox</i> do MATLAB.....	40
Figura 20 – Sinal decomposto em 5 níveis pela família <i>Daubechies 4</i>	41
Figura 21 – Coeficientes gerados pela decomposição do sinal em 5 níveis pela família <i>Daubechies 4</i>	41
Figura 22 – Análise de potência espectral dos dados de atenção.....	43
Figura 23 – Comparação de potência espectral entre os dados de atenção e relaxamento...	44
Figura 24 – Visualização dos dados normalizados utilizados para treinamento do classificador.....	45
Figura 25 – Visualização do resultado da classificação do teste de atenção.....	46
Figura 26 – Visualização do resultado da classificação do teste de relaxamento.....	46

SUMÁRIO

1	INTRODUÇÃO	15
1.1	OBJETIVOS.....	15
1.1.1	Objetivos específicos	16
2	FUNDAMENTAÇÃO TEÓRICA	17
2.1	<i>NEUROFEEDBACK</i>	17
2.1.1	Conceito	17
2.1.2	Registro da atividade cerebral	18
2.1.2.1	Eletroencefalografia.....	18
2.1.2.2	Posicionamento dos eletrodos.....	19
2.1.2.3	Bandas de frequência do sinal elétrico.....	20
2.1.3	Sistema	21
2.1.3.1	Treinamento de neurofeedback.....	22
2.2	PROCESSAMENTO DOS SINAIS DE EEG.....	24
2.2.1	Transformada de Fourier	24
2.2.1.1	Transformada de Fourier de curta duração.....	26
2.2.2	Transformada <i>wavelet</i>	28
2.2.2.1	Transformada discreta <i>wavelet</i>	29
2.3	CLASSIFICAÇÃO DO SINAL.....	32
2.3.1	Máquinas de vetores de suporte (SVM)	32
3	MATERIAIS E MÉTODOS	35
3.1	CONFIGURAÇÃO DOS SISTEMAS.....	35
3.2	AQUISIÇÃO DO SINAL EEG.....	36
3.2.1	Equipamentos	36
3.2.2	Aquisição da atividade cerebral	36
3.3.3	Protocolo de treinamento e teste	37
3.3	PRÉ-PROCESSAMENTO DO SINAL DE EEG.....	37
3.4	PROCESSAMENTO MATEMÁTICO DO SINAL.....	40
3.5	CLASSIFICAÇÃO DOS DADOS.....	42
4	RESULTADOS	43
4.1	CARACTERÍSTICAS DO SINAL.....	43
4.2	CLASSIFICADOR SVM.....	45
5	CONCLUSÃO	48

5.1	TRABALHO FUTUROS.....	48
	REFERÊNCIAS.....	50
	APÊNDICE A - Leitura do arquivo EDF no MATLAB.....	54
	APÊNDICE B - Criação dos vetores de características utilizando a Transformada <i>Wavelet</i>.....	55
	APÊNDICE C - Normalização dos vetores, treinamento e classificação dos dados utilizando SVM.....	56
	APÊNDICE D - Plotagem dos dados de treinamento e teste.....	57

1 INTRODUÇÃO

Sistemas de *neurofeedback* vem cada vez atraindo mais pesquisas em validações de eficiência e eficácia, principalmente devido aos recentes avanços de tecnologia em aquisições e processamento de sinais elétricos por meio de computadores (SHERLIN *et al.*, 2011), demonstrando uma multiplicidade de possíveis aplicações como ferramenta terapêutica para atividades cerebrais desviantes ou em aprimoramentos cognitivos para indivíduos saudáveis (ENRIQUEZ-GEPPERT; HUSTER; HERRMANN, 2017). Similar a um sistema BCI (*brain computer interface*) o seu funcionamento depende de um meio de captação dos sinais elétricos emitidos pelo cérebro que servirá de interface a um sistema computacional capaz de realizar o processamento do sinal.

O processamento computacional do sinal elétrico é realizado de forma a identificar e classificar padrões de sinais, determinados por critérios específicos para identificação de estados mentais, por meio de algoritmos de aprendizagem e o qual retornam ao próprio sujeito em utilização do *neurofeedback* a informação final em forma de recursos visuais e/ou sonoros para que ele tenha controle do próprio desempenho.

Sendo o EEG um exame amplamente conhecido e utilizado em aquisições de atividades cerebrais para fins de diagnósticos médicos, e, capaz de realizar um registro elétrico contínuo do cérebro podendo ser interpretado por diferentes programas de computador capazes de realizar o processamento do sinal (SUBASI AND GURSOY, 2010), o presente trabalho traz como objetivo a classificação do estado mental por meio de aprendizagem supervisionada para estudo em aplicações de *neurofeedback* a partir da análise computacional de um sinal elétrico obtido por um aparelho de EEG.

1.1 OBJETIVOS

O objetivo principal desse trabalho consiste em identificar os estados mentais de atenção e relaxamento por meio da programação de algoritmos computacionais capazes de interpretar os dados obtidos de um EEG para processamento e classificação dos sinais elétricos com o intuito de validar a possibilidade da aplicação dos dados obtidos em um sistema de *neurofeedback*.

1.1.1 Objetivos específicos

Como objetivos específicos pode-se citar:

1. Definir um protocolo para aquisição dos sinais eletroencefalográficos.
2. Realizar o pré-processamento dos sinais de EEG com o tratamento adequado para filtrar os sinais cerebrais desejados.
3. Extrair as características de ondas específicas para o estudo utilizando um algoritmo computacional capaz.
4. Aplicar um classificador de sinal aos dados obtidos por meio de aprendizagem de máquina supervisionada para identificar os padrões avaliados.
5. Avaliar os dados obtidos sobre a possibilidade de aplicação em um sistema de *neurofeedback*.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 NEUROFEEDBACK

2.1.1 Conceito

O conceito de modular a atividade cerebral por meio de técnicas de condicionamento, no qual a informação adquirida é empregada pelo próprio sujeito para que ele controle o seu desempenho, tem sido chamado de *neurofeedback* (SHERLIN *et al.*, 2011). O monitoramento e registro da atividade cerebral geralmente é realizada por um eletroencefalógrafo (EEG), porém também é conhecido a utilização de outros métodos, como imagens de ressonância magnética funcional (fMRI) (YOUNG *et al.*, 2014) ou o sistema de espectroscopia de infravermelho próximo (NIRS) (MIHARA *et al.*, 2012). O avanço da tecnologia engendrou um aumento significativo na facilidade e acessibilidade dos equipamentos necessários para o registro e análise da atividade cerebral e tornou essa técnica uma opção viável para aplicação por profissionais treinados em intervenções clínicas (SHERLIN *et al.*, 2011).

A capacidade de uma pessoa aprender e assumir o controle da sua atividade neural por meio de técnicas de condicionamento não é algo relativamente novo como alvo de estudo. Segundo Enriquez-Geppert; Huster; Herrmann (2017), desde a década de 1960 já se fazia o uso de técnicas de condicionamento operante para demonstrar a capacidade de autorregulagem da atividade neural, mostrado em pesquisas com aplicação em macacos em 1969 e posteriormente, em 1974, estudos com base em EEG estavam entre os primeiros a demonstrar a capacidade de humanos em autorregular sua atividade na banda de frequência alfa (8 – 13 Hz) por condicionamento operacional/operante, estando também entre os primeiros estudos a aplicar o *neurofeedback* como ferramenta terapêutica para epilepsia.

De acordo com Caballo; Claudino (1996), o treinamento do *neurofeedback* envolve mecanismos de aprendizagem contínua, tanto da máquina quanto do homem, mediante às modificações dos padrões cerebrais do indivíduo. Para que seja utilizado como ferramenta terapêutica como, por exemplo, visto em neuro reabilitações na aprendizagem motora em recuperação pós-AVC (ZICH *et al.*, 2015), em transtornos de déficit de atenção e hiperatividade (TDAH) (ARNS *et al.*, 2009), ou em epilepsias (EGNER, T.; STERMAN, M. B., 2006), é necessário se basear em uma relação causal entre as alterações dos padrões de

atividades cerebrais e a autorregulação por meio da alteração do comportamento a fim de produzir alterações cognitivas, motoras ou comportamentais benéficas ao indivíduo.

2.1.2 Registro da atividade cerebral

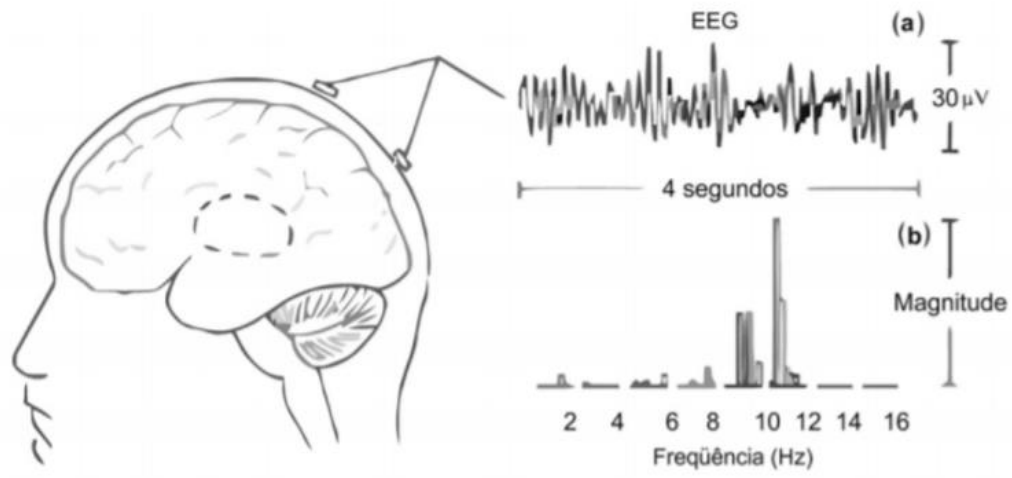
Para a interface cérebro-computador realizada no *neurofeedback* a obtenção das informações fisiológicas a serem condicionadas se torna parte essencial do processo, que pode ser captada pelo eletroencefalograma (EEG), ressonância magnética funcional (fMRI) ou ainda espectroscopia por infravermelho funcional (fNIRS). O EEG, um dos instrumentos pelo qual o *neurofeedback* obtém as informações necessárias, capta a atividade eletro cortical disponibilizando a informação da atividade cerebral.

2.1.2.1 Eletroencefalografia

Segundo Putz; Pabst (2006), eletroencefalografia é a medição da atividade elétrica dos neurônios a partir de eletrodos fixados no couro cabeludo humano (escalpo). Essa medição pode ser utilizada para o estudo das funções encefálicas ou para o diagnóstico de uma série de distúrbios como epilepsia, tumores, traumatismo e doenças degenerativas.

Diferentemente de uma abordagem invasiva, a qual requer implantes físicos dos eletrodos e possibilitando medir neurônios isolados ou potenciais de campo muito locais, o EEG também permite observar o que acontece no cérebro humano em regiões ativas, ou nas frequências cerebrais presentes, de forma não invasiva (KROPOTOV, 2009). Essa possibilidade ocorre com o uso de eletrodos condutores colados ao couro cabeludo e responsáveis por lerem os sinais elétricos relativos à atividade cerebral. Os pares de eletrodos colados registram a diferença de potencial elétrico entre eles e medem o sinal elétrico emitido, o qual é usualmente fraco, na ordem de (30-100 μ V), e, portanto, precisa ser amplificado (ALVES, 2013). Na Figura 1 é possível observar a representação de eletrodos de EEG posicionados no couro cabeludo com ilustrações dos resultados do sinal plotados no domínio do tempo e da frequência.

Figura 1 – Típico sinal de EEG (a) no domínio do tempo e (b) no domínio da frequência.




Fonte: Tong; Thakor (2009).

2.1.2.2 Posicionamento dos eletrodos

O condicionamento dos eletrodos no couro cabeludo deve respeitar um padrão de posicionamento, como, por exemplo, o padrão do Sistema Internacional 10-20, recomendado pela Federação Internacional das Sociedades de Eletroencefalografia e Neurofisiologia Clínica. Segundo Niedermeyer; Silva (2005), esse sistema é composto por 21 pontos que são marcados dividindo o crânio em proporções de 10% ou 20% do comprimento das distâncias entre os pontos de referência, *násio* e *ínio* no plano medial e os pontos pré-auriculares no plano perpendicular ao crânio. Para facilitar o mapeamento topográfico da atividade EEG, é identificado por uma nomenclatura formada de máximo 2 letras, sendo o lóbulo que está por baixo de cada eletrodo juntamente com um número ou uma outra letra para identificar a sua posição hemisférica. O uso desse sistema de porcentagens permite padronizar a colocação dos eletrodos independentemente do tamanho do crânio do indivíduo, como no caso da grande diferença entre crianças e adultos, por exemplo (JASPER, 1958). A Figura 2 apresenta uma ilustração da disposição de eletrodos seguindo o Sistema Internacional 10-20.

Figura 2 – Disposição de eletrodos no Sistema Internacional 10-20.



Fonte: Casagrande (2019).

2.1.2.3 Bandas de frequência do sinal elétrico

Segundo Florisbal (2021), usualmente na área clínica o sinal de EEG é caracterizado em faixas de frequências definidas por: bandas *alfa*, *beta*, *theta* e *delta*, e são as principais bandas avaliadas em estudos clássicos de sinais de eletroencefalografia. Com base nas faixas de frequência, os sinais EEG, divididos nessas cinco bandas, são descritos a seguir (NOACHTAR *et al.*, 1999).


- **Atividade Delta (δ):** ondas eletromagnéticas variando entre 0,5 e 3 Hz em frequência e entre 100 e 200 μV em amplitude. Em um estado consciente, a maioria dos adultos não exhibe quase nenhuma atividade *delta*; em vez disso, essa atividade ocorre quando em um sono profundo, inconsciente, anestesiado ou sem oxigênio.
- **Atividade Theta (θ):** ondas eletromagnéticas variando entre 4 e 7 Hz em frequência, com uma amplitude de menos de 30 μV . Esta atividade ocorre principalmente nas regiões parietal e temporal do cérebro. Tais ondas são produzidas quando as pessoas experimentam pressão emocional, interrupções da consciência ou relaxamento físico profundo.
- **Atividade Alfa (α):** ondas eletromagnéticas variando entre 8 e 13 Hz em frequência, e entre 30 e 50 μV em amplitude. Este tipo de onda periódica é

produzido nas regiões parietal e occipital do cérebro quando em estado de consciência, quieto ou em repouso. Ao piscar, as ondas *alfas* desaparecem. Isso é conhecido como um bloqueio alfa.

- **Atividade Beta (β):** ondas eletromagnéticas variando entre 14 e 30 Hz em frequência, e entre 5 e 20 μ V em amplitude. Esse tipo de atividade ocorre na região frontal quando as pessoas estão conscientes e alertas. Essas ondas são particularmente evidentes quando uma pessoa está pensando ou recebendo estímulo sensorial.
- **Atividade Gama (γ):** ondas eletromagnéticas variando entre 31 e 50 Hz em frequência, e entre 5 e 10 μ V em amplitude. A atividade *gama* está relacionada à atenção seletiva e estados alterados de consciência.

Na Figura 3 é mostrada uma representação típica do sinal de EEG para as faixas de frequência *beta*, *alfa*, *theta* e *delta*.

Figura 3 – Bandas características de sinais de EEG.




Fonte: Espinelli (2011).

2.1.3 Sistema

De acordo com Florisbal (2021), a partir de um sistema EEG pode ser definida uma determinada classificação do sinal obtido por meio de estímulos que incitam certos padrões de atividade em determinadas regiões do cérebro. Toda forma natural de comunicação e controle necessita de nervos periféricos e de músculos onde processos complexos são gerados no cérebro a partir da intenção do usuário, ativando e produzindo padrões em determinadas áreas, esses sinais são enviados pelo sistema nervoso periférico para assim gerar uma saída motora (GRAIMANN; ALLISON; PFURTSCHELLER, 2009).

Similar a um sistema BCI, o *neurofeedback* realiza três funções básicas: Inicialmente são captados os sinais elétricos, provenientes das atividades corticais e subcorticais ao nível do escalpo, por meio de um eletroencefalograma, por exemplo. Devido a amplitude dos sinais de EEG ser de apenas alguns microvolts antes da aquisição dos sinais cerebrais é necessário um processo de amplificação do sinal antes da sua digitalização e a aplicação de filtros para prevenir o sistema contra ruídos provenientes da rede elétrica. Ao passar pelos amplificadores os sinais são digitalizados e processados e nesse momento são realizadas as extrações das características relevantes dos sinais e a sua classificação. Por fim, é dado o *feedback* dos sinais já classificados ao sujeito de forma visual, tátil, auditiva ou uma combinação dos mesmos (PEEK, 1995). A Figura 4 apresenta a ilustração de um sistema de *neurofeedback* permitindo visualizar o fluxo necessário das informações para seu funcionamento.

Figura 4 – Demonstração do funcionamento de um sistema *neurofeedback*.



Fonte: Paz (2017).

2.1.3.1 Treinamento de *neurofeedback*

Segundo Paz (2011), o treino de *neurofeedback* trabalha de forma dinâmica no córtex pois induz ao participante um aumento, ou diminuição, do ritmo e da amplitude em uma faixa de onda específica de uma região do córtex, essa alteração na faixa de onda pode ocorrer simultaneamente em regiões diferentes do córtex. Uma visão mais ampla do treino de *neurofeedback* é fornecida pelo modelo cognitivo de Lacroix (1986), no qual se verifica que as modificações das ondas cerebrais ocorrem não só por meio do feedback sonoro ou visual, mas também pela modificação da percepção do sujeito acerca do seu estado fisiológico, o qual promove uma integração cognitiva do comportamento condicionado.

Uma das questões primordiais em relação ao treinamento é o tempo que o sistema demanda desde a captação dos sinais até o *feedback* oferecido. Com o aumento do tempo o processo de aprendizagem tem menor eficiência, uma vez que o sujeito tem maior dificuldade em estabelecer uma relação entre o seu estado e os comportamentos necessários para a modificação da informação recebida, sendo que a agilidade do sistema é um fator crítico e indispensável para o treinamento *neurofeedback* (APPOLINÁRIO, 2001).

Para determinar a duração da sessão é necessário verificar a capacidade do indivíduo em se concentrar no treinamento, quanto maior a duração da sessão mais difícil será permanecer focado. Porém em sessões de menor duração é necessário tomar o cuidado para que o treinamento não finalize enquanto o indivíduo está imerso na tarefa. A duração da sessão média em estudos terapêuticos é de cerca de 20 a 40 minutos (ENRIQUEZ-GEPPERT; HUSTER; HERRMANN, 2017).

Segundo Drechsler *et al.* (2007), existem três tipos de treinamentos mais difundidos que: treino *theta/beta*, treino ritmo sensorial-motor (SMR) e treino de potenciais corticais lentos (*slow cortical potentials* – SCP's). Para pacientes com TDAH, por exemplo, o treinamento mais utilizado é o *theta/beta*, que consiste em diminuir a atividade da banda *theta* e aumentar a atividade da banda *beta*, por meio do condicionamento resultante do *neurofeedback*, com o objetivo de reduzir a desatenção e a impulsividade característico desses pacientes.

2.2 PROCESSAMENTO DOS SINAIS DE EEG

Segundo Casagrande (2019), o processamento de sinais consiste na análise e modificação de sinais por meio de transformações matemáticas direcionadas a extrair informações-chaves que não estavam disponíveis no sinal original, e, com isso, atribuir uma aplicação específica. Referente a aquisição de dados do EEG, de acordo com Ocazionez (2009), é necessário adotar uma frequência mínima de amostragem do sinal como uma taxa de 200 Hz de forma a satisfazer o teorema de Nyquist, em que a quantidade de amostras por unidade de tempo de um sinal (frequência de amostragem) deve ser maior que o dobro da maior frequência contida no sinal a ser amostrado para que esse possa ser reproduzido integralmente. Na prática, os sinais do EEG, que são plotados no domínio do tempo (variável independente) e no domínio da amplitude (variável dependente), precisam ser processados pois a informação dos componentes espectrais está contida na frequência do sinal.

Para medir e identificar o conteúdo da frequência de um sinal, existem ferramentas matemáticas específicas desenvolvidas para análise de sinais, como por exemplo, a transformada de Fourier de curta duração, transformada *wavelet* contínua e a transformada *wavelet* discreta.

2.2.1 Transformada de Fourier

O progresso da atividade computacional permitiu aos neurocientistas quantificar, por meio de métodos de análise espectral, as componentes das frequências cerebrais contidas em exames de eletroencefalografia (FLORES VEGA, 2010). A transformada de Fourier, que leva o nome do físico francês Joseph Fourier, autor da Teoria Analítica do Calor de 1822 e desenvolveu diversas pesquisas na área de processamento de sinais, segundo seu teorema, foi demonstrado que todo sinal periódico pode ser expresso por uma somatória de ondas seno e cosseno, com suas amplitudes, fases e frequências, e que somadas reproduzem o sinal original (SHIRADO *et al.*, 2015). De acordo com Flores Vega (2010), inicialmente esse método resolveu o problema de quantificar o espectro da frequência do sinal, estando juntamente com o método da transformada rápida de Fourier entre os mais utilizados na análise de sinais.

A transformada de Fourier é uma ferramenta que permite determinar a contribuição que cada função seno e cosseno, presentes em uma série temporal, apresenta para a energia


total desta série (BARBOSA e BLITZKOW, 2008). A transformada de Fourier é definida da seguinte forma:

$$F(\omega) = \int_{-\infty}^{+\infty} f(t)e^{-j2\pi\omega t} dt \quad (1)$$

Onde $F(\omega)$ é a série temporal ou sinal analisado, ω é a frequência de cada componente oscilatório inerente ao sinal (representa as diferentes frequências contidas na série) e a exponencial transforma para o espaço das frequências.

Os sinais representados no tempo mostram o momento em que ocorrem os eventos observados, porém sinais que são representados no domínio da frequência correspondem à quantidade de vezes que um evento ocorreu dado um determinado período (AMARAL, 2019). Na Figura 5 é possível verificar uma representação do efeito da transformada de Fourier, na qual é responsável por transformar os sinais no domínio do tempo para o domínio da frequência.

Figura 5 – Visualização da transformada de Fourier para obtenção do espectro do sinal.



Fonte: Amaral (2019).

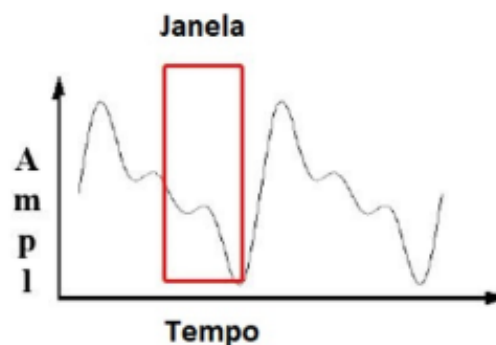
Como visto no exemplo da Figura 5, com a análise de Fourier em um sinal periódico é possível verificar informações sobre a frequência global do sinal, porém não é possível localizar mudanças rápidas de frequências, não permitindo, conseqüentemente, a retirada acerca da localização temporal das frequências detectadas. Por ser um método que pressupõe

o uso de um sinal estacionário, se limitando, portanto, ao uso de sinais onde o espectro da frequência não varia ao longo do tempo, esse tipo de método dificilmente se viabiliza em análise de sinais eletroencefalográficos. Para solucionar esse problema, foi desenvolvida uma variante da transformada original, a transformada de Fourier de curta duração. Esse método foi desenvolvido de modo a associar um dado instante de tempo a um segmento a fim de se aplicar a transformada a cada segmento e permitindo observar as mudanças de frequência no tempo.

2.2.1.1 Transformada de Fourier de curta duração

Proposto por Denis Gabor em 1946, o método da transformada de Fourier de curta duração (STFT) foi elaborado para efetuar análises em sinais não estacionários como forma de superar a deficiência encontrada na transformada de Fourier (CASAGRANDE, 2019). Este método foi proposto com o objetivo de identificar aspectos temporais de uma determinada região do sinal, consistindo em dividir a série temporal em intervalos iguais e aplicar a transformada de Fourier em cada um destes trechos por meio de uma janela $h(t)$ de tamanho fixo e constante por todo o sinal. A Figura 6 apresenta um exemplo com uma ilustração da aplicação de uma janela $h(t)$ em um sinal periódico.

Figura 6 – Exemplo de divisão da série temporal em uma janela de tempo.



Fonte: Casagrande (2019).


Este método considera a multiplicação do sinal por um segmento no intervalo de tempo antes do cálculo da transformada de Fourier, considerando o sinal como estacionário localmente (OCAZIONEZ, 2009).

$$F(\omega, \tau) = \int_{-\infty}^{+\infty} h(t - \tau)x(t)e^{-j2\pi\omega t} dt \quad (2)$$

Na equação acima o parâmetro τ define a localização do intervalo de interesse, podendo ser deslocado ao longo de todo o sinal $x(t)$.

O funcionamento da transformada de Fourier de curta duração é apresentado na Figura 7 com um exemplo de série temporal dividido em cinco segmentos com intervalos iguais de tempo, contendo cada segmento três segundos de duração, onde em seguida foi aplicada a transformada em cada um deles.

Figura 7 – Transformada de Fourier aplicada em segmentos da série temporal.



Fonte: Barbosa; Blitzkow (2008).

Conforme visto na Figura 7, é possível notar a presença de diferentes frequências de cada segmento definido em suas respectivas localizações temporais. Ou seja, nos primeiros oito segundos se verifica a presença de três frequências (1 Hz, 5 Hz e 10 Hz), enquanto nos oito últimos segundos estão presentes apenas as frequências de 1 Hz e 10 Hz. A transformada de Fourier de curta duração contribuiu para o estudo e análise de séries temporais não-estacionárias. Entretanto, ainda permaneceram dois problemas a serem resolvidos:

1. O tamanho do segmento permanece fixo, causando uma limitação que não possibilita modificar o tamanho dela após o início de sua aplicação na série analisada, percorrendo todo o sinal sem a possibilidade de ser ajustada aos trechos particulares da função.

2. As funções trigonométricas possuem energia infinita, ou seja, elas são limitadas entre $-\infty$ e $+\infty$.

A necessidade de desenvolver função matemática que possuísse energia finita, e que essa função fosse capaz de dilatar ou comprimir, eliminando o problema de o segmento temporal ser fixo, partiu de um geofísico chamado Jean Morlet, em 1982, ao tentar resolver dois problemas em séries temporais de ecos geofísicos na busca de poços petrolíferos. Juntamente com Alex Grossman, eles construíram as bases matemáticas da teoria de *onduletas*, referindo-se à “pequenas ondas” (BARBOSA; BLITZKOW, 2008).

2.2.2 Transformada *wavelet*

O princípio básico da transformada *wavelet* é similar ao da transformada de Fourier, porém ao invés de utilizar uma combinação ponderada de senoides infinitas são utilizadas funções do tipo finitas, conhecidas como *wavelets* (*onduletas*) (CASAGRANDE, 2019). As *wavelets* são funções que oscilam por um curto período possuindo um valor médio zero, geralmente irregulares e assimétricas, transformando o sinal em uma combinação ponderada de versões de diferentes escalas e posições da *wavelet* original, a *wavelet*-mãe. Dessa forma, a análise com *wavelets* significa que o sinal será comparado com uma *wavelet*-mãe a qual será esticada ou comprimida e atrasada ou adiantada diversas vezes (MISITI *et al.*, 2009).

Representadas por $\psi_{a,b}$ e obtidas por meio de dilatações e deslocamentos da *wavelet*-mãe, representada por ψ , a equação da transformada *wavelet* segue a seguinte equação abaixo, onde a pertence aos números reais e realiza a dilatação da função ψ e b , também pertencente aos números reais, realiza o deslocamento da função. Já o termo $1/\sqrt{a}$ realiza o efeito de normalização para que todas as *wavelets*, derivadas da *wavelet*-mãe, tenham a mesma energia (COSTA, 2008).

$$\psi_{a,b} = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (3)$$


Para que uma onda seja considerada uma *wavelet*, é necessário que em princípio ela cumpra a condição de média zero, expressa pela equação abaixo.

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (4)$$

Essa condição define que nem toda onda pode ser considerada como *wavelet* (OCAZIOEZ, 2009). Atualmente, para o cálculo da transformada, existem algumas

famílias de *wavelets* que foram construídas e podem ser consideradas de acordo com diferentes aplicações. Na Figura 8 é apresentado algumas *onduletas* como exemplo de famílias de *wavelets*.

Figura 8 – Exemplos de famílias de *wavelets*.



Fonte: CASAGRANDE (2019).

A Equação 5 apresenta a condição da energia unitária, a qual também deve ser satisfeita para que a função seja considerada como *wavelet*.

$$\int_{-\infty}^{+\infty} |\psi(t)|^2 dt = 1 \quad (5)$$

Segundo Ocazionez (2009), se tratando de processamento de sinais biológicos, uma variação da transformada *wavelet* chamada transformada discreta *wavelet* (DWT) tem sido uma importante ferramenta utilizada em trabalhos de reconhecimento do nível de atenção em humanos, em estudos dos efeitos de campos eletromagnéticos de baixa frequência em EEG e ECG, ou em procedimentos que trazem uma melhor identificação de potenciais evocados devidos a estímulos auditivos. A transformada discreta *wavelet* utiliza versões discretizadas *wavelets* definidas por meio de algoritmos, porém também é possível a utilização de bancos de filtros para uma boa aproximação da transformada.

2.2.2.1 Transformada discreta *wavelet*

Conforme apresentado por Costa *et al.* (2010), a transformada discreta *wavelet* permite a análise de um determinado sinal em diferentes níveis de resolução de tempo e frequência

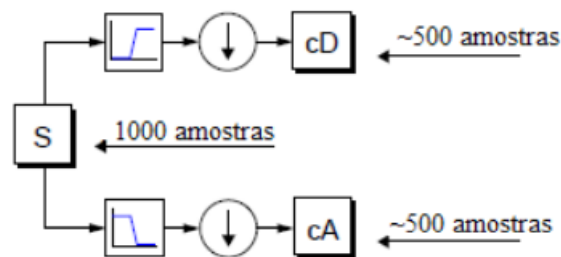
pela análise de multiresolução e se mostrou apropriada à detecção e localização de transitórios em componentes de baixa e alta frequência.

De forma geral, a DWT consiste em escolher subconjuntos das escalas e posições da *wavelet*-mãe $\psi(t)$, essa escolha dos parâmetros de dilatação (a) e deslocamento (b) são baseadas em potência de dois, sendo possível construir uma *wavelet* para qualquer função conforme apresentado na equação abaixo (CASAGRANDE, 2019).

$$\psi_{a,b}(t) = 2^{\frac{a}{2}}\psi\left(2^{-\frac{a}{2}}(t - b)\right) \quad (6)$$

As versões compactadas da função *wavelet* correspondem às componentes de alta frequência, enquanto as versões dilatadas correspondem às componentes de baixa frequência. Ao correlacionar o sinal original com funções *wavelet* de tamanhos diferentes os detalhes do sinal podem ser obtidos em várias escalas, essas funções *wavelet* correlacionadas podem ser organizadas em uma decomposição de resolução múltipla. Conforme apresentado no esquema abaixo, a decomposição DWT de um sinal utiliza sucessivos filtros passa-altas e baixas na filtragem das séries temporais e dois *downsamplers* para evitar a obtenção de dois sinais com o mesmo número de amostras do sinal inicial (SUBASI, 2007). Na Figura 9 é apresentado um esquema da obtenção de aproximação de um sinal de 500 amostras por filtragem do sinal com *downsampling*.

Figura 9 – Exemplo de obtenção da primeira aproximação por filtragem do sinal com *downsampling*.

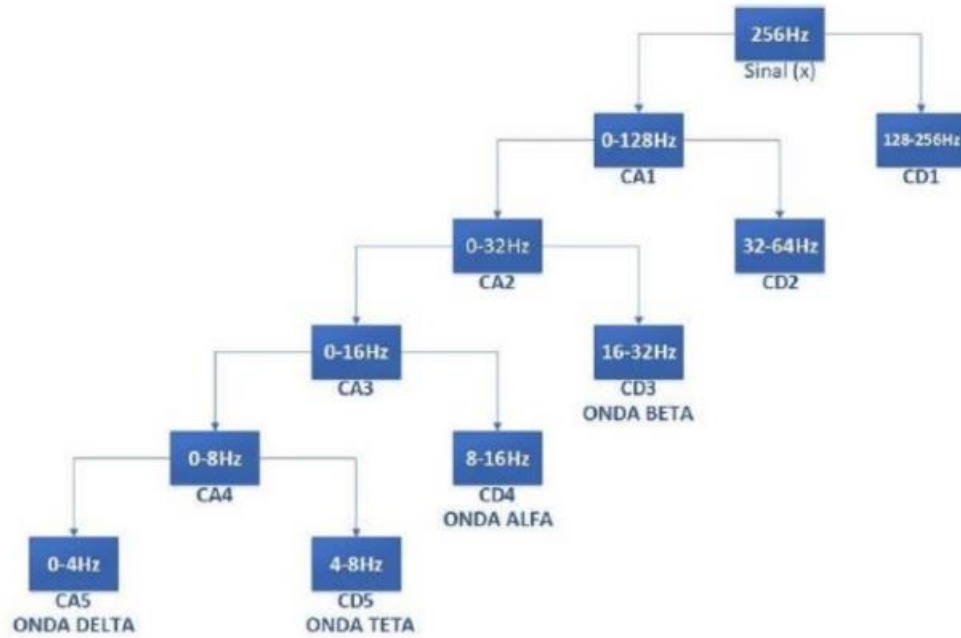


Fonte: Ocazionez (2009).

A análise multiresolução fornece a separação de um sinal em aproximações permitindo uma alta resolução no tempo e baixa escala para altas frequências, e, simultaneamente, uma baixa resolução no tempo e alta escala para baixas frequências. Esse método se mostrou útil em abordagens de componentes com alta frequência que duram pouco tempo e componentes de baixa frequência que duram um longo tempo. Na Figura 10 é apresentado um esquema de

análise em multiresolução de um sinal amostrado em 256 Hz resultando nas faixas de frequência para cada nível de detalhe.

Figura 10 – Exemplo de análise multiresolução em um sinal amostrado em 256 Hz.



Fonte: Casagrande (2019).

2.3 CLASSIFICAÇÃO DO SINAL


A escolha de um classificador adequado ao sistema de *neurofeedback* é fundamental dado que pelas características do sistema esse processamento precisa ser rápido e robusto, pois, conforme apresentado acima, por se tratar de um sistema dinâmico é necessário que as informações retornem ao usuário o mais breve possível para que se tenha o efeito de condicionamento esperado. Segundo Barbosa (2012), existem dois classificadores que se encaixam nesse perfil, o MLP (Redes de *Perceptron* Multicamadas) e o SVM (Máquinas de Vetores de Suporte). O MLP é um modelo de rede neural artificial com estratégia de aprendizado supervisionado por meio de camadas de nós adicionais (chamadas de neurônios), responsáveis pela computação dos dados de entrada, essas camadas adicionais permitem cálculos mais complexos do que em redes neurais de uma única camada tornando possível a resolução de problemas não linearmente separáveis, contudo, para que esses problemas sejam resolvidos se faz necessário um algoritmo de retropropagação do erro (*backpropagation*).

Conforme descrito por Almeida (2021), o SVM tende a apresentar uma maior capacidade de generalização, e, portanto, um melhor desempenho frente aos dados de teste quando comparado com redes neurais em virtude do princípio da minimização do risco estrutural (SRM), método que pode ser superior ao ERM (*Empirical Risk Minimization*), teoria que embasa projetos de redes neurais como o método de treinamento MLP.

2.3.1 Máquinas de vetores de suporte (SVM)

O SVM é um algoritmo de aprendizado de máquina baseado na teoria de aprendizado estatístico cuja principal característica é a sua capacidade de encontrar um hiperplano ótimo que maximiza a margem de separação dos dados em duas classes, essa classificação ocorre em um espaço de alta dimensionalidade, aquele de margem máxima que divide duas classes de maneira mais significativa (ALMEIDA, 2021). A Figura 11 exemplifica um conjunto linearmente separável em R^2 e os diferentes hiperplanos possíveis.

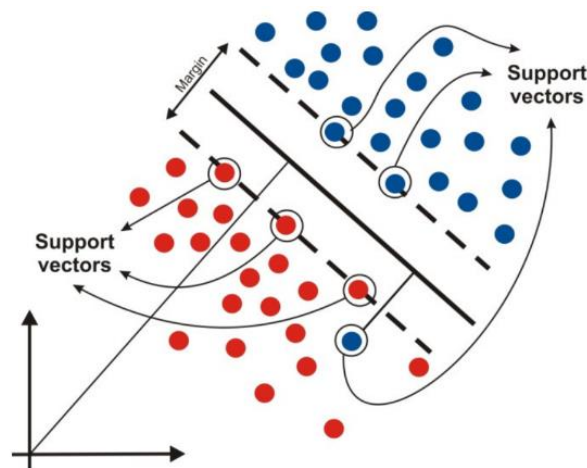
Figura 11 – Exemplo de hiperplanos separáveis em R^2 .



Fonte: Almeida (2021).

Com a restrição de utilização apenas dos vetores suportes localizados nas fronteiras entre as classes (hiperplanos suportes), um de seus principais fundamentos, o SMV é capaz de ignorar *outliers* e calcular um hiperplano ótimo por meio da otimização de um problema restrito (ALMEIDA, 2021). A Figura 12 apresenta um exemplo de dados separados por um hiperplano otimizado por vetores de suporte.

Figura 12 – Vetores suportes localizados nos hiperplanos suportes.



Fonte: Kanda (2013).

Com a aplicação de uma estrutura conhecida como núcleo, ou *kernel*, é possível mapear os dados de entrada em um espaço de características (mapeamento entre o espaço de baixa e alta dimensionalidade) e converter um problema não linear em padrões de maior

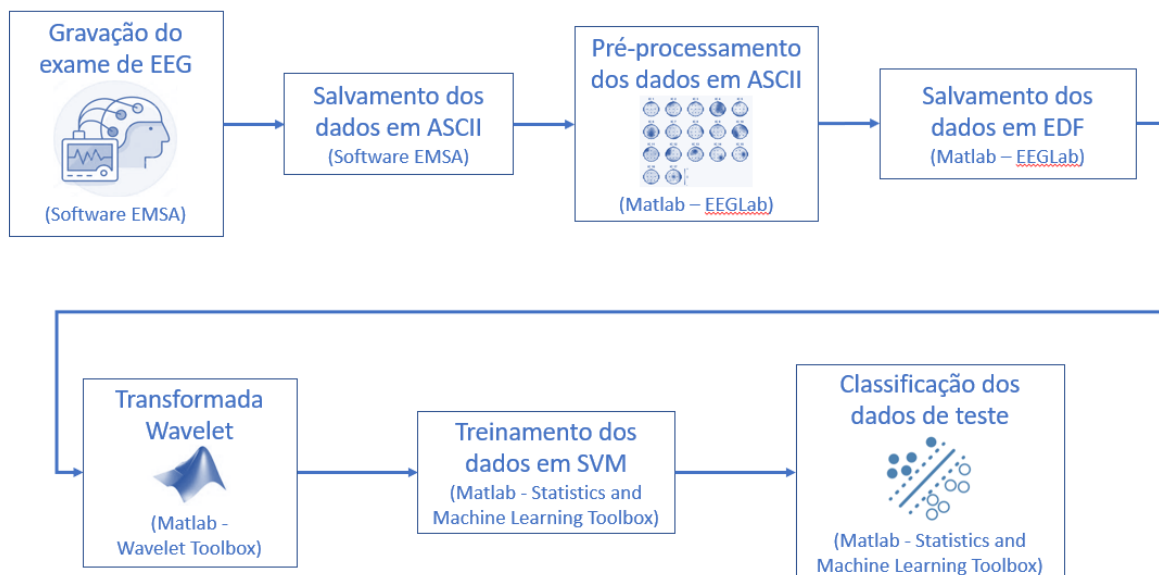
probabilidade de serem linearmente separáveis. Essa função recebe dois pontos do espaço de entrada e calcula o produto escalar entre eles no espaço de características retornando ao espaço de entrada um hiperplano de superfície não-linear. Os três tipos de *kernel* mais comuns são o *Linear* (default do software MATLAB), o *Polinomial* no qual a ordem do polinômio é um parâmetro definido, e o *RBF* em que a largura da função gaussiana é o parâmetro definido pelo usuário (BARBOSA, 2012).

3 MATERIAIS E MÉTODOS

3.1 CONFIGURAÇÃO DOS SISTEMAS

Com o objetivo de avaliar os dados obtidos após processamento e classificação do sinal de EEG quanto à possibilidade de aplicação em um sistema de *neurofeedback* o trabalho foi realizado seguindo uma configuração “*offline*” dos sistemas nos quais cada etapa foi tratada separadamente, sem a comunicação entre si dos *softwares* utilizados. Conforme apresentado no capítulo dois, espera-se que o sistema de *neurofeedback* funcione de forma contínua e em tempo real alimentando o usuário com informações sobre o seu desempenho de forma a se obter o condicionamento do comportamento esperado por meio de treinamentos. Devido a intenção de validar os métodos utilizados neste trabalho optou-se por essa configuração “*offline*” na qual seria possível analisar cada etapa separadamente, para isso foi necessário a transferência manual dos dados obtidos entre os programas, salvando os dados no computador para posterior utilização nas etapas subsequentes. Na Figura 13 é apresentada a configuração geral dos sistemas e fluxos utilizados.

Figura 13 – Ilustração do fluxo do sistema utilizado.



Fonte: Elaborado pelo autor

3.2 AQUISIÇÃO DO SINAL EEG

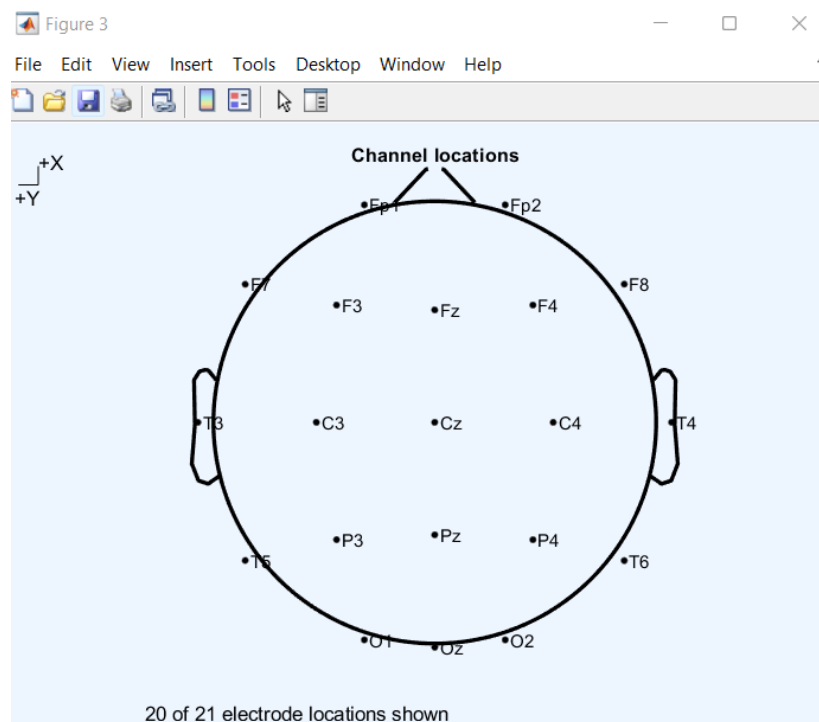
3.2.1 Equipamentos

Para os registros do EEG quantitativo utilizou-se um equipamento digital da marca EMSA, com 20 canais, resolução de 12 *bits*, frequência de amostragem de 200 Hz e filtro *notch* de 60 Hz para eliminação de ruídos da rede elétrica. Foi utilizado o próprio *software* da EMSA capacitado a realizar a aquisição dos dados de EEG, com a disponibilidade de salvamento dos dados em formato ASCII, o qual foi utilizado para o tratamento matemático no software MATLAB após o registro do exame.

3.2.2 Aquisição da atividade cerebral

A colocação dos elétrodos de escalpo (F7, T3, T5, Fp1, F3, C3, P3, O1, F8, T4, T6, Fp2, F4, C4, P4, O2, Fz, Cz, Pz, Oz) seguiu as normas da Sociedade Brasileira de Neurofisiologia Clínica (sistema 10-20). Os registros foram obtidos com o paciente em vigília e repouso, com olhos abertos e o tempo total de aquisição do exame foi de, aproximadamente, 30 minutos.

Figura 14 – Posição dos eletrodos.



Fonte: Elaborado pelo autor

3.2.3 Protocolo de treinamento e teste

O treinamento de atenção consistiu em uma tarefa que avalia a função de atenção seletiva usando o paradigma descrito por Campanholo *et al.* (2014). Para o treino foi utilizado o jogo *Color Addict* da fabricante Copag, que consiste em um baralho com 110 cartas onde cada uma exibe uma palavra com o nome de uma cor, de forma aleatória, e essa mesma palavra é colorida com uma cor, também aleatória. A Figura 15 mostra a imagem jogo utilizado para o treinamento de atenção. A tarefa executada nesse jogo compreendeu em inibir o processo automático de leitura da carta para falar a cor apresentada.

Foram gravados 3 treinos curtos com tempo de 30 segundos cada para ser utilizado posteriormente como treinamento dos dados de aprendizagem supervisionada. Em seguida foram gravados 3 treinos, de aproximadamente 3 minutos cada, utilizando o baralho inteiro que servirão como os dados de teste a serem identificados posteriormente pelo classificador.

Figura 15 – Cartas do jogo *Color Addict* utilizado no treinamento.



Fonte: Elaborado pelo autor

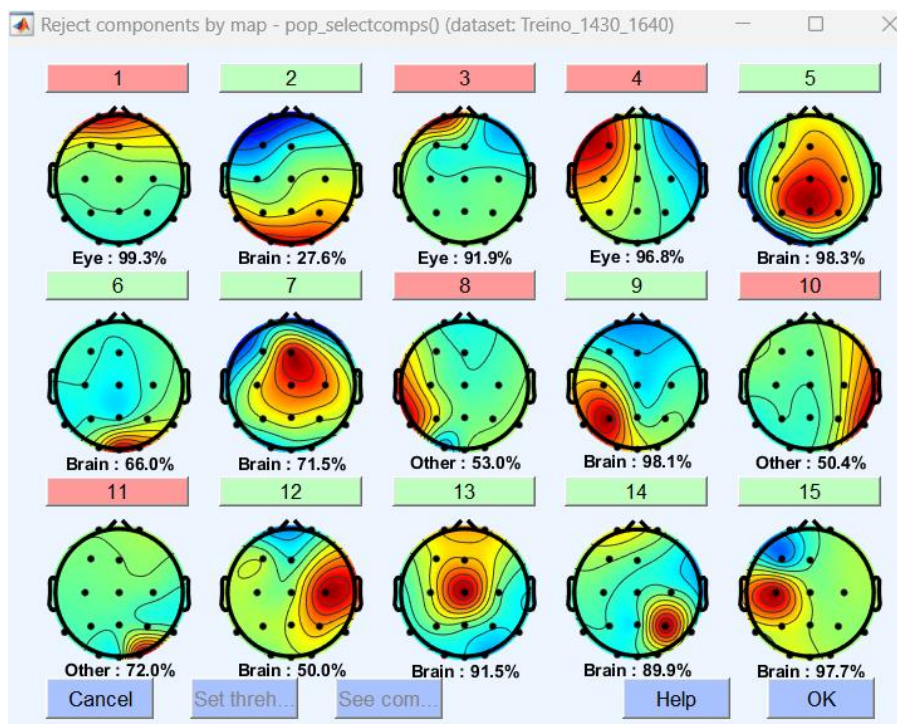
3.3 PRÉ-PROCESSAMENTO DO SINAL DE EEG

Para o pré-processamento do sinal foi utilizado o *EEGLab*, ferramenta de processamento de sinais eletrofisiológicos contínuos, no ambiente do *software* MATLAB 2022a. O *EEGLab* é uma ferramenta é disponibilizada pelo *Swartz Center for Computational Neuroscience*, que é um centro de pesquisas do Instituto de Computação Neuronal (*Institute for Neural Computation*) da Universidade da Califórnia San Diego, sob as condições gerais de uma licença pública. O *toolbox* pode ser executado sobre diversas plataformas e sistemas operacionais, tais como: Linux, Unix, Windows, e Mac OSX (SANTOS, 2014).

Por meio das funcionalidades da ferramenta foram selecionados os períodos de dados dos melhores treinos e testes realizados na etapa anterior e em seguida foi aplicado um filtro passa-banda de 1-40 Hz para ser utilizado em todos os sinais, dessa forma, o filtro removeu todas as frequências abaixo de 1 e acima de 40 Hz, removendo as frequências que não estão na região de interesse do EEG.

Dentro da banda selecionada os fragmentos foram submetidos ao algoritmo *Infomax* (Runica) para serem decompostos em fontes de atividades independentes. Na Figura 16 é apresentado os componentes que foram removidos (em vermelho) por apresentarem características de biopotenciais não desejados.

Figura 16 – Análise de componentes independentes para remoção dos artefatos indesejados.




Fonte: Elaborado pelo autor

Os componentes que se caracterizavam com biopotenciais não desejados, como movimentos de contração muscular da face, ombro, mandíbula, movimento dos olhos e outros, foram removidos por meio de análises estatísticas do dado original. A Figura 17 apresenta o sinal após o pré-processamento em vermelho, e em azul o sinal original, ficando no eixo vertical os componentes identificados e no eixo horizontal o tempo em segundos.

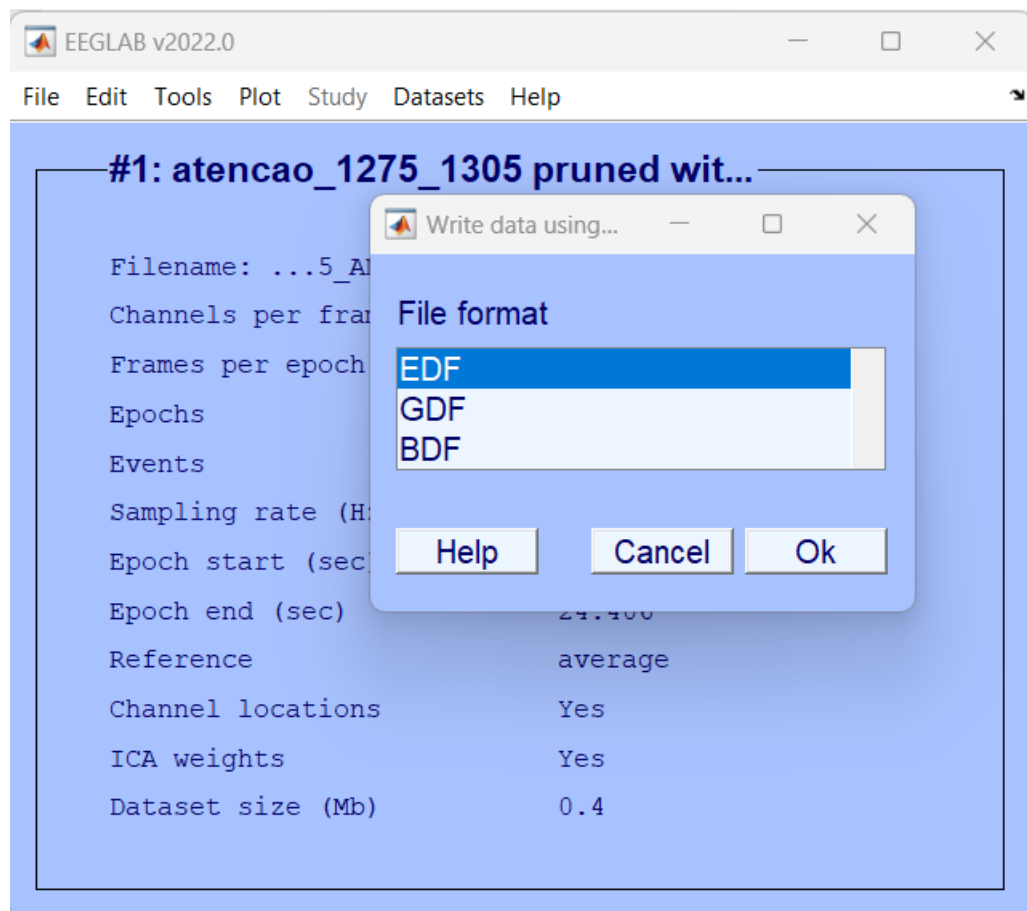
Após o pré-processamento do sinal, os dados foram salvos no formato EDF utilizando a ferramenta de exportação do *EEGLab*, apresentada na Figura 18.

Figura 17 – Sinal após o pré-processamento dos dados de EEG.



Fonte: Elaborado pelo autor.

Figura 18 – Exportação do sinal após pré-processamento dos dados.



Fonte: Elaborado pelo autor.

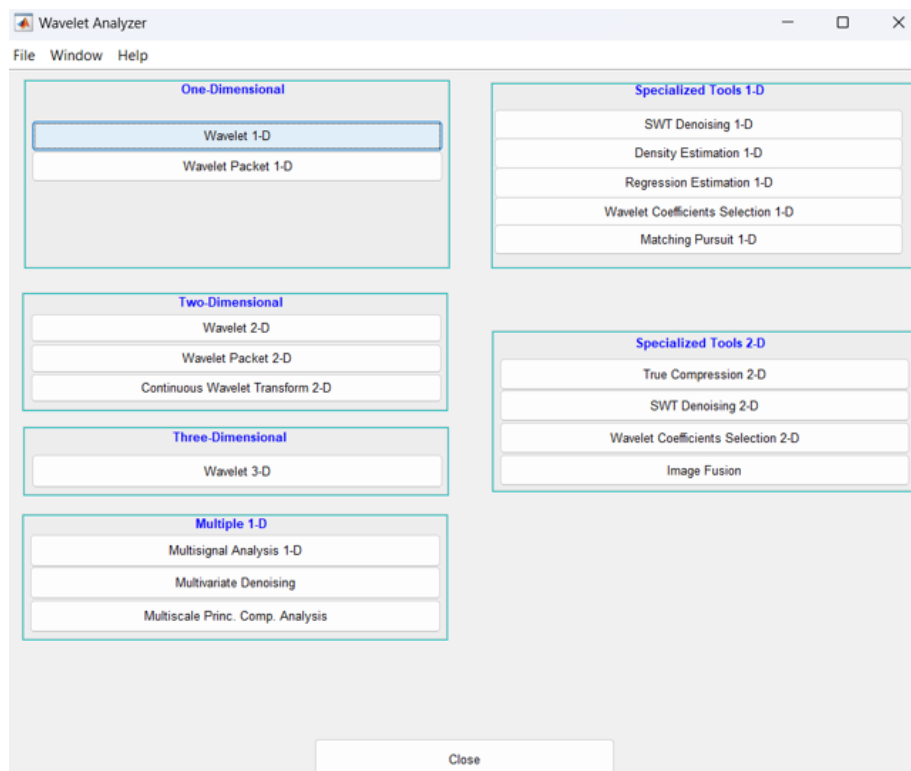
3.4 PROCESSAMENTO MATEMÁTICO DO SINAL

O próximo passo foi carregar os dados já pré-processados, por meio da função *edfRead* apresentada no código do Apêndice A, para posteriormente realizar a transformada *wavelet* discreta passando por um conjunto de filtros passa-alta e passa-baixa para que os coeficientes *wavelet* possam ser calculados. As decomposições foram realizadas em 5 níveis com as *wavelets Daubechies 4* (db4) gerando cinco coeficientes de detalhe (D1, D2, D3, D4 e D5) e um coeficiente de aproximação (A5).

Esse processamento do sinal foi realizado utilizando o MATLAB R2022a, com as funções presentes na *wavelet toolbox*. Essa ferramenta é composta por várias opções de processamento e aplicações para analisar e sintetizar sinais, imagens e dados que possuem comportamento regular pontuado com mudanças abruptas, incluindo algoritmos para a transformada *wavelet* contínua (CWT) e algoritmos de visualizações de 18 *wavelets* discretas (DWT), permitindo revelar padrões variáveis no tempo comuns em múltiplos sinais (ARAUJO, 2018).

A análise pela DWT ocorreu por meio do comando *wavemenu* dentro do *comand window* utilizando a opção *Wavelet 1-D*, conforme mostrado na Figura 19.

Figura 19 - Menu principal do *wavelet toolbox* do MATLAB.




Fonte: Elaborado pelo autor.

Na Figura 20 é apresentada a tela do *software* com a decomposição do sinal em 5 níveis plotados na dimensão de amostras pela tensão, sendo de $d1$ até $d5$ (em verde) os 5 níveis de detalhe do sinal e $a5$ (em azul) a aproximação do sinal.

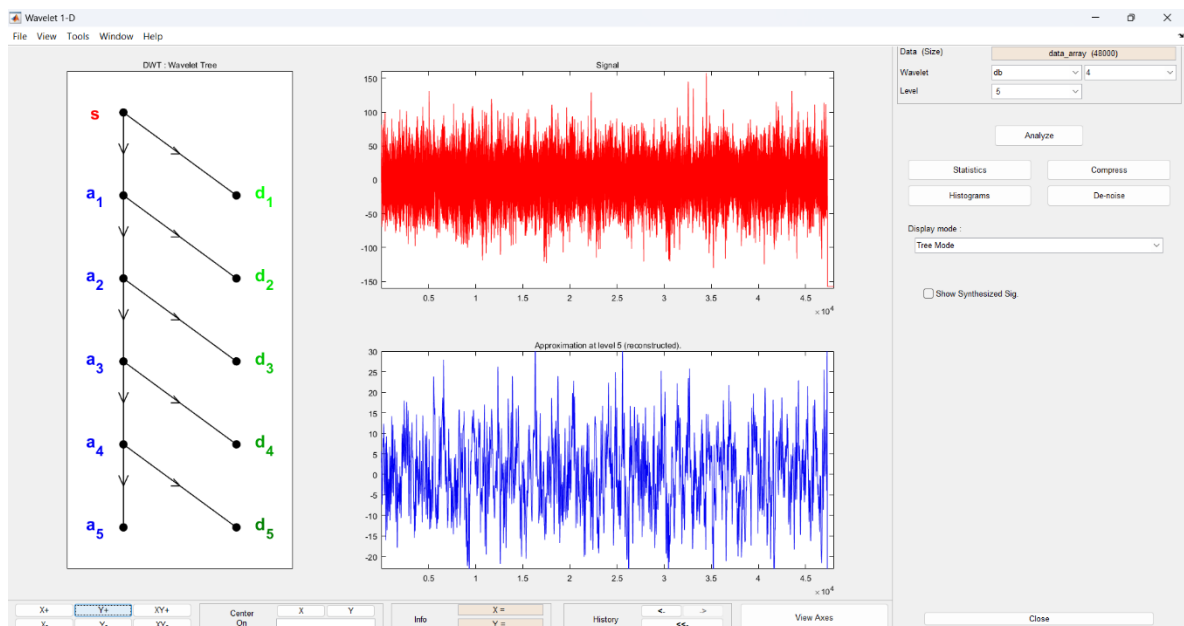
Na Figura 21 é possível observar a tela do *software* com o detalhamento dos coeficientes gerados pela decomposição.

Figura 20 - Sinal decomposto em 5 níveis pela família *Daubechies 4*.



Fonte: Elaborado pelo autor.

Figura 21 - Coeficientes gerados pela decomposição do sinal em 5 níveis pela família *Daubechies 4*.



Fonte: Elaborado pelo autor.

Baseando-se nos valores gerados em cada um dos seis coeficientes (A5, D5, D4, D3, D2 e D1) da transformada *wavelet* discreta, foi criado, a cada 1 segundo (200 amostras), um vetor com características de média, desvio padrão, máximo e mínimo, conforme apresentado no exemplo das variáveis abaixo.

- $mediaA5$ = média entre os valores do coeficiente A5
- $desvpadA5$ = desvio padrão entre os valores do coeficiente A5
- $maximoA5$ = valor máximo entre os valores do coeficiente A5
- $minimoA5$ = valor mínimo entre os valores do coeficiente A5

Para essa etapa foi utilizado o código do Apêndice B para obtenção dos resultados da transformada discreta *wavelet* e criação dos vetores de características.

3.5 CLASSIFICAÇÃO DOS DADOS

Nesta etapa, os vetores de características foram normalizados em intervalos entre -1 a $+1$, para melhor desempenho do classificador SVM, tanto para a etapa de treinamento quanto de teste. O classificador foi treinado e avaliado com base nos vetores de características normalizados gerados na etapa anterior utilizando principalmente o *kernel linear* e *polinomial* para comparação. Após o treinamento, o classificador rotulou a amostra de teste do EEG em *Atenção* [+1] ou *Relaxamento* [-1].

No Apêndice C é apresentado o código utilizado nesta etapa de normalização, treinamento e classificação dos dados de teste. Todos esses passos foram realizados utilizando o pacote de ferramentas *Statistics and Machine Learning Toolbox* disponível para o *software* MATLAB.

Posteriormente, os dados de treinamento de *Atenção* e *Relaxamento* foram plotados em um gráfico com a identificação dos vetores de suporte juntamente com os dados de teste já classificados pelo algoritmo em *Atenção* ou *Relaxamento*. Para esta última etapa, foi utilizado o código apresentado no Apêndice D para criação dos gráficos.


4 RESULTADOS

4.1 CARACTERÍSTICAS DO SINAL

Anteriormente ao cálculo do vetor de características, que seriam utilizados posteriormente no treinamento do classificador, se fez necessário verificar se os dados disponíveis após a gravação do exame de EEG e o processamento do sinal estavam adequados em relação aos filtros aplicados e se as bandas de frequência estavam de acordo com os estados de atenção e relaxamento. Para isso, foi verificada a potência espectral para cada um dos sinais.

Na Figura 22 é mostrada a análise de potência espectral do sinal na qual é possível verificar a predominância dos valores de potência nas faixas de frequência entre 1 e 40 Hz.


Figura 22 – Análise de potência espectral dos dados de atenção.



Fonte: Elaborado pelo autor.

Para validar se os sinais correspondentes aos estados de atenção e relaxamento estavam em níveis diferentes para que fosse possível realizar o treinamento do classificador os trechos referentes a cada estado foram plotados na análise de potência espectral para a comparação dos dados. Na Figura 23 é mostrado o trecho do sinal para o estado de atenção em laranja e o sinal para o estado de relaxamento em roxo, sendo possível a verificação das diferenças de potência para cada banda de frequência. Neste caso é verificado uma menor potência para o estado de relaxamento, e em específico para a faixa de frequência entre 30 e 40 Hz, região de atividade gama (γ), principalmente relacionada à atenção seletiva.

Figura 23 – Comparação de potência espectral entre os dados de atenção e relaxamento.



Fonte: Elaborado pelo autor.

Após a verificação de potência dos sinais, os vetores de características foram calculados por meio do código, verificado no apêndice B, utilizando a transformada *wavelet* para cada trecho dos estados de atenção e relaxamento. As Tabelas 1 e 2 apresentam os valores calculados de média, desvio padrão, máximo e mínimo de cada um dos 6 coeficientes encontrados para estados de atenção e relaxamento, respectivamente. Os coeficientes de detalhe são representados pelos prefixos cDi_db sendo i o nível do detalhe, e o prefixo $cA5_db$ representa o coeficiente de aproximação.

Tabela 1 – Coeficientes do vetor de características dos dados de atenção

Característica	cA5_db	cD5_db	cD4_db	cD3_db	cD2_db	cD1_db
MÉDIA	-6,05E+07	-1,85E+06	9,00E+04	-6,28E+04	-3,41E+04	3,52E+02
DESvio PADRÃO	4,07E+08	1,20E+08	7,57E+07	5,69E+07	2,87E+07	8,48E+06
MAX	6,59E+08	1,47E+09	8,01E+08	6,21E+08	1,60E+08	2,63E+08
MIN	-3,09E+09	-7,93E+08	-8,18E+08	-4,08E+08	-2,11E+08	-2,45E+08

Fonte: Produção do próprio autor.

Tabela 2 – Coeficientes do vetor de características dos dados de relaxamento


Característica	cA5_db	cD5_db	cD4_db	cD3_db	cD2_db	cD1_db
MÉDIA	-1,25E+07	-1,95E+06	3,46E+05	1,73E+06	-7,13E+03	7,20E+03
DESvio PADRÃO	1,34E+08	7,85E+07	4,84E+07	4,43E+07	2,26E+07	4,79E+06
MAX	3,24E+08	2,76E+08	1,92E+08	2,30E+08	1,15E+08	9,78E+07
MIN	-1,01E+09	-4,57E+08	-1,76E+08	-1,76E+08	-1,30E+08	-9,89E+07

Fonte: Produção do próprio autor.

4.2 CLASSIFICADOR SVM

A partir dos dados normalizados dos vetores de características para os estados de atenção e relaxamento foi realizado o treinamento do classificador SVM utilizando o *kernel linear* e o *kernel polinomial* para verificação de diferenças na acurácia da classificação entre os dois métodos. Nesta etapa o classificador foi treinado com aproximadamente 720 dados de *input* oriundos da matriz de vetores de características, considerando 30 segundos de teste e vetores de características com 24 coeficientes resultando em uma matriz 30 x 24. Na Figura 24 é apresentada a visualização dos dados de treinamento utilizando o *kernel linear* plotados em um gráfico onde os eixos horizontal e vertical representam os valores normalizados dos coeficientes. Os pontos em vermelho representam os dados referentes ao estado de atenção e em azul os do estado de relaxamento, também é possível observar os pontos utilizados como vetores de suporte pelo classificador representados pelo círculo preto ao redor do ponto.

Figura 24 – Visualização dos dados normalizados utilizados para treinamento do classificador.




Fonte: Elaborado pelo autor.

Após o treinamento do classificador foi utilizado um trecho correspondente ao teste de atenção e outro de relaxamento para que o SVM fizesse a predição da classificação. A Figura 25 apresenta o resultado da classificação pelo SVM para o teste de atenção e a Figura 26 apresenta o resultado do trecho de teste para o estado de relaxamento. Os dados foram plotados no mesmo gráfico apresentado na Figura 24 sendo que os quadrados em vermelho


claro representam a classificação pelo SVM em um estado de atenção e os quadrados em azul claro representam a classificação em um estado de relaxamento.

Figura 25 – Visualização do resultado da classificação do teste de atenção.



Fonte: Elaborado pelo autor.

Figura 26 – Visualização do resultado da classificação do teste de relaxamento.



Fonte: Elaborado pelo autor.

A Tabela 3 apresenta os resultados da acurácia do classificador calculada para cada um dos testes dos estados de atenção e relaxamento utilizando o *kernel linear* e o *kernel polinomial* para comparação.

Tabela 3 - Acurácia do classificador utilizando *kernel linear* e *polinomial*

Teste	<i>Kernel Linear</i>	<i>Kernel Polinomial</i>
ATENÇÃO	99,01%	100,00%
RELAXAMENTO	100,00%	100,00%

Fonte: Produção do próprio autor.

5 CONCLUSÃO

Os resultados de extração de características dos sinais de EEG mostraram que o protocolo de treinamento utilizado para gravar o exame e o método para o processamento do sinal foram adequados apresentando padrões de ondas cerebrais que se diferenciaram entre si para os estados de atenção e relaxamento ao apresentar alterações suficientes nas características de seus coeficientes para que os dados fossem utilizados em um classificador SVM.

O algoritmo de aprendizado de máquina utilizado para treinamento e classificação dos dados se mostrou coerente ao classificar os testes de atenção e relaxamento com acurácia mínima de 99,01%, indicando que os vetores de características extraídos dos coeficientes foram suficientes para realizar a classificação entre os dois estados.

A aplicação dos métodos propostos resultou em um procedimento capaz de identificar os estados mentais de atenção e relaxamento, conforme proposto inicialmente, e com resultados comparáveis aos obtidos na literatura referenciada, trazendo então a possibilidade de ser adaptado para a utilização na implementação de um sistema baseado em *neurofeedback*.

5.1 TRABALHO FUTUROS

Para que a implementação da metodologia apresentada seja realizada em um sistema de *neurofeedback* se faz a sugestão de algumas adequações em trabalhos futuros.

Primeiramente, devido ao seu funcionamento em tempo real, é necessário que haja uma integração direta dos dados gravados com o EEG com o algoritmo de processamento. Diferentemente da metodologia apresentada, onde os dados foram gravados e posteriormente inseridos no *software* de processamento, neste momento será necessário adaptar o método para a utilização de uma ferramenta capaz de realizar a comunicação de séries temporais em tempo real entre os dispositivos e programas, como por exemplo o *Lab Streaming Layer*, que ficaria responsável pela comunicação entre a aquisição dos dados, o processamento e o *game* escolhido como *output* do sistema *neurofeedback*.

Outra adequação pode ser realizada no protocolo de treinamento e teste no momento da aquisição dos dados. Devido a ampla possibilidade de utilização como ferramenta terapêutica do *neurofeedback* o protocolo para aquisição dos dados pode ser alterado de forma a refletir exatamente os padrões de ondas cerebrais que se deseja reforçar no paciente, nesse momento é sugerido que a gravação do treinamento seja realizada de forma similar

entre os estados que se deseja diferenciar, por exemplo, ambos os estados de relaxamento e atenção devem ser gravados com o paciente recebendo estímulos visuais, sem se movimentar ou falar durante o exame para que aumente a precisão do classificador em relação ao comportamento que se pretende reforçar. Nesse momento, uma consideração importante pode ser identificar outras possibilidades de uso para o sistema sugerido, como por exemplo identificação de estados mentais para aplicações pré-cirúrgicas para se confirmar um estado anestesiado do paciente antes do prosseguimento da cirurgia.

Para as etapas de processamento e classificação do sinal também é sugerido o estudo de outros *softwares* além do MATLAB devido ao custo operacional de licença. Opções de programação gratuitas como a linguagem *Python* ou *softwares* como *scilab* ou *gnuoctave* também podem ser opções para substituir o MATLAB. Uma outra consideração importante ne ponto seria estudar a quantidade mínima de eletrodos para se obter resultados de classificação satisfatórios, por se tratar de um equipamento com eletrodos aplicados no couro cabeludo do paciente, uma menor quantidade poderia simplificar o exame trazer maior conforto ao paciente durante sua aplicação.

Tal metodologia aplicada aqui, ao ser aplicada com as devidas adequações, sugere o prosseguimento como uma oportunidade de aprofundamento no estudo sobre a eficácia da ferramenta como solução terapêutica ao ser realizado com acompanhamento profissional da área médica, permitindo capacitar o estudo em relação a escolha dos trechos de atividade cerebral captados pelo EEG a serem utilizados como reforçador durante o procedimento do *neurofeedback*.

REFERÊNCIAS

- ALMEIDA, W. F. **Técnicas de aprendizado de máquina para interfaces cérebro-computador baseadas em EEG.** 2021. Dissertação (Mestrado em Sistemas de Informação) - Escola de Artes, Ciências e Humanidades, Universidade de São Paulo, São Paulo, 2021. Disponível em: doi:10.11606/D.100.2021.tde-20062021-211101. Acesso em: 14 nov. 2022.
- ALVES, L. S. Medição de biopotenciais: o estado da arte. **Instrumentação Física: medição de biopotenciais**, Porto Alegre, 2013.
- AMARAL, R. H. O. **Classificação de sinais de eeg em atividades de imagética motora com a transformada wavelet.** 2019. Trabalho de Conclusão de Curso (Graduação em Engenharia Biomédica) - Universidade Federal do Rio Grande do Norte, Natal, Rio Grande do Norte, 2019.
- APPOLINÁRIO, F. **Avaliação dos efeitos do treinamento em neurofeedback sobre o desempenho cognitivo de adultos universitários.** Tese (Doutorado em Psicologia) - Universidade de São Paulo, 2001.
- ARAÚJO, A. C. C. P. S. **Comparação de famílias wavelets para denoising de imagens mamográficas digitais.** 2018. Trabalho de Conclusão de Curso (Graduação em Engenharia Biomédica) - Universidade Federal de Uberlândia, Uberlândia, 2019.
- ARNS, M. *et al.* Efficacy of neurofeedback treatment in adhd: the effects on inattention, impulsivity and hyperactivity: a meta-analysis. **Clinical EEG and Neuroscience**, Los Angeles, v. 40, n. 3, p. 180–189, 2009. Disponível em: <https://doi.org/10.1177/155005940904000311>. Acesso em: 25 out. 2022.
- BARBOSA, A. C.; BLITZKOW, D. **Onduletas: histórico e aplicação.** São Paulo, 2008.
- BARBOSA, A. F. **Um sistema inteligente de classificação de sinais de EEG para interface cérebro-computador.** 2012. Dissertação (Mestrado em Automação e Sistemas; Engenharia de Computação; Telecomunicações) - Universidade Federal do Rio Grande do Norte, Natal, 2012.
- CABALLO, V. E.; CLAUDINO, M. D. **Manual de técnicas de terapia e modificação do comportamento.** São Paulo: Editora Santos, 1996.
- CAMPANHOLO, K. R. *et al.* Performance of an adult brazilian sample on the trail making test and stroop test. **Dementia & Neuropsychologia**. São Paulo, v. 8, n. 1, p. 26-31, 2014. Disponível em: <https://doi.org/10.1590/S1980-57642014DN81000005>. Acesso em: 25 out. 2022.
- CASAGRANDE, W. D. **Identificação de estado mental de atenção através do EEG para treinamento com neurofeedback.** 2019. Dissertação (Mestrado em Engenharia Elétrica.) - Universidade Federal do Espírito Santo – UFES, 2019.

COSTA, F. B. *et al.* Transformada wavelet discreta aplicada ao diagnóstico de distúrbios. **SBSE - Simpósio Brasileiro de Sistemas Elétricos**, Belém, n. 3, p. 47, 2010.

COSTA, M. V. C. **Compressão de sinais de eletromiografia explorando correlação bidimensional**. 2008. Dissertação (Mestrado em Engenharia Elétrica) - Universidade de Brasília, Brasília, 2008.

DRECHSLER, R. *et al.* Controlled evaluation of a neurofeedback training of slow cortical potentials in children with attention deficit/hyperactivity disorder (adhd). **Behavioral And Brain Functions**, Londres, v. 3, n. 1, p. 35, 2007.

EGNER, T.; STERMAN, M. B. Neurofeedback treatment of epilepsy: from basic rationale to practical application. **Expert Review of Neurotherapeutics**, Londres, v. 6, n.2, p. 247-257, 2006. Disponível em: DOI: 10.1586/14737175.6.2.247. Acesso em: 14 nov. 2022.

ENRIQUEZ-GEPPERT, S.; HUSTER, R. J.; HERRMANN, C. S. Eeg-neurofeedback as a tool to modulate cognition and behavior: a review tutorial. **Frontiers in human neuroscience**, Genebra, v. 11, p. 51, 2017. Disponível em: <https://doi.org/10.3389/fnhum.2017.00051>. Acesso em: 27 out. 2022.

FLORES VEGA, C. H. **Reconhecimento de estados cognitivos em sinas EEG**. 2010. Dissertação (Mestrado em Sistemas Eletrônicos) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2010. Disponível em: doi:10.11606/D.3.2010.tde-11082010-171552. Acesso em: 31 out. 2022.

FLORISBAL, G. C. **Análise e classificação de sinais de EEG a partir de movimentação passiva em pacientes sedados**. 2021. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) - Universidade Federal Do Rio Grande Do Sul – UFRGS, 2021.

GRAIMANN, B.; ALLISON, B.; PFURTSCHELLER, G. **Brain-computer interfaces: a gentle introduction**. Berlim: Springer, 2009.

JASPER, H. H. The ten-twenty electrode system of the international federation. **The International Federation of Clinical Neurophysiology**, Vancouver, v. 10, p. 370–375, 1958. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/10590970/>. Acesso em: 25 out. 2022.

KROPOTOV, J. **Qualitative EEG, event related potentials and neuropathy**. San Diego: Academic Press, 2009.

LACROIX J. M. **Mechanisms of biofeedback control: consciousness and self-regulation**. Boston: Springer, 1986.

MIHARA, M. *et al.* Neurofeedback using real-time near-infrared spectroscopy enhances motor imagery related cortical activation. **PloS one**, Tóquio, v. 7, n. 3, p. e32234, 2012. Disponível em: <https://doi.org/10.1371/journal.pone.0032234>. Acesso em: 26 out. 2022.

MISITI, M. *et al.* **Wavelet toolbox™ 4**. Natick: The Mathworks, Inc, 2009.

NIEDERMEYER, E.; SILVA, F. L. **Electroencephalography**: basic principles, clinical applications, and related fields. 5. ed. Lippincott Williams & Wilkins, 2005.

NOACHTAR, S. *et al.* **A glossary of terms most commonly used by clinical electroencephalographers and proposal for the report form for the EEG findings**. The international federation of clinical neurophysiology. *Electroencephalography and clinical neurophysiology. Supplement*, v. 52, p. 21–41, 1999. Disponível em: https://www.researchgate.net/publication/12710323_A_glossary_of_terms_most_commonly_used_by_clinical_electroencephalographers_and_proposal_for_the_report_form_for_the_EEG_findings_The_International_Federation_of_Clinical_Neurophysiology. Acesso em: 25 nov. 2022.

OCAZIONEZ, S. A. C. **Processamento no domínio da frequência de sinais de eletroencefalografia coletados durante protocolo de estresse moderado**. 2009. Dissertação (Mestrado em Engenharia Elétrica) - Universidade de Brasília, Brasília, 2009.

PAZ, V. K. C. **Efeito do treino de neurofeedback em idosos sobre a memória operacional**: um estudo encefalográfico. 2017. Dissertação (Mestrado em Biologia Animal) - Universidade de Brasília, 2017.

PEEK, C. J. **A primer of biofeedback instrumentation**. Guilford Press, 1995.

PUTZ, R.; PABST, R. **Sobotta-atlas of human anatomy**: head, neck, upper limb, thorax, abdomen, pelvis, lower limb. Elsevier, 2006.

SANTOS, P. H. B. N. D. **Estudo de técnicas de processamento de sinais de eletroencefalograma (eeg) com enfoque em sinais convulsivos**. Relatório do Trabalho de Conclusão de Curso II - Centro Federal de Educação Tecnológica de Minas Gerais, Belo Horizonte – Minas Gerais, 2014.

SHERLIN, L. H. *et al.* Neurofeedback and basic learning theory: implications for research and practice. **Journal of Neurotherapy**, Londres, v. 15, n. 4, p. 292-304, 2011. Disponível em: https://www.researchgate.net/publication/235660267_Neurofeedback_and_Basic_Learning_Theory_Implications_for_Research_and_Practice. Acesso em: 25 out. 2022.

SHIRADO, W. *et al.* Estudo comparativo entre algoritmos das transformadas discretas de Fourier e wavelet. **Revista Brasileira de Computação Aplicada**, Londrina, v. 7, n. 3, p. 97-107, 2015. Disponível em: <http://dx.doi.org/10.5335/rbca.2015.4880>. Acesso em: 29 out. 2022.

SUBASI, A. Eeg signal classification using wavelet feature extraction and a mixture of expert model. **Expert Systems with Applications**, Sarajevo, v. 32, n. 4, p. 1084–1093, 2007.

SUBASI, A.; GURSOY, M. I. Eeg signal classification using PCA, ICA, LDA and support vector machines. **Expert Systems with Applications**, Sarajevo, v. 37, n. 12, P 8659-8666, 2010. Disponível em: <https://doi.org/10.1016/j.eswa.2010.06.065>. Acesso em: 25 out. 2022.

YOUNG, K. D. *et al.* Real-time fmri neurofeedback training of amygdala activity in patients with major depressive disorder. **PloS one**, Catalunha, v. 9, n. 2, p. e88785, 2014. Disponível em: <https://doi.org/10.1371/journal.pone.0088785>. Acesso em: 10 out. 2022.

ZICH, C. *et al.* Wireless eeg with individualized channel layout enables efficient motor imagery training. **The International Federation of Clinical Neurophysiology**, Vancouver, v. 126, n. 4, p. 698-710, 2015.

BIBLIOGRAFIA CONSULTADA

CARVALHO, J. B. **Classificador máquina de suporte vetorial com análise de Fourier aplicada em dados de EEG e EMG**. 2016. Dissertação (Mestrado em Matemática Aplicada e Estatística) - Centro de Ciências Exatas e da Terra, Universidade Federal do Rio Grande do Norte, Natal, 2016.

ESPINELLI, J. H. C. **Uso do eletroencefalograma e instrumentação virtual para análise do perfil do sono**. 2011. Trabalho de Graduação (Graduação em Engenharia de Controle e Automação) - Universidade Estadual Paulista “Júlio de Mesquita Filho”, 2011.

KANDA, P. A. M. **Análise de wavelets com máquina de vetor de suporte no eletroencefalograma da doença de Alzheimer**. 2013. Tese (Doutorado em Neurologia) - Faculdade de Medicina, University of São Paulo, São Paulo, 2013. doi:10.11606/T.5.2013.tde-12042013-105244. Acesso em: 14 nov. 2022.

RODRIGUES, S. D. L. **Diagnóstico da doença de Alzheimer em intervalos de curta duração utilizando o EEG**. 2012. Dissertação (Mestrado em Tecnologia Biomédica) - Instituto Politécnico de Bragança, Escola Superior de Tecnologia e Gestão, 2012. <http://hdl.handle.net/10198/8013>. Acesso em: 31 out. 2022.

TONG, S.; THAKOR, N. V. **Quantitative EEG analysis methods and clinical applications**. Boston: Artech House, 2009.

APÊNDICE A – Leitura do arquivo EDF no MATLAB

```
% Leitura de todos os canais do arquivo .EDF no MATLAB
```

```
data = edfread('Atenção.edf');
```

```
% Conversão do formato tabela (timetable) criado pelo software em formato de vetor
```

```
data_cellarray = table2array(data);
```

```
% Conversão do vetor em formato de matriz
```

```
data_array_atencao = cell2mat(data_cellarray);
```

APÊNDICE B – Criação dos vetores de características utilizando a Transformada Wavelet

```

% carrega os dados de atencao
data_array = transpose(data_array_atencao);

% calcula o comprimento do sinal para ser utilizado no laço de repetição FOR
N = length(data_array)/200;

% faz a varredura do sinal a cada 200 amostras (1 segundo)
for i = 1:N
A_trechos = data_array(:,(i-1)*200+1:i*200);

% transforma a matriz em um vetor linha
A_t = transpose(A_trechos);
B = reshape(A_t,1,[]);

% aplica a Transformada Wavelet utilizando a Família "db4"
% cria os coeficientes cA5, cD5, cD4, cD3, cD2 e cD1 em C1 dos 5 níveis de
decomposição e indica o comprimento de cada um deles em L1
[C1,L1] = wavedec(B,5,'db4');

% extrai o coeficiente de aproximação cA5
cA5_db = appcoef(C1,L1,'db4',5);

% extrai os coeficientes de detalhe cD5, cD4, cD3, cD2 e cD1
cD5_db = detcoef(C1, L1, 5);
cD4_db = detcoef(C1, L1, 4);
cD3_db = detcoef(C1, L1, 3);
cD2_db = detcoef(C1, L1, 2);
cD1_db = detcoef(C1, L1, 1);

%% cria o Vetor de Características - Família "db4"
% calcula a média, desvio padrão, valor máximo e valor mínimo para cada um dos 6
coeficientes gerados e cria o vetor de características para o treinamento e teste no SVM (24
características)
vc_db_atencao (i,:) = [mean(cA5_db) mean(cD5_db) mean(cD4_db) mean(cD3_db) ...
mean(cD2_db) mean(cD1_db) std(cA5_db) std(cD5_db) std(cD4_db) ...
std(cD3_db) std(cD2_db) std(cD1_db) max(cA5_db) max(cD5_db) max(cD4_db) ...
max(cD3_db) max(cD2_db) max(cD1_db) min(cA5_db) min(cD5_db) min(cD4_db) ...
min(cD3_db) min(cD2_db) min(cD1_db)];

end % encerra loop FOR

```

APÊNDICE C – Normalização dos vetores, treinamento e classificação dos dados utilizando SVM

```

% carrega os vetores de características de treinamento e teste
load('vc_db_teste')
load('vc_db_atencao')
load('vc_db_relax')

% carrega as classes referentes a cada linha, [1] para atenção e [-1] para relaxamento
load('vc_label_atencao')
load('vc_label_relax')

% faz a normalização (escalonamento) dos vetores de características de atenção no
intervalo entre [-1 e 1]
v = vc_db_atencao;
a = max (v(:));
b = min (v(:));
vx = 2* v / (a-b);
c = min (vx(:));
vc_n_atencao = vx - (c + 1); % vetor normalizado de treinamento

% faz a normalização (escalonamento) dos vetores de características de relaxamento no
intervalo entre [-1 e 1]
w = vc_db_relax;
c = max (w(:));
d = min (w(:));
wx = 2* w / (c-d);
d = min (wx(:));
vc_n_relax = wx - (d + 1); % vetor normalizado de treinamento

% faz a normalização (escalonamento) dos vetores de características de teste no intervalo
entre [-1 e 1]
x = vc_db_teste;
e = max (x(:));
f = min (x(:));
xx = 2* x / (e-f);
g = min (xx(:))
vc_n_teste = xx - (g + 1); % vetor normalizado de teste

% empilha os vetores de características normalizados de atenção e relaxamento
train_data = [vc_n_atencao;vc_n_relax];
% empilha as classes de atenção e relaxamento
train_label = [vc_label_atencao;vc_label_relax];

% realiza o treinamento do classificador com kernel 'linear'
SVMModel = fitcsvm(train_data, train_label,'KernelFunction','linear','Solver','SMO');

% classifica os dados de teste a partir do classificador treinado anteriormente
test_data = vc_n_teste;
[label, score] = predict(SVMModel, test_data);

```

APÊNDICE D – Plotagem dos dados de treinamento e teste

```

% plota os dados de treino e vetores suporte
X = train_data;
y = train_label;
sv = SVMModel.SupportVectors;
figure
gscatter(X(:,1),X(:,2),y)
hold on
plot(sv(:,1),sv(:,2),'ko','MarkerSize',10)

% plota os dados de teste classificados pelo SVM
dd = test_data
tic;[label, score] = predict(SVMModel, dd);toc
pos = find(label==1);
hold on;
redcolor = [1 0.8 0.8];
bluecolor = [0.8 0.8 1];
h1 =
plot(dd(pos,1),dd(pos,2),'s','color',redcolor,'MarkerSize',10,'MarkerEdgeColor',redcolor,'Ma
rkerFaceColor',redcolor);
pos = find(label==-1);
hold on;
h2 =
plot(dd(pos,1),dd(pos,2),'s','color',bluecolor,'MarkerSize',10,'MarkerEdgeColor',bluecolor,'
MarkerFaceColor',bluecolor);

% insere legenda no gráfico
legend('Treino em Relaxamento','Treino em Atenção','Vetores Suportes','Teste em
Atenção','Teste em Relaxamento')
uistack(h1, 'bottom');
uistack(h2, 'bottom');

```