

Wagner Dias Casagrande

**Identificação de Estado Mental de Atenção
Através do EEG para Treinamento com
Neurofeedback**

Vitória - ES

2019

Wagner Dias Casagrande

Identificação de Estado Mental de Atenção Através do EEG para Treinamento com Neurofeedback

Dissertação submetida ao programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para a obtenção do Grau de Mestre em Engenharia Elétrica.

Universidade Federal do Espírito Santo – UFES
Programa de Pós-Graduação em Engenharia Elétrica

Orientador: Dr. Anselmo Frizera Neto

Vitória - ES

2019

Ficha catalográfica disponibilizada pelo Sistema Integrado de
Bibliotecas - SIBI/UFES e elaborada pelo autor

C334i Casagrande, Wagner dias, 1993-
Identificação de estado mental de atenção através do EEG para
treinamento com neurofeedback. / Wagner dias Casagrande. -
2019.
70 f. : il.

Orientador: Anselmo Frizera Neto.
Dissertação (Doutorado em Engenharia Elétrica) -
Universidade Federal do Espírito Santo, Centro Tecnológico.

1. Eletroencefalografia. 2. Fourier, Transformadas de. 3.
Aprendizado do computador. 4. Distúrbio do déficit de atenção
com hiperatividade. 5. Biofeedback - Treinamento. I. Frizera
Neto, Anselmo. II. Universidade Federal do Espírito Santo.
Centro Tecnológico. III. Título.


CDU: 621.3

Wagner Dias Casagrande

Identificação de Estado Mental de Atenção Através do EEG para Treinamento com Neurofeedback


Dissertação submetida ao programa de Pós-Graduação em Engenharia Elétrica do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para a obtenção do Grau de Mestre em Engenharia Elétrica.

Trabalho aprovado. Vitória - ES, 20 de fevereiro de 2019:




Dr. Anselmo Frizera Neto

Programa de PósGraduação em Engenharia Elétrica (PPGEE - UFES) - Orientador



Dra. Mariane Lima de Souza

Programa de PósGraduação em Psicologia (PPGP - UFES) - Membro da Banca Avaliadora



Dr. André Ferreira

Departamento de Engenharia Elétrica (UFES) - Membro da Banca Avaliadora

Vitória - ES

2019

Agradecimentos

Primeiramente, agradeço a Deus por ter me dado sabedoria e motivação para que eu superasse os obstáculos da vida e desenvolvesse este trabalho.

Agradeço aos meus pais, José Sérgio Resende Casagrande e Margareth Dias dos Santos, as minhas irmãs Flávia e Andréa, e a minha noiva Tamara que me apoiaram e me incentivaram durante esta caminhada me dando forças e tendo paciência e compreensão por todo o tempo tomado por esta etapa da minha vida.

Agradeço também ao meu orientador Anselmo Frizera Neto e ao André Ferreira, pela dedicação, empenho, paciência e por terem compartilhado comigo seus conhecimentos ao longo desta jornada.

Agradeço à FAPES e ao CNPq (Edital 05/2017 – PRONEM – N° 80615503) pelo suporte financeiro a esta pesquisa. E agradeço ao CNPq pela bolsa de estudos concedida no período do mestrado.

Agradeço aos meus amigos do grupo BRAEN, que através de nossa pesquisa conjunta proporcionaram a primeira parte deste trabalho. Agradeço também pelos ótimos momentos durante esta jornada.

Agradeço ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Espírito Santo pela oportunidade de aprendizado e por ter proporcionado a conquista desta nova etapa em minha vida.

Resumo

O Transtorno de Déficit de Atenção e Hiperatividade (TDAH) é um transtorno associado a fatores neurobiológico e genéticos, com início na infância e que pode persistir na vida adulta, comprometendo o funcionamento da pessoa em vários setores de sua vida. As taxas mundiais de prevalência de TDAH estão em torno de 5,3% em crianças e adolescentes e 2,5% em adultos. Estudos sugerem que 40 a 60% das crianças afetadas continuam tendo o transtorno na idade adulta. Embora o tratamento farmacológico tenha se mostrado eficaz, ainda apresenta desvantagens, como efeitos colaterais (anorexia), dor abdominal, cefaleia e insônia. Dada a taxa relativamente alta de sintomas residuais, a incapacidade gerada por este distúrbio e a possível resistência ao tratamento farmacológico, é necessário combinar o arsenal terapêutico disponível com novos métodos não farmacológicos. O *neurofeedback* tem demonstrado, através de numerosos estudos, melhorar significativamente a atenção e proporcionar melhorias equivalentes às dos medicamentos estimulantes para crianças com transtorno de déficit de atenção e hiperatividade. Este trabalho tem como escopo o desenvolvimento de um sistema *neurofeedback* para dar suporte ao tratamento convencional de crianças com TDAH, bem como o desenvolvimento de um jogo sério com intuito de se gerar o *feedback* visual. O mesmo utiliza os sinais eletroencefalográficos captados através do EEG para classificar a tarefa mental de atenção. Para a análise e processamento dos sinais, o método de Welch e a transformada wavelet discreta (DWT) foram utilizadas para a extração de características, a análise de discriminantes lineares (LDA) foi aplicada para reduzir a dimensionalidade das características para cada eletrodo e a Máquina de Vetores de Suporte (SVM) foi empregada para classificar o estado de atenção. Desta maneira, pode-se complementar o tratamento convencional baseado em medicamentos para melhorar a resposta final dos pacientes. Um protocolo experimental de testes foi proposto e os resultados demonstraram que o sistema foi capaz de adquirir, processar e classificar os sinais. Análise acerca da acurácia do classificador utilizado mostrou que o sistema foi capaz de identificar os instantes em que os sujeitos estavam em um estado de atenção e relaxamento, tendo como melhor acurácia 90% para o método de Welch. Os resultados das etapas de processamento dos sinais biológicos, bem como os valores de acurácia se mostraram em conformidade com a literatura estudada. Trabalhos futuros envolvem o aprimoramento das técnicas utilizadas no processamento dos sinais, o desenvolvimento de um ambiente complexo gerado pela técnica de realidade virtual e a validação do sistema com crianças que possuem TDAH.

Palavras-chave: *Neurofeedback*, Transformada wavelet discreta (DWT), Eletroencefalografia, Máquina de vetores de suporte (SVM), Transtorno de déficit de atenção e hiperatividade (TDAH).

Abstract

Attention Deficit Hyperactivity Disorder (ADHD) is a disorder associated with neurobiological and genetic factors, beginning in childhood and can persist in adulthood, compromising the functioning of the person in various sectors of his life. The worldwide prevalence rates for ADHD are around 5.3% in children and adolescents and 2.5% in adults. Studies suggest that 40 to 60% of affected children continue to have the disorder in adulthood. Although pharmacological treatment has proved effective, it still has disadvantages, such as side effects (anorexia), abdominal pain, headache and insomnia. Given the relatively high rate of residual symptoms, the disability generated by this disorder and the possible resistance to pharmacological treatment, it is necessary to combine the available therapeutic arsenal with new non-pharmacological methods. Neurofeedback has been shown through numerous studies to significantly improve attention and provide equivalent improvements to stimulant medications for attention deficit hyperactivity disorder (ADHD) children. This work aims to develop a neurofeedback system aimed at supporting the conventional treatment of children with ADHD, as well as the development of a serious game in order to generate visual feedback. The same uses the electroencephalographic signals captured through the EEG to classify the mental task of attention. For the analysis and processing of the signals, the Welch method and the discrete wavelet transform (DWT) were used for the extraction of characteristics, the linear discriminant analysis (LDA) was applied to reduce the dimensionality of the characteristics for each electrode and the Machine of Support Vectors (SVM) was used to classify the attention state. In this way, conventional drug-based treatment can be supplemented to improve patients' final response. An experimental test protocol was proposed and the results demonstrated that the system was able to acquire, process and classify the signals. Analysis of the accuracy of the used classifier showed that the system was able to identify the instants in which the subjects were in a state of attention and relaxation, with the best accuracy being 90% for the Welch method. The results of the processing steps of the biological signals, as well as the accuracy values were shown in accordance with the studied literature. Future work involves improving the techniques used in signal processing, developing a complex environment generated by the virtual reality technique and validating the system with children who have ADHD.

Keywords: Neurofeedback, Discrete Wavelet Transform (DWT), Electroencephalography, Supporting Vector Machine (SVM), Attention Deficit Hyperactivity Disorder (ADHD).

Lista de ilustrações

Figura 1 – Disposição dos eletrodos no sistema internacional 10-20.	26
Figura 2 – Representação de um sinal $y(t)$ no domínio do tempo.	36
Figura 3 – Espectro de Fourier do sinal $y(t)$	37
Figura 4 – Representação Transformada de Fourier de Curta Duração (GABOR, 1946).	38
Figura 5 – Séries temporais de frequências distintas.	38
Figura 6 – série resultante da soma de duas e três frequências, simultaneamente.	39
Figura 7 – Transformada de Fourier do sinal presente na figura 6.	39
Figura 8 – Transformada de Fourier da primeira janela.	40
Figura 9 – Exemplos de famílias de wavelets (AL-GEELANI; PIAH; BASHIR, 2015).	42
Figura 10 – Representação gráfica da CWT mediante intensidade.	43
Figura 11 – Representação gráfica da CWT mediante três dimensões.	43
Figura 12 – Wavelets e senoidais com frequência igual à frequência central (MISITI; OPPENHEIM; POGGI, 2000).	45
Figura 13 – DWT - uma decomposição do sinal s	46
Figura 14 – DWT - decomposição de cada level.	46
Figura 15 – IDWT - reconstrução do sinal.	47
Figura 16 – Árvore gerada pela análise multiresolução do sinal s (SANTOS; SILVA; STEDILE, 2014).	48
Figura 17 – Representação do sistema <i>neurofeedback</i> desenvolvido neste trabalho.	49
Figura 18 – Sistema 10-20 com a posição dos eletrodos utilizados.	50
Figura 19 – Protocolo de aquisição da atividade cerebral proposto, para treinamento do classificador.	51
Figura 20 – SVM linear, separando duas classes de dados (LARHMAM, 2018).	55
Figura 21 – Interface do game desenvolvido.	56
Figura 22 – Decomposição do sinal original em suas sub-bandas.	59
Figura 23 – Gráfico PSD da atividade de atenção.	60
Figura 24 – Gráfico PSD da atividade de relaxamento.	60
Figura 25 – Plot classificador SVM para as duas classes (atenção e relaxamento) de um usuário durante o treinamento do classificador.	61

Lista de abreviaturas e siglas

ACNS	<i>American Clinical Neurophysiology Society</i>
BRAEN	<i>Brazilian Research Group on Brain and Cognitive Engineering</i>
CWT	Transformada Wavelet Contínua
DWT	Transformada Wavelet Discreta
EEG	Eletroencefalografia
fMRI	Imagens de Ressonância Magnética funciona
IDWT	Tansformada Inversa de Wavelet Discreta
LDA	Análise de Discriminantes Lineares
LSL	<i>Lab Streaming Layer</i>
MEG	Magnetoencefalografia
MRI	Ressonância Magnética
NCM	Nomenclatura Combinatória Modificada
NFB	<i>Neurofeedback</i>
NIRS	Sistema de Espectroscopia de Infravermelho Próximo
PET	Tomografia por Emissão de Pósitrons
PSD	Densidade Espectral de Potência
SCP	Potenciais Corticais Lentos
SF	Série de Fourier
SFTD	Série de Fourier de Tempo Discreto
SMR	Ritmo Sensório Motor
STFT	Transformada Fourier de Tempo-Curto
SVM	Máquina de Vetores de Suporte
TCC	Terapia Comportamental Cognitiva

TDAH	Transtorno de Déficit de Atenção e Hiperatividade
TF	Transformada Fourier
TW	Transformada Wavelet

Sumário

1	INTRODUÇÃO	17
1.1	Motivação	17
1.2	Objetivo	18
1.2.1	Geral	18
1.2.2	Específicos	18
1.3	Contribuições	19
1.4	Estruturação da Dissertação	19
2	NEUROFEEDBACK	21
2.1	Conceitos e definições	21
2.2	Histórico e desenvolvimento	22
2.3	Aspectos neurofisiológicos do <i>neurofeedback</i>	24
2.3.1	Eletroencefalografia – EEG	24
2.3.1.1	Origem dos sinais elétricos cerebrais	24
2.3.1.2	Ritmos da atividade cerebral	25
2.3.1.3	Localização dos sensores de EEG sistema 10-20	26
2.4	Instrumentos de <i>neurofeedback</i>	27
2.4.1	Protocolos de treinamento	27
2.5	Outras técnicas de medição de atividade cerebral	29
2.5.1	Ressonância magnética funcional (fMRI)	29
2.5.2	Espectroscopia no infravermelho próximo (NIRS)	30
2.5.3	Magnetoencefalografia (MEG)	30
2.5.4	Tomografia por emissão de pósitrons (PET)	30
3	FERRAMENTAS DE ANÁLISE E PROCESSAMENTO DOS SI- NAIS EEG	33
3.1	Transformada de Fourier	33
3.2	Transformada de Fourier de Curta Duração (STFT)	37
3.3	Transformada de Wavelet (TW)	40
3.3.1	Transformada Wavelet Contínua	42
3.3.2	Transformada Wavelet Discreta	44
4	MATERIAIS E MÉTODOS - DESENVOLVIMENTO DO SISTEMA DE <i>NEUROFEEDBACK</i>	49
4.1	Sistema <i>neurofeedback</i>	49
4.2	Aquisição atividade cerebral	50

4.3	<i>Lab streaming layer (LSL)</i>	51
4.4	Pré-processamento	52
4.5	Extração de características	52
4.5.1	Energia wavelet relativa	52
4.5.2	Densidade Espectral de Potência (PSD)	53
4.6	Análise linear discriminante (LDA)	54
4.7	Classificação	54
4.7.1	Support Vector Machine (SVM)	54
4.8	Jogo	55
5	VALIDAÇÃO EXPERIMENTAL	57
5.1	Protocolo experimental	57
5.1.1	Participantes	57
5.1.2	Base de dados	57
5.2	Resultados	58
6	CONCLUSÃO	63
6.1	Conclusão	63
6.2	Trabalhos futuros	64
	REFERÊNCIAS	65

1 Introdução

Esta Dissertação de Mestrado está direcionada ao desenvolvimento de um sistema *neurofeedback* voltado para dar suporte ao tratamento convencional de crianças com Transtorno de Déficit de Atenção e Hiperatividade (TDAH), bem como ao desenvolvimento de um jogo com intuito de se gerar o *feedback* visual do estado de atenção para o usuário. Desta maneira, pode-se complementar o tratamento convencional baseado em medicamentos com a finalidade de melhorar a resposta final dos pacientes. Este primeiro tópico apresenta a motivação para a realização desta pesquisa e seus objetivos, além das principais contribuições alcançadas. Ao final do mesmo, será apresentado como a Dissertação está estruturada.

1.1 Motivação

O Transtorno de Déficit de Atenção e Hiperatividade (TDAH) é um transtorno associado a fatores neurobiológicos, em grande parte explicados pela genética (isto é, existem chances maiores de ele ser herdado), que tem início na infância e que pode persistir na vida adulta, comprometendo o funcionamento da pessoa em vários setores de sua vida, e se caracteriza por três grupos de alterações: hiperatividade, impulsividade e desatenção.

As taxas mundiais de prevalência de TDAH estão em torno de 5,3% em crianças e adolescentes e 2,5% em adultos. Estudos sugerem que 40 a 60% das crianças afetadas continuam tendo o transtorno na idade adulta, dependendo dos critérios de persistência aplicados (POLANCZYK; ROHDE, 2007).

Embora o tratamento farmacológico com metilfenidato tenha se mostrado eficaz (GOLDMAN et al., 1998), ainda apresenta desvantagens, como efeitos colaterais (anorexia), dor abdominal, cefaleia e insônia.

Orientações europeias para a síndrome hipercinética defendem um tratamento combinando a farmacologia, a terapia comportamental cognitiva (TCC) e a orientação dos pais (TAYLOR et al., 2004). Entende-se como hipercinética, o início precoce e por uma combinação de comportamento hiperativo e pobremente modulado com desatenção marcante, falta de envolvimento persistente nas tarefas, conduta invasiva nas situações e persistência (BARBOSA; BARBOSA, 2000).

No entanto, dada a taxa relativamente alta de sintomas residuais, a incapacidade gerada por este distúrbio, particularmente no nível da escola, e a possível resistência contra o tratamento farmacológico, é necessário aumentar o arsenal terapêutico disponível e, portanto, é interessante considerar novas terapias não farmacológicas como a TCC nas

habilidades pessoais de aprendizado da criança para regular seus sintomas (TOPLAK et al., 2008). Como o EEG pode ser correlacionado com estados mentais e estar alterado no TDAH, é concebível que as habilidades de aprendizagem possam ser desenvolvidas e treinadas através do EEG e seu *feedback*, a fim de alcançar um efeito terapêutico no paciente (HEINRICH; GEVENSLEBEN; STREHL, 2007). Trata-se do treinamento *neurofeedback*, que visa melhorar as capacidades psicológicas particulares, neste caso a atenção com a prática através de software de computador especialmente concebido sob a forma de jogos. Esses jogos devem equilibrar o engajamento / diversão (que ajuda na conformidade do treinamento) com o desafio / aprendizado e, normalmente, incluem o *feedback* de desempenho com o nível de dificuldade da tarefa variado de acordo com o desempenho (JOHNSTONE et al., 2017).

Vale ressaltar que o *neurofeedback* tem demonstrado, através de estudos científicos, melhorar significativamente a atenção e proporcionar melhorias equivalentes às dos medicamentos estimulantes para crianças com transtorno de déficit de atenção e hiperatividade (TDAH) (KAISER; OTHMER, 2000; LUBAR, 1997). Em um estudo de Alegria et al. (2017) o neurofeedback de ressonância magnética funcional (fMRI) demonstrou redução significativa nos sintomas de TDAH após a neuroterapia e aos 11 meses de acompanhamento.

1.2 Objetivo

1.2.1 Geral

O objetivo geral desta Dissertação consiste no desenvolvimento de um algoritmo que possibilite a análise dos dados coletados através da eletroencefalografia (EEG) e que seja capaz de identificar se o participante está em um estado mental de atenção ou relaxamento, e com isso, fornecer ao sujeito *feedback* em forma de um jogo, com o intuito de fazer os participantes serem capazes de autorregular suas atividades cerebrais, tornando-os capazes de focar e sustentar sua atenção, de forma voluntária e consistente. O algoritmo desenvolvido será a base do sistema *neurofeedback*.

1.2.2 Específicos

Pode-se enumerar como objetivos específicos pertinentes ao trabalho:

1. Comparar as ferramentas de análise dos sinais eletroencefalográficos.
2. Definir protocolo de treinamento *neurofeedback*, específico para o tratamento do Transtorno de Déficit de Atenção e Hiperatividade (TDAH).

3. Programar algoritmo capaz de identificar o padrão das ondas cerebrais em estado de atenção durante a realização de tarefa alvo.
4. Desenvolver um jogo para se gerar o *feedback* visual.
5. Fazer testes, a fim de validar o sistema.

1.3 Contribuições

A principal contribuição desta Dissertação é o desenvolvimento de um algoritmo para identificação de estado mental de atenção e relaxamento que possa ser utilizado em um sistema *neurofeedback* para o futuro tratamento de crianças com TDAH.

No decorrer da pesquisa foi proposta uma abordagem de gamificação do sistema *neurofeedback*, que consiste, basicamente, do uso de mecânicas e dinâmicas de jogos, a fim de se aumentar o engajamento do paciente para com o treinamento.

Foi proposto um protocolo de aquisição dos dados EEG para posterior identificação do estado mental de atenção a partir de dois métodos de extração de características, sendo eles a Transformada wavelet discreta (DWT) e a Densidade espectral de potência (PSD).

1.4 Estruturação da Dissertação

Este documento está organizado da seguinte forma: após a apresentação da motivação inicial no Capítulo 1, o Capítulo 2 apresenta os conceitos e definições sobre o *neurofeedback*, os aspectos neurofisiológicos relacionados e os protocolos de treinamento mais difundidos. Também são apresentadas outras técnicas de medição de atividade cerebral com suas vantagens e desvantagens frente à eletroencefalografia. Neste Capítulo também é realizada uma revisão da literatura relacionada com o histórico e desenvolvimento do *neurofeedback*.

No Capítulo 3 são apresentadas as ferramentas de análise dos sinais eletroencefalográficos mais empregadas e é feita uma comparação entre mesmas.

No Capítulo 4 é apresentado o sistema *neurofeedback* proposto, os materiais e métodos utilizados para a aquisição dos dados, o protocolo experimental proposto neste estágio do desenvolvimento da Dissertação, as técnicas utilizadas no processamento dos dados obtidos e o retorno ao usuário do sistema em forma de jogo sério.

No Capítulo 5 são apresentados os resultados preliminares, bem como uma discussão a respeito destes resultados.

Finalmente, o Capítulo 6 apresenta as conclusões deste trabalho até o momento, o que se espera até a finalização do trabalho e recomendações para trabalhos futuros.

2 Neurofeedback

2.1 Conceitos e definições

O *neurofeedback* (NFB) é uma técnica de neuromodulação na qual os sinais cerebrais são monitorados, geralmente por registro da atividade cerebral por eletroencefalografia (EEG) (ARNS et al., 2009; SHERLIN et al., 2011; LARSEN; SHERLIN, 2013). Porém, também pode ser realizado tanto por imagens de ressonância magnética funcional (fMRI) (YOUNG et al., 2014) quanto através do sistema de espectroscopia de infravermelho próximo (NIRS) (MIHARA et al., 2012), entre outros. Para todos os casos, a informação adquirida através desses registros, é empregada pelo próprio sujeito para que ele controle o seu desempenho (LARSEN; SHERLIN, 2013). Para tanto, este sistema se vale de recursos digitais sonoros e/ou visuais (e até táteis) que são modulados em tempo real pela atividade cerebral registrada (PEEK, 1995).

As pessoas têm a capacidade de aprender a assumir o controle de vários aspectos de sua atividade neural através de um processo de treinamento que envolve a exibição online de mudanças contínuas a serem fornecidas ao usuário por meio do EEG (NEUPER; PFURTSCHELLER, 2009), como por exemplo, nível de atenção atual exibido numericamente, em um gráfico de barras ou como uma exibição visual envolvente (JOHNSTONE et al., 2017).

O treinamento NFB envolve, assim, vários mecanismos de aprendizado no cérebro, dos quais o condicionamento operante é considerado o principal (NEUPER; PFURTSCHELLER, 2009; ENRIQUEZ-GEPPERT; HUSTER; HERRMANN, 2017). E está fundamentada no processo de aprendizagem contínua tanto da máquina quanto do homem mediante a modificação de padrões cerebrais realizada pelo próprio indivíduo (CABALLO; CLAUDINO, 1996).

Este método tem sido aplicado como uma ferramenta terapêutica para normalizar a atividade cerebral desviante; ou como uma ferramenta de aprimoramento cognitivo para indivíduos saudáveis no chamado “treinamento de desempenho de pico” (ENRIQUEZ-GEPPERT; HUSTER; HERRMANN, 2017). Alguns exemplos são o uso de treinamento NFB em neuroreabilitação para aprendizagem motora na recuperação pós-AVC (ZICH et al., 2015; KRUCOFF et al., 2016), no tratamento do transtorno do déficit de atenção e hiperatividade (ADHD) (ARNS et al., 2009) ou epilepsia (STERMAN; EGNER, 2006); ou treinamento de NFB para melhorar as habilidades de atenção (SHIN et al., 2016).

Esses estudos baseiam-se na suposição de uma relação causal entre oscilações cerebrais específicas e cognição, comportamento ou função motora - isto é, a autorregulação

da atividade cerebral específica se destina a produzir mudanças benéficas nas funções cognitiva, comportamental ou motora.

A eficácia do treinamento NFB pode ser medida usando duas variáveis independentes: a mudanças na atividade do EEG e as alterações cognitivas ou comportamentais de uma função direcionada (ROGALA et al., 2016).

Os padrões de atividade cerebral a serem modificados através do treinamento cognitivo com o *neurofeedback* são definidos de acordo com o objetivo a ser alcançado, que no caso desta Dissertação seria a autorregulação do processo atencional que se encontra comprometido nos pacientes com TDAH.

2.2 Histórico e desenvolvimento

De acordo com Demos (2005), a pesquisa de Richard Caton realizada em 1875 é considerada um marco inicial para o *biofeedback*. Inicialmente, seus experimentos incluíam a colocação de eletrodos no cérebro exposto de animais. Posteriormente, também registrou atividades elétricas provenientes do escalpo fechado de animais. Por volta de 1920, Hans Berger mensurou a atividade elétrica em escalpos humanos. Berger foi o primeiro a registrar a atividade elétrica cerebral em papel, gerando um eletroencefalograma. Ele identificou duas ondas filtradas diferentes, alfa e beta. A frequência de 10 Hz ficou conhecida como Ritmo Berger.

Berger também observou que o pensamento e o estado de alerta geravam elevados aumentos na banda da frequência beta, que chegava a alcançar de 13 a 30 Hz. Ele acreditava que anormalidades no EEG refletem distúrbios clínicos. Muitos protocolos de tratamento por *neurofeedback* são baseados nesta suposição de Berger (CRISWELL, 1995).

No decorrer dos anos 30, Edgar Adriane e B.H.C. Mathews repetiram com sucesso as medidas das ondas elétricas de Berger. Através de um dispositivo de cintilação por foto estimulação, eles também estudaram a sincronização das ondas cerebrais. Também foram os pioneiros no uso de amplificador diferencial. Suas pesquisas mostraram que os padrões de ondas cerebrais podem ser alteradas por frequências específicas de luzes intermitentes. A sincronização das ondas cerebrais mudou o EEG, porém não podia ser considerado *biofeedback*, uma vez que não havia um retorno (*feedback*) das informações biológicas do que estava sendo treinado, isto é, era um processo de uma única via. Em 1963 o professor da Universidade de Chicago, Joseph Kamiya, queria descobrir se era possível fazer o reconhecimento consciente das ondas cerebrais. Ele treinou um voluntário a reconhecer um período de intensa atividade das ondas cerebrais alfa (8-12 Hz). Kamiya deu ao seu voluntário reforços verbais no treinamento cada vez que ele entrava no estado alfa. O experimento foi bem sucedido.

À vista disso, a habilidade humana em regular o estado das próprias ondas cerebrais via instrumentação foi confirmada (CRISWELL, 1995). O experimento de Kamiya demonstrou todo o ciclo de treinamento *biofeedback*, onde um instrumento registrava uma atividade biológica específica de interesse, a pessoa que está sendo treinada é reforçada de tempos em tempos sobre a ocorrência da atividade desejada e, então, o controle da atividade biológica se torna possível. O *biofeedback* é baseado neste processo inovador criado por Kamiya. Foi ele quem abriu as portas para o treino de aprimoramento das ondas alfa.

Foi relatado quase que simultaneamente na França por Durup e Fessard em 1935 e nos Estados Unidos por Loomis, Harvey e Hobart em 1936, que as primeiras demonstrações de que a atividade do cérebro, mais especificamente, o bloqueio da resposta de alfa, poderia ser classicamente condicionada. Loomis descreveu que em um quarto completamente escuro a união de um tom auditivo baixo com um estímulo de luz resultou em um condicionamento, cuja resposta causou o bloqueio de alfa. Observaram também que a extinção ocorria se o tom baixo era apresentado várias vezes em ausência de estímulo de luz (SHERLIN et al., 2011).

Consoante Siever (2008), em 1960 o Dr. Antoine Remond, médico francês e pesquisador de eletroencefalografia, começou a experimentar o controle voluntário das ondas cerebrais. Em seguida, Remond descobriu a assinatura das pessoas portadoras de TDAH, ou disfunção cerebral mínima, como era conhecida na época. Em 1969 ele publicou seus achados em um livro intitulado "*Le rythme alpha moyen. Méthodologie et description*" (O ritmo alfa médio. Metodologia e descrição) onde explicou suas descobertas sobre o funcionamento interno do cérebro e da mente.

Por volta de 1960 pesquisadores independentes dos Estados Unidos construíram instrumentos para o monitoramento e o retorno da informação fisiológica com finalidade terapêutica, mas somente em 1969, Barbara Brown organizou a primeira conferência que consolidou a nomenclatura "*biofeedback*" para tal procedimento, criando a organização nacional americana intitulada *Biofeedback Research Society*. Com o desenvolvimento de instrumentos para *biofeedback* a demonstração e a investigação científica tornaram-se possíveis e o novo procedimento logo saiu dos laboratórios de pesquisa para ganhar a clínica. A utilização desses instrumentos na área de captação de sinais elétricos exclusivamente cerebrais através de eletrodos passou a ser chamada de *neurofeedback* (JONAS; LEVIN, 2001).

Moriyama et al. (2012) relatam que em 1965, Sterman descobriu, acidentalmente, que os gatos podiam ser condicionados a produzir um ritmo rápido EEG de cerca de 12 a 15 Hz sobre o córtex sensorio motor (SMR - ritmo sensorio motor). Sterman utilizou os mesmos gatos em outro experimento em que os mesmos seriam expostos a uma substância tóxica conhecida por provocar convulsões. Ele ficou surpreso ao observar que os animais

que tinham sido ensinados a produzir SMR eram resistentes ao efeito convulsivo dessa substância. Sterman realizou estudo controlado cego com medidas repetidas, e conseguiu demonstrar que o NFB poderia ser usado para controlar as crises convulsivas. Os estudos de Sterman encorajaram outros pesquisadores a tentarem utilizar o NFB para a epilepsia e, alguns deles, eventualmente relataram que tanto crianças com epilepsia quanto com sintomas hipercinéticos apresentaram melhora surpreendente de hipercinesia após as sessões de NFB. Lubar e Shouse (1976) foram os primeiros a relatar os benefícios do NFB em crianças com transtornos hipercinéticos sem epilepsia.

Arns et al. (2009) aponta que surgiram diversos estudos a fim de investigar os efeitos do *neurofeedback* nos diferentes sintomas de distúrbio como desatenção, impulsividade e hiperatividade, desde o primeiro relato de tratamento de TDAH através da técnica de *neurofeedback*, em 1976.

2.3 Aspectos neurofisiológicos do *neurofeedback*

Visando uma maior compreensão de como os dados cerebrais são captados, se faz necessária uma revisão de alguns conceitos básicos.

2.3.1 Eletroencefalografia – EEG

2.3.1.1 Origem dos sinais elétricos cerebrais

O cérebro sempre fascinou os humanos, e particularmente um cientista alemão chamado Hans Berger, que descobriu a eletroencefalografia (EEG) há cerca de 80 anos. Depois disso, novos métodos para explorá-lo foram encontrados e podemos categorizá-los em dois grupos principais: Invasivo e não invasivo.

Uma abordagem invasiva requer implantes físicos de eletrodos em humanos ou animais, possibilitando medir neurônios isolados ou potenciais de campo muito locais.

Uma abordagem não invasiva faz uso de, por exemplo, ressonância magnética (MRI) e tecnologia EEG para fazer medições. Ambas oferecem diferentes perspectivas e nos permitem observar o que acontece dentro do cérebro, sejam as regiões que estão ativas ou as frequências cerebrais presentes, respectivamente (KROPOTOV, 2009).

No EEG, os potenciais elétricos relacionados ao cérebro são registrados no couro cabeludo. Pares de eletrodos condutores feitos de prata, por exemplo, são usados para ler essa eletricidade. A diferença de voltagem entre os eletrodos é medida e, como o sinal é fraco ($30\text{-}100\mu\text{V}$), ele precisa ser amplificado (ALVES, 2018).

A corrente ocorre quando os neurônios se comunicam. O evento mais simples é chamado de potencial de ação e é uma descarga causada pela rápida abertura e fechamento

dos canais iônicos Na^+ (sódio) e K^+ (potássio) na membrana do neurônio. Se a membrana despolarizar para algum limiar, o neurônio irá "disparar". O rastreamento dessas descargas ao longo do tempo revela a atividade cerebral (SANTOS; SILVA; STEDILE, 2014).

2.3.1.2 Ritmos da atividade cerebral

Junto da descoberta de Berger, veio a evidencição das diferentes frequências elétricas que poderiam estar ligadas a ações e diferentes estágios de consciências. Isso foi feito observando os sujeitos executando tarefas diferentes, como por exemplo, resolvendo problemas matemáticos, enquanto gravavam seu EEG.

Com base nas faixas de frequência, os sinais EEG podem ser divididos em cinco bandas (NOACHTAR et al., 1999), como pode ser identificado a seguir:

- 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 exibe quase nenhuma atividade δ ; em vez disso, essa atividade ocorre quando em um sono profundo, inconsciente, anestesiado ou sem oxigênio.
- Atividade Teta (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 pensar ou piscar, as ondas α 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 μV 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 μV em amplitude. Estudo recente descobriu que a atividade γ está relacionada à atenção seletiva (PORTUGAL, 2017). Outro estudo também destaca que essa atividade está relacionada à estados alterados de consciência (APPOLINÁRIO, 2001).

2.3.1.3 Localização dos sensores de EEG sistema 10-20

O Sistema Internacional 10-20 é o método mais utilizado para descrever a colocação de eletrodos em intervalos específicos ao longo da cabeça. Ele utiliza 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 (NIEDERMEYER; SILVA, 2005). O lóbulo que está por baixo de cada eletrodo é identificado por uma nomenclatura formada por no máximo 2 letras, juntamente com um número ou uma outra letra para identificar a sua posição hemisférica como mostra a Figura 1. Esta nomenclatura é usada para facilitar o mapeamento topográfico da atividade EEG (EPSTEIN, 2006).




Figura 1 – Disposição dos eletrodos no sistema internacional 10-20.

Já o Sistema Internacional 10-20 com a nomenclatura combinatória modificada (NCM), substitui os rótulos T3/T4 e T5/T6 pelos rótulos T7/T8 e P7/P8, respectivamente. Esta substituição torna-se evidente quando inspecionamos o diagrama da cabeça, em que são mostradas, com exceção de Fp1/Fp2 e O1/O2, todas as posições dos eletrodos ao longo da mesma linha sagital têm o mesmo número e que todos os eletrodos designados pela mesma letra encontram-se na mesma linha coronal. Com a modificação, a nomenclatura alfanumérica para cada eletrodo especifica suas coordenadas de localização dentro da malha do sistema 10-20. Esta modificação foi recomendado pela primeira vez pela ACNS (*American Clinical Neurophysiology Society*), para estar em concordância com os nomes e localizações dos eléctrodos nas versões estendidas do sistema 10-20, como o sistema internacional 10/10.

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](#)).

Num exame eletroencefalográfico típico, por exemplo, dos 21 eletrodos utilizados, 19 são colocados nas regiões do escalpo determinadas pelo sistema 10-20 e os outros dois nos lóbulos das orelhas ("A1" e "A2"), para serem utilizados como referências elétricas ([APPOLINÁRIO, 2001](#)).

2.4 Instrumentos de *neurofeedback*

De uma forma geral, os sistemas de *neurofeedback* realizam três funções básicas: Inicialmente são captados os sinais elétricos provenientes das atividades corticais e subcorticais, ao nível do escalpo. Após a aquisição dos sinais cerebrais, os mesmos passam por um processo de amplificação, pois a amplitude dos sinais EEG é de apenas alguns micro-volts, necessitando serem amplificados milhares de vezes antes de serem digitalizados, além de prevenir o sistema contra ruídos provenientes da rede elétrica. Depois que passar pelos amplificadores, os sinais são processados. Na etapa de processamento que são feitas as extrações das características relevantes dos sinais e a classificação dos mesmos. Por fim, é dado *feedback* dos sinais já processados ao sujeito de forma visual, tátil, auditiva ou uma combinação dos mesmos ([PEEK, 1995](#)).

Uma das questões primordiais é o tempo que o sistema demanda desde a captação dos sinais até o *feedback* oferecido. Se esse tempo for excessivamente longo, o processo de aprendizagem não terá eficiência, uma vez que o sujeito não conseguirá estabelecer uma relação entre o seu estado interno e os comportamentos de modulação necessários para modificar os mesmos. Logo, a agilidade do sistema é um fator crítico e indispensável para o treinamento *neurofeedback* ([APPOLINÁRIO, 2001](#)).

Os dispositivos atuais de *neurofeedback* oferecem uma grande gama de possibilidades de treinamento cerebral, por meio da combinação de vários parâmetros, que quando definidos, configura - se um protocolo de treinamento ([APPOLINÁRIO, 2001](#)).

2.4.1 Protocolos de treinamento

Para se projetar um protocolo de treinamento, importantes considerações devem ser levadas em conta, que são ([ENRIQUEZ-GEPPERT; HUSTER; HERRMANN, 2017](#)): a duração da sessão, a intensidade do treinamento, o uso de uma condição de controle, e o tipo de treino.

Para determinar a duração da sessão, deve-se levar em conta a capacidade de um participante se concentrar no treinamento. Quanto maior a duração da sessão, mais difícil fica para o sujeito permanecer focado no final. Por outro lado, sessões de menor duração permitem menos testes práticos para treinamento de controle, além da possibilidade

de terminar quando o indivíduo fica imerso na tarefa. A duração da sessão comum em estudos terapêuticos é de cerca de 20 a 40 minutos (ENRIQUEZ-GEPPERT; HUSTER; HERRMANN, 2017). Em Zich et al. (2015), foram feitas sessões de treinamento de aproximadamente 24 minutos, de forma a se facilitar o efeito de aprendizagem, evitando o esgotamento e o tédio.

A intensidade do treinamento engloba a quantidade de sessões de treinamento e a quantidade de descanso (em dias) entre os mesmos. Segundo Enriquez-Geppert, Huster e Herrmann (2017), para o aprendizado da autorregulação da atividade cerebral, pouco são os conhecimentos sobre o número ideal de sessões de treinamento em um determinado intervalo de tempo, nem a duração de um intervalo efetivo entre elas.

Para proporcionar a avaliação dos efeitos específicos do NFB, é de suma importância utilizar uma condição de controle. Ela permite o controle de efeitos de treinamento relacionados à repetição e efeitos não específicos que podem ser causados pelo cenário geral (por exemplo, interações treinador-sujeito) (ENRIQUEZ-GEPPERT; HUSTER; HERRMANN, 2017). Uma opção é usar a mesma quantidade de sessões de treinamento tanto para o grupo de indivíduos quanto o grupo experimental, mas não recebem NFB. Outra opção é apresentar o grupo de controle com *pseudo-feedback*. Nesse caso, os sujeitos de controle recebem um sinal artificial de feedback gerado por computador ou uma repetição do sinal de *feedback* derivado de outro assunto / outra sessão. Um grupo simulado permitiria controlar o efeito do esforço de atenção que acompanha qualquer treinamento de EEG-NFB (ROGALA et al., 2016). Entretanto, a credibilidade de *feedback* é uma questão importante a ser considerada (ENRIQUEZ-GEPPERT; HUSTER; HERRMANN, 2017): se um sujeito de controle fica ciente de que suas ações não afetam o sinal de *feedback*, isso pode resultar em comportamento passivo (“desamparo aprendido”, segundo Enriquez-Geppert, Huster e Herrmann (2017)) e diminuição de desempenho.

São vários os tipos de treino encontrados em literatura, mas, são três os mais difundidos (DRECHSLER et al., 2007), que são: treino teta/beta, treino ritmo sensorial-motor (SMR) e treino de potenciais corticais lentos (slow cortical potentials – SCP’s).

O treino mais utilizado em pacientes com TDAH é o teta/beta, que consiste em diminuir a atividade da banda teta e aumentar a atividade da banda beta (DRECHSLER et al., 2007). Este tipo de treino pode tratar uma disfunção neuronal subjacente e tem como objetivo reduzir a desatenção e a impulsividade (GEVENSLEBEN et al., 2010; KROPOTOV et al., 2005).

Já o treino ritmo sensorial-motor, visa aumentar a atividade da banda beta, porem na faixa de frequência de 12 a 15 Hz, frequência está relacionada com o SMR, com a finalidade de se reduzir os sintomas hipercinéticos (inquietação, impulsividade, agitação) (KROPOTOV et al., 2005). O estudo de Kropotov et al. (2005) foi o primeiro a estudar as correlações de potenciais evocados no treino beta, mostrando que não são apenas

os parâmetros de atenção que são melhorados pelo tratamento por *neurofeedback*, mas também existem alterações em parâmetros neuropsicológicos que refletem melhorias no controle comportamental em pacientes com TDAH (KROPOTOV et al., 2005).

Os SCP's são alterações da atividade elétrica cortical, que duram desde várias centenas de milissegundos a vários segundos, e são considerados para representar mobilizações a curto prazo dependentes de tarefas que envolvem o processamento cortical (GEVENSLEBEN et al., 2010). Enquanto os SCP's negativos refletem aumento da excitação (por exemplo, durante estados de preparação comportamental ou cognitiva), os SCP's positivos indicam uma redução da excitação cortical das redes neuronais subjacentes (por exemplo, durante a inibição comportamental) (GEVENSLEBEN et al., 2010). Os participantes aprendem a aumentar a positividade ou negatividade ao longo do seu córtex sensorial-motor, normalmente medida pelo eletrodo da linha média central (DRECHSLER et al., 2007). Este tipo de treino é destinado ao controle da regulação cortical e à atribuição eficiente dos recursos, que é suposto estarem debilitadas em pacientes com TDAH (DRECHSLER et al., 2007).

2.5 Outras técnicas de medição de atividade cerebral

Além do EEG, são várias as técnicas empregadas para detectar os ritmos elétricos do cérebro de forma não invasiva. Dentre as mais utilizadas, podemos citar:

2.5.1 Ressonância magnética funcional (fMRI)

É uma técnica que funciona detectando as mudanças na oxigenação e no fluxo sanguíneo (contraste endógeno dependente do nível de oxigenação sanguínea (BOLD)) que ocorrem em resposta à atividade neural, isto é, quando uma área do cérebro é mais ativa, consome mais oxigênio e, para atender a esse aumento, o fluxo sanguíneo aumenta para a área ativa.

A fMRI pode ser usada para produzir mapas de ativação mostrando quais partes do cérebro estão envolvidas em um processo mental particular, o que já é bem difundido.

O benefício da fMRI é sua alta resolução espacial, onde pode-se localizar áreas cerebrais ativadas com resolução espacial milimétrica. Mas o tempo de resposta lento da resposta BOLD limita sua resolução temporal (OGAWA et al., 1992).

Tanto o EEG quanto o fMRI são muito sensíveis a alterações das atividades sinápticas. Estudos sugerem que com EEG e fMRI simultâneos, os mesmos eventos neurais podem ser caracterizados com alta resolução temporal e espacial. Uma das aplicações mais promissoras para EEG-fMRI hoje é a caracterização da estrutura e dinâmica da rede cerebral (MULERT, 2013).

2.5.2 Espectroscopia no infravermelho próximo (NIRS)

É um método que permite o monitoramento contínuo da oxigenação tecidual e das alterações hemodinâmicas no cérebro, não apenas durante o período interictal, mas também durante as convulsões.

NIRS trabalha iluminando a parte infravermelha próxima do espectro (700-900nm) através do crânio e detectando o quanto a luz que está sendo emitida é atenuada. O quanto a luz é atenuada depende da oxigenação do sangue e, assim, a NIRS pode fornecer uma medida indireta da atividade cerebral (DEMITRI, 2007).

Assim como a fMRI, NIRS é baseada no monitoramento do fluxo sanguíneo local e na oxigenação, mas é muito mais barata que a fMRI, não invasiva, portátil e aplicável a pacientes móveis e lactentes, além de possuir melhor resolução temporal. Uma das desvantagens é que sua resolução espacial é seriamente pior que a mesma da fMRI (HAGINOYA et al., 2002). No entanto, alguns resultados significativos foram obtidos pelo NIRS, como por exemplo, foi demonstrado que as crises convulsivas estão geralmente associadas a um aumento no volume sanguíneo cerebral, mas as crises de ausência estão associadas a uma leve diminuição no volume sanguíneo cerebral do córtex frontal (HAGINOYA et al., 2002).

2.5.3 Magnetoencefalografia (MEG)

É uma técnica de imagem utilizada para medir os campos magnéticos produzidos pela atividade elétrica no cérebro através de dispositivos extremamente sensíveis, conhecidos como SQUIDS (*Superconducting Quantum Interference Device*), que são basicamente sensores de fluxo magnético sensíveis. Essas medidas são comumente usadas em pesquisas e ambientes clínicos.

Há muitos usos para o MEG, incluindo auxiliar os cirurgiões na localização de uma patologia, auxiliando os pesquisadores na determinação da função de várias partes do cérebro, *neurofeedback* e outros.

Vale ressaltar que os padrões espaciais característicos podem ser diferenciados mais claramente com o MEG do que com o EEG (NISO et al., 2016). Esses ritmos variam em função do comportamento, atenção, estado mental e vigilância do sujeito. Outro fato importante a se destacar, é que mudanças no conteúdo de frequência e na ritmicidade do MEG espontâneo podem indicar vários tipos de anomalias cerebrais.

2.5.4 Tomografia por emissão de pósitrons (PET)

Estabelecida na década de 1970, PET utiliza vestígios de material radioativo de curta duração para mapear processos funcionais no cérebro. Quando o material sofre

decaimento radioativo, um pósitron é emitido, o qual pode ser captado pelo detector, que é introduzido no organismo imediatamente antes uma sessão de imagens (CASSE et al., 2002). As Áreas que apresentarem alta radioatividade estão associadas à atividade cerebral. A aplicação de PET apresenta algumas limitações que são o seu alto custo, as dificuldades técnicas e a resolução espacial e temporal relativamente baixa (CASSE et al., 2002).

3 Ferramentas de análise e processamento dos sinais EEG

O processamento de sinais consiste na análise e modificação de sinais de forma a extrair informações adicionais importantes que não estavam disponíveis no formato original (sinal bruto), e ainda, torná-los mais apropriados para alguma aplicação específica. Para tanto, são necessárias transformações matemáticas ([GURGEL, 2013](#)).

A maioria dos sinais, na prática, são sinais no domínio do tempo em seu formato bruto. Ou seja, o que quer que esse sinal esteja medindo, está em função do tempo. Em outras palavras, quando o sinal é plotado, um dos eixos é o tempo (variável independente), e o outro (variável dependente) é geralmente a amplitude. Quando plotamos sinais no domínio do tempo, obtemos uma representação de amplitude de tempo do sinal. Essa representação nem sempre é a melhor representação do sinal para a maioria das aplicações relacionadas ao processamento de sinal. Em muitos casos, a informação mais distinta está escondida no conteúdo de frequência do sinal. O espectro de frequência de um sinal é basicamente os componentes de frequência (componentes espectrais) daquele sinal, ou seja, mostra quais frequências existem no sinal ([OCAZIONEZ, 2009](#)).

Para medir e identificar o conteúdo da frequência de um sinal, uma solução seria a Transformada de Fourier (TF). Se a TF de um sinal no domínio do tempo for obtida, como saída, teremos a representação de amplitude-frequência desse sinal, isto é, agora será possível identificar o quanto de cada frequência existe no sinal analisado ([OCAZIONEZ, 2009](#)).

Existem muitas outras transformações além da TF, que são utilizadas para análise de sinais, como por exemplo, Transformada de Fourier de Curta Duração, Transformada Wavelet Contínua e Transformada Wavelet Discreta ([GURGEL, 2013](#)).

Toda técnica de transformação possui sua própria área de aplicação, com vantagens e desvantagens. Para uma melhor compreensão de cada uma das transformações, vamos examinar cada uma delas.

3.1 Transformada de Fourier

A análise de Fourier foi introduzida pelo físico e matemático Jean Baptiste Fourier no ano de 1807, que consiste do estudo de sinais e sistemas realizando decomposição de funções periódicas em séries trigonométricas convergentes.

Existem quatro formas distintas de representação de Fourier, que são definidas

através da classe dos sinais e pelas suas propriedades temporais (GURGEL, 2013). Os sinais periódicos tem representação pela série de Fourier: a série de Fourier (SF) se aplica a sinais periódicos de tempo contínuo; e a série de Fourier de tempo discreto (SFTD) se aplica a sinais periódicos de tempo discreto. Sinais não periódicos tem representação pela transformada de Fourier: se o sinal for não periódico de tempo contínuo sua representação se denomina de transformada de Fourier (TF); se o sinal for não periódico de tempo discreto sua representação se dá pela transformada de Fourier de tempo discreto (TFTD) (GURGEL, 2013).

Tratando - se de sinais advindos do EEG, a representação de fourier adequada é a Transformada de Fourier, pois seus sinais são não periódicos e de tempo contínuo.

A transformada de Fourier é uma ferramenta que decompõe um determinado sinal determinístico nas suas componentes frequenciais. Para que a transformada seja aplicada a uma função, esta deve ser periódica, ou seja, possuir um padrão que se repete periodicamente (MACEDO, 2011). Entretanto, muitos sinais trabalhados na prática não são periódicos, contudo, estes sinais podem, muitas das vezes, serem considerados periódicos (ou estacionários) em curtos períodos de amostragem (MACEDO, 2011).

Através da série de Fourier, qualquer função periódica, por mais complexa que seja, tem sua representação equivalente como uma soma de componentes senoidais de frequências distintas (GURGEL, 2013).

A frequência é definida como o número de ocorrência de um determinado evento durante o tempo de um período unitário, ou seja, ela é dada pelo inverso do período, T , e se este for medido em segundos a frequência será dada em Hz, conforme a seguinte equação (GURGEL, 2013):

$$F = 1/T \quad (3.1)$$

A frequência angular unitária (ω_0) é outro tipo de frequência que é utilizado no estudo de fenômenos de ondulatórios, que significa a taxa de variação temporal de uma determinada angulação. É definida como:

$$\omega_0 = 2\pi F = 2\pi/T \quad (3.2)$$

De acordo com FILHO et al. (1976), Seja a função temporal $f(t)$, periódica com período T , que obedece às condições de Dirichlet. Em todo ponto de continuidade esta função possui representação equivalente pela série de Fourier, $S_f(t)$, dada pela seguinte equação na forma trigonométrica:

$$S_f(t) = f(t) = \frac{a_0}{2} + \sum_{n=1}^{+\infty} \left[a_n \cos\left(\frac{2n\pi t}{T}\right) + b_n \sin\left(\frac{2n\pi t}{T}\right) \right] \quad (3.3)$$

Onde a_0 , a_n e b_n são os coeficientes calculados pelas respectivas fórmulas:

$$a_0 = \frac{2}{T} \int_{t_0}^{t_0+T} f(t) dt \quad (3.4)$$

$$a_n = \frac{2}{T} \int_{t_0}^{t_0+T} f(t) \cos\left(\frac{2n\pi t}{T}\right) dt \quad (3.5)$$

$$b_n = \frac{2}{T} \int_{t_0}^{t_0+T} f(t) \sin\left(\frac{2n\pi t}{T}\right) dt \quad (3.6)$$

Observa-se que conhecido $S_f(t)$, dado pela equação (3.3), e os coeficientes dados pelas equações (3.4), (3.5) e (3.6), f pode ser reconstruída temporalmente.

Como foi dito anteriormente, a série de Fourier aplica-se somente a sinais periódicos. Quando um sinal não apresenta periodicidade sua representação na frequência é dada em termos da transformada de Fourier. Assim, a equação (3.3) pode ser escrita na forma exponencial da seguinte maneira:

$$S_f(t) = \sum_{n=-\infty}^{+\infty} F_n(e^{j\frac{2n\pi t}{T}}) \quad (3.7)$$

Fazendo $\omega_0 = 2\pi/T$, temos que:

$$F_n = \frac{1}{T} \int_{t_0}^{t_0+T} f(t)(e^{-jn\omega_0 t}) dt \quad (3.8)$$

A equação (3.7) fornece os coeficientes complexos da série de Fourier, descritos por uma magnitude e uma fase.

Um sinal aperiódico f pode ser entendido como um sinal periódico com um período infinito, f_t .

Fazemos o período tendendo ao infinito, ou seja: $T \rightarrow +\infty$

Assim, essa nova função é uma função periódica e pode ser representada por uma série de Fourier.

Se o período tende a ser infinito, f_t tende a ser f , de forma que a série de Fourier que representa f_t também representará f .

Então, pode - se dizer que quando um sinal não apresenta periodicidade, ele pode ser expresso por uma soma contínua, ou seja, uma integral, de sinais exponenciais, generalizando a série de Fourier na forma exponencial:

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} F(\omega) e^{j\omega t} d\omega \quad (3.9)$$

A equação (3.10) é a transformada de Fourier analítica, que fornece a representação em termos de frequência de f . A equação (3.9) é a Transformada inversa de Fourier de F .

$$F(\omega) = \int_{-\infty}^{+\infty} f(t) e^{-j\omega t} dt \quad (3.10)$$

Com o intuito de haver um maior entendimento, exemplifiquemos a visualização do espectro de Fourier de um sinal sintético, $f(t)$, composto por três sinais de frequências distintas, sendo elas, 10, 20 e 30 Hz.

A Figura 2, apresenta um sinal no domínio do tempo ao qual não é possível fazer afirmações, ou sequer visualizar informações, no domínio da frequência.





Figura 2 – Representação de um sinal $y(t)$ no domínio do tempo.

Realizando a Transformada de Fourier desse sinal e obtendo o diagrama do espectro de frequência podemos visualizar sua composição frequencial, conforme o gráfico seguinte.

Vemos a partir da Figura 3 que o sinal $y(t)$ apresenta três amplitudes de frequências distintas se destacando: 10 Hz, 20 Hz e 30 Hz. Este resultado é coerente. O sinal $y(t)$ nada

Figura 3 – Espectro de Fourier do sinal $y(t)$.

mais é do uma soma de três sinais senoidais com frequências diferentes, sintetizados em computador apenas para estudo.

Portanto, pode ser observado que ao se olhar para as análises de Fourier de um sinal, temos informações sobre a frequência global do sinal. No entanto, não é possível realizar nenhuma análise em pequenos trechos do sinal, nem localizar mudanças rápidas de frequências e, ainda, nenhuma informação pode ser retirada acerca da localização temporal das frequências detectadas.

Quando um sinal não apresenta alterações no tempo de suas propriedades estatísticas, isso é irrelevante. Porém, uma classe extensa de sinais apresenta características não estacionárias ou de natureza transiente, para os quais a localização temporal é indispensável.

Para estudar tais sinais é necessário ter à disposição uma transformada que seja capaz de obter a frequência de um sinal localmente no tempo (ou espaço), e que forneça um tratamento detalhado desse sinal. Essa impossibilidade encontrada na Transformada de Fourier possibilitou a criação de métodos de análise em tempo-frequência, tais como, a Transformada de Fourier de Curta Duração (*Short Time Fourier Transform*) e a Transformada Wavelet.

3.2 Transformada de Fourier de Curta Duração (STFT)

Em 1946, o engenheiro Denis Gabor propôs efetuar análises em sinais não estacionários, de forma a se superar a deficiência encontrada na Transformada de Fourier. O método proposto ficou conhecido como Transformada de Fourier de Curta Duração (STFT) ou também conhecida como método de Janelamento.

Gabor adaptou a transformada de Fourier adicionando uma janela, ou seja, uma

função de análise auxiliar no integrando da transformada de Fourier capaz de analisar o sinal dividindo-o em seções de tamanhos iguais. Essa função ficou conhecida como “átomo de Gabor” (LEITE, 2007). Este método é apropriado para identificar aspectos temporais de uma determinada região do sinal. O método consiste em dividir o sinal ou serie temporal em intervalos iguais e aplicar a transformada de Fourier em cada um destes trechos através de uma janela de tamanho fixo e constante por todo o sinal. Vale ressaltar que o fato de a análise de sinal ser completamente feita por uma janela invariante no tempo impede que sejam descritas as altas e as baixas frequências simultaneamente.

A Figura 4 apresenta a representação da STFT, que proporciona informações sobre as localizações temporais das estruturas de frequências de acordo com o tamanho da janela definida para efetuar a análise por todo o sinal. Vale destacar que os tamanhos de janelas, uma vez escolhido um tamanho, eles são iguais por todo o tempo do sinal.




Figura 4 – Representação Transformada de Fourier de Curta Duração (GABOR, 1946).

Para um maior entendimento, são apresentadas três séries temporais com 9 segundos de duração, exemplo semelhante ao de Barbosa e Blitzkow (2008). Cada uma contendo frequências e amplitudes distintas: 1 Hz, 5Hz e 10 Hz, conforme ilustradas na Figura 5. A Figura 6 mostra a resultante da soma dos sinais de 1 Hz e 5 Hz durante os primeiros 4,5 segundos da série, e a soma das frequências de 1 Hz, 5Hz e 10 Hz para os últimos 4,5 segundos.




Figura 5 – Séries temporais de frequências distintas.




Figura 6 – série resultante da soma de duas e três frequências, simultaneamente.

A seguir, na Figura 7, tem-se a Transformada de Fourier efetuada sobre a série temporal mostrada na Figura 6.




Figura 7 – Transformada de Fourier do sinal presente na figura 6.

A seguir é exemplificada a técnica desenvolvida por Gabor. O sinal representado no gráfico da figura 6 é novamente analisado, a fim de obter-se a localização temporal das estruturas de frequências durante o tempo de ocorrência do sinal, também apresentado anteriormente. Para efetuar a análise usando a STFT, a série temporal foi dividida em três seguimentos com intervalos de tempos iguais, três segundos cada uma. Em cada trecho de três segundos será aplicada uma “janela” de mesmo tamanho, fixo para todo o sinal, definida pelos coeficientes determinados no início do procedimento. Em seguida, aplica-se a Transformada de Fourier separadamente em cada trecho. Na primeira janela a Transformada de Fourier ficará como mostrado na Figura 8. Já nas duas janelas seguintes, a TF ficará igual ao que foi mostrado na Figura 7. A técnica percorreu todo o sinal, porém, analisou janela por janela. Diferentemente da transformada de Fourier clássica, agora temos informações temporais e podemos dizer com certa precisão em quais momentos, ou intervalo de tempo, estão localizadas as estruturas de frequências.

Podemos visualizar como as três frequências presentes no sinal estão espalhadas




Figura 8 – Transformada de Fourier da primeira janela.

temporalmente. Vemos que duas frequências estão presentes no primeiro segmentos de fato, e que três frequências (1 Hz, 5 Hz e 10 Hz) estão presentes nas outras duas janelas finais do sinal. Como esperado.

A representação obtida pela Transformada de Fourier fornece alguma informação no tempo, porém, torna-se claro que a sua limitação é dada pelo tamanho da janela que é definida no início do processamento. Uma vez definida o seu tamanho ela irá percorrer todo o sinal sem a possibilidade de ser ajustada aos trechos particulares da função. As wavelets surgiram para suprir tal necessidade.

3.3 Transformada de Wavelet (TW)

A transformada de Fourier é uma ferramenta útil para analisar os componentes de frequência do sinal. No entanto, se tomarmos a transformada de Fourier ao longo de todo o eixo do tempo, não podemos dizer em que instante uma determinada frequência se eleva. A transformada de Fourier de curta duração (STFT) usa uma janela deslizante para encontrar o espectrograma, que fornece as informações de tempo e frequência. Mas ainda existe outro problema: O comprimento da janela limita a resolução na frequência. Transformada Wavelet parece ser uma solução para o problema acima.

A primeira literatura relacionada à transformada wavelet é a wavelet Haar. Foi proposto pelo matemático Alfrèd Haar em 1909. No entanto, o conceito da wavelet não existia na época. Até 1981, o conceito foi proposto pelo geofísico Jean Morlet. Mais tarde, Morlet e o físico Alex Grossman inventaram o termo wavelet em 1984. Antes de 1985, a wavelet Haar era a única wavelet ortogonal que as pessoas conheciam. Muitos pesquisadores até pensaram que não havia nenhuma wavelet ortogonal exceto a wavelet de Haar. Felizmente, o matemático Yves Meyer construiu a segunda wavelet ortogonal chamada wavelet Meyer em 1985. À medida que mais e mais acadêmicos se uniram nesse campo, a 1ª conferência internacional foi realizada na França em 1987.

Em 1988, Stephane Mallat e Meyer propuseram o conceito de multiresolução.

No mesmo ano, Ingrid Daubechies encontrou um método sistemático para construir a wavelet ortogonal de suporte compacto. Em 1989, Mallat propôs a transformação rápida de wavelets. Com o surgimento desse algoritmo rápido, a transformada wavelet teve inúmeras aplicações no campo de processamento de sinais.

O princípio básico da Transformada Wavelet é muito similar ao da Transformada de Fourier, porém ao invés de utilizar senóides infinitas, utiliza outro tipo de funções, agora finitas, conhecidas como wavelets (onduleta), e são representadas por $\Psi_{a,b}$ obtidas através de dilatações e deslocamentos de uma wavelet-mãe representada por Ψ . No caso de wavelets, normalmente não se fala em representação tempo-frequência, mas em representação tempo-escala, porque o termo frequência é reservado a transformada de Fourier” (SANCHES, 2001). A equação matemática das wavelets pode ser representada da seguinte forma:

$$\Psi_{a,b} = \frac{1}{\sqrt{a}} \Psi \left(\frac{t-b}{a} \right) \quad (3.11)$$

O termo a pertence aos números reais e tem a função de realizar uma dilatação da função Ψ . Já o termo b , também pertencente aos números reais, realiza um deslocamento da mesma. O termo $1/\sqrt{a}$ está presente para efeitos de normalização, a fim de permitir que todas as wavelets derivadas da wavelet-mãe possuam a mesma energia (COSTA, 2008).

Para uma onda ser considerada uma wavelet a condição de admissibilidade de ter média zero deve ser cumprida. Essa condição pode ser expressa pela equação (3.12).

$$\int_{-\infty}^{+\infty} \Psi(t) dt = 0 \quad (3.12)$$

Outra condição deve ser satisfeita, de que a função wavelet deve ter energia unitária. Essa condição pode ser expressa de acordo com a equação (3.13).

$$\int_{-\infty}^{+\infty} |\Psi(t)|^2 dt = 1 \quad (3.13)$$

É imposto pela equação 3.12, que nem toda onda pode ser considerada como uma wavelet. Desde então, foram construídas algumas famílias de wavelets que atualmente são utilizadas para o cálculo de sua transformada. Dependendo da aplicação uma família terá melhores resultados que a outra, por isso é importante escolher a wavelet de acordo com a aplicação. A Figura 9 apresenta alguns exemplos de famílias de wavelets existentes atualmente.

A seguir são apresentados os conceitos e detalhes relevantes da Transformada wavelet nas suas versões contínua e discreta.




Figura 9 – Exemplos de famílias de wavelets (AL-GEELANI; PIAH; BASHIR, 2015).

3.3.1 Transformada Wavelet Contínua

A Transformada wavelet contínua (CWT, do inglês *Continuous Wavelet Transform*) de um sinal $x(t)$ pode ser definida como na equação (3.14), sendo esse um dos métodos de maior crescimento no processamento de diversos sinais.

$$C_{a,b} = \int_{-\infty}^{+\infty} x(t) \Psi_{a,b}(t) dt \quad (3.14)$$

Assim, a CWT se torna uma medida da similaridade entre o sinal $x(t)$ e as diferentes formas (escaladas e deslocadas) $\Psi_{a,b}$ da wavelet mãe ψ .

A informação obtida pela CWT pode ser representada de duas maneiras, utilizando um gráfico de intensidade e um gráfico em três dimensões, relacionando o tempo com a escala e os coeficientes $C_{a,b}$, como pode ser visto nas Figuras 10 e 11, respectivamente.




Figura 10 – Representação gráfica da CWT mediante intensidade.




Figura 11 – Representação gráfica da CWT mediante três dimensões.

A compreensão da informação obtida pela CWT pode se basear na relação que existe entre as diferentes escalas calculadas e a frequência. As escalas menores representam as wavelets de curta duração que estarão relacionadas com mudanças rápidas do sinal e,

consequentemente correspondem ao comportamento do sinal em altas frequências. Já no caso das escalas maiores, há uma relação com mudanças lentas do sinal relacionando-se assim com o comportamento em baixas frequências.

A fim de se quantificar a conexão existente entre escalas e frequência, é adequado que cada uma das escalas seja relacionada a uma senóide de frequência conhecida. Um modo de se realizar tal relação está presente em 3.15 (MISITI; OPPENHEIM; POGGI, 2000).

$$F_a = \frac{\Delta * F_c}{a} \quad (3.15)$$

Onde:

Δ - corresponde ao período de amostragem;

a - corresponde à escala em questão;

F_c - é a frequência central da wavelet que representa a principal componente de frequência da mesma.

Através dos parâmetros citados, é possível encontrar o valor de F_a [Hz], que representa a pseudo-frequência associada à wavelet na escala a .

Na Figura 12 é possível observar algumas wavelets superpostas a uma senóide de frequência igual à frequência central das mesmas.

A partir da definição de frequência central e, consequentemente de pseudo-frequência, é possível uma melhor interpretação dos resultados obtidos pela CWT. A partir destes conceitos, basta reconhecer quais são as possíveis componentes em frequência de maior dedução no sinal de acordo com a magnitude dos coeficientes da CWT para diferentes escalas.

3.3.2 Transformada Wavelet Discreta

A Transformada Discreta de Wavelet (DWT - *Discrete Wavelets Transform*) é amplamente utilizada para a análise tempo-frequência de sinais biomédicos (ORHAN; HEKIM; OZER, 2011), especialmente em estudos de sinal de EEG devido às suas características não-estacionárias. A DWT emprega janelas de tempo extensas para baixas frequências e janelas de tempo curto para frequências mais altas, resultando em uma boa análise de tempo e frequência.

A DWT consiste em escolher subconjuntos das escalas a e posições b da wavelet mãe $\Psi(t)$. Utiliza versões discretizadas de wavelets, podendo ser definida de acordo com a equação 3.16.




Figura 12 – Wavelets e senoidais com frequência igual à frequência central (MISITI; OPENHEIM; POGGI, 2000).

$$\Psi_{(a,b)}(t) = 2^{\frac{a}{2}} \Psi\left(2^{-\frac{a}{2}}(t - b)\right) \quad (3.16)$$

A escolha dos parâmetros dilatação (a) e deslocamento (b) baseadas em potência de dois, são conhecidas como dilatação e deslocamento diádicas $\{a_j = 2^{-j}; b_{j,k} = 2^{-j}k\}$ (j e k inteiros). A equação (3.16) mostra que é possível construir uma wavelet para qualquer função, dilatando uma função $\Psi(t)$ com um coeficiente 2^j , e traduzindo a função resultante em uma grade cujo intervalo é proporcional a 2^{-j} (MALLAT, 1989).

As versões contratadas (compactadas) da função wavelet correspondem às componentes de alta frequência, enquanto as versões dilatadas (esticadas) correspondem às componentes de baixa frequência. Então, correlacionando o sinal original com funções wavelet de tamanhos diferentes, os detalhes do sinal podem ser obtidos em várias escalas. Essas correlações com as diferentes funções wavelet podem ser organizadas em um esquema hierárquico chamado decomposição de resolução múltipla. O algoritmo de decomposição de resolução múltipla separa o sinal em detalhes em diferentes escalas e uma representação mais grosseira do sinal denominado aproximação (QUIROGA; NADASDY; BEN-SHAUL, 2004).

A decomposição DWT de um sinal usa sucessivos filtros passa-altas e baixas na filtragem das séries temporais e dois *downsamplers* em 2. O filtro passa-baixas Lo_D é a wavelet mãe discreta e o filtro passa-alta Hi_D é a sua versão espelho (SUBASI, 2007). A saída dos primeiros filtros passa-alta e passa-baixa são referidos como coeficientes de aproximação e detalhados, representados por $cA1$ e $cD1$, respectivamente. Isto é mostrado na Figura 13.




Figura 13 – DWT - uma decomposição do sinal s .

O $cA1$ é ainda decomposto e o procedimento é repetido até que o número especificado de níveis de decomposição seja atingido (JAHANKHANI; KODOGIANNIS; REVETT, 2006).

Na Figura 14 é possível observar a divisão dos coeficientes de aproximação $cA1$ em duas partes usando o mesmo esquema, substituindo s por $cA1$ e produzindo $cA2$ e $cD2$ como mostrado, e assim por diante.




Figura 14 – DWT - decomposição de cada level.

O nível máximo de decomposição é especificado dependendo dos principais componentes de frequência no sinal dado. (ORHAN; HEKIM; OZER, 2011).

Por outro lado, a partir de cAi e cDi , a transformada inversa de wavelets discretos (IDWT) reconstrói o $cAi-1$, invertendo o passo de decomposição inserindo zeros e convolvendo os resultados com os filtros de reconstrução, como mostrado na Figura 15.




Figura 15 – IDWT - reconstrução do sinal.

Uma característica importante da DWT é a Análise de Multiresolução, que permite a análise de diferentes frequências com diferentes resoluções (SANTOS; SILVA; STEDILE, 2014). Essa análise permite uma alta resolução no tempo e baixa escala para altas frequências, e uma baixa resolução no tempo e alta escala para baixas frequências (SANTOS; SILVA; STEDILE, 2014). O que torna essa abordagem útil, já que na prática componentes de alta frequência duram pouco tempo e componentes de baixa frequência duram um longo tempo.

Na Figura 16 é possível identificar a árvore gerada pela análise multiresolução de um sinal amostrado a 500 Hz.




Figura 16 – Árvore gerada pela análise multirresolução do sinal s (SANTOS; SILVA; STE-DILE, 2014).

Através da análise multirresolução, demonstrada anteriormente, os coeficientes das bandas de frequência delta, teta, alfa e beta são adquiridos, dessa forma, possibilitando posterior cálculo das respectivas energias wavelet.

4 Materiais e Métodos - Desenvolvimento do sistema de *neurofeedback*

Esta seção apresenta as tarefas experimentais, a descrição do conjunto de dados coletados, o tratamento dos sinais eletroencefalográficos, o cálculo e análise da densidade espectral de potência e da DWT, além do desenvolvimento do jogo por meio do software Unity.

4.1 Sistema *neurofeedback*

Com o intuito de haver um maior entendimento de todo o sistema desenvolvido, na Figura 17 é possível observar cada etapa do processo e logo abaixo uma breve descrição das mesmas.




Figura 17 – Representação do sistema *neurofeedback* desenvolvido neste trabalho.

Inicialmente, é feita a aquisição dos dados cerebrais através do sistema EEG Cognionics 20 canais a uma taxa de amostragem de 500 Hz. Para se fazer a comunicação online de todo o sistema, a biblioteca *Lab streaming Layer* permite o link entre o EEG e o software Matlab. No software Matlab, serão processados e analisados os dados coletados na etapa de aquisição dos dados cerebrais. O Processamento e análise citados, consistem em pré-processamento, extração de características e classificação. Ao final, se encontra o Jogo, que foi desenvolvido com o intuito de dar *feedback* visual ao usuário, a partir dos dados processados e concluir o sistema *neurofeedback*.

Cada uma das etapas explicitadas anteriormente, serão explicadas com maior detalhe nos tópicos adiante.

4.2 Aquisição atividade cerebral

O sistema de aquisição da atividade cerebral utilizado, consiste de um EEG da empresa Cognionics, Inc. (*Quick - 20 Dry EEG Headset*) com 20 eletrodos ativos distribuídos de acordo com o sistema 10-20 e um pacote de software para o processamento preliminar de dados. A coleta de dados foi feita a uma taxa de amostragem de 500 Hz. Foram utilizados 6 eletrodos posicionados em F3, F4, C3, C4, O1 e O2, com referência em A1. As posições dos eletrodos utilizados estão marcados em vermelho como pode ser identificado na Figura 18.




Figura 18 – Sistema 10-20 com a posição dos eletrodos utilizados.

Para se realizar o treinamento *neurofeedback*, primeiramente, é necessário que se faça uma aquisição da atividade cerebral com o intuito de se treinar o classificador presente no sistema. Isto é, para que seja respeitada a individualidade cerebral, o classificador precisa identificar os padrões cerebrais dos estados de atenção e relaxamento de cada usuário. Para isso, foi proposto um protocolo de treinamento do classificador em que as aquisições foram realizadas e o conjunto de dados foi utilizado para posterior treinamento offline do classificador. O protocolo consistia de duas tarefas de 15 segundos cada e um intervalo de 40 segundos entre cada tarefa, totalizando 1 minuto e 10 segundos de sessão de aquisição, como pode ser identificado na Figura 19. A duração das tarefas e do intervalo foram definidas de forma experimental, em que foi estabelecido um tempo para se obter dados suficientes para se treinar o classificador e um tempo para a transição do estado mental de atenção e relaxamento. As tarefas mentais utilizadas neste estudo foram:

1. Tarefa mental de relaxamento: o participante ficava de frente para um monitor, onde era exibido o espaço estrelado utilizado no jogo. Posteriormente, era comunicado ao mesmo que mantivesse os olhos abertos em um estado de repouso.
2. Tarefa mental de atenção: o participante foi submetido a uma atividade de atenção concentrada, que consistia em focar a visão na nave espacial apresentada no monitor,

que faz parte do jogo, com o objetivo de manter a concentração na nave.




Figura 19 – Protocolo de aquisição da atividade cerebral proposto, para treinamento do classificador.

Após o treinamento do classificador, o sistema estará apto para iniciar o treinamento *neurofeedback* do usuário de forma online. Entretanto, para que o sistema fosse capaz de fazer todas as aplicações funcionarem em sincronismo e de forma online, utilizou-se uma ferramenta chamada *Lab streaming layer*.

4.3 Lab streaming layer (LSL)

O *Lab streaming layer* é uma ferramenta disponível no github ([KOTHE, 2018](#)), que permite a troca de séries temporais entre dispositivos, programas e computadores ([REIS et al., 2014](#)). O LSL é utilizado para coletar as séries temporais de forma unificada em trabalhos de pesquisa. é composta de uma biblioteca central de transporte que contempla várias interfaces de linguagem (C, C ++, Python, Java, C #, MATLAB) e uma série de aplicativos. Esses aplicativos incluem um programa de gravação, visualizadores *on-line*, importadores e software de aquisição. Esses programas de aquisição podem adquirir dados de vários hardwares, como por exemplo, EEG, rastreamento de olhos, captura de movimento, entre outros equipamentos de vários fabricantes.

A utilização desta ferramenta garante algumas vantagens que são de suma importância ao sistema *neurofeedback* proposto, que são: a gama de interfaces de linguagem suportadas, facilitando ao usuário a utilização da ferramenta; trabalha com taxa de amostragem regular ou irregular, com tipos de valor uniformes (inteiros, flutuantes, duplos, sequências de caracteres); possui um relógio embutido que permite registrar o tempo das amostras transmitidas para que possam ser sincronizadas mutuamente; e os dados são

armazenados em *buffer* no lado do emissor e do receptor (com *buffers* configuráveis e arbitrariamente grandes) para tolerar falhas de rede intermitentes.

4.4 Pré-processamento

Uma vez digitalizados, os sinais EEG precisam ser pré-processados (ORMIGA, 2010). Para selecionar a banda de frequência de interesse desse estudo, foram projetados filtros digitais.

Um filtro *Butterworth* passa-faixa com frequência de corte em 1 Hz e 30 Hz foi projetado no intuito de selecionar as bandas de frequência relacionadas ao objetivo do trabalho. O filtro foi definido visando uma resposta mais plana da magnitude na banda passante, assim como uma resposta em fase mais linear (AMIN et al., 2015).

Por fim, foi aplicado um filtro *Notch* em 60 Hz, pois a rede elétrica é uma fonte de ruído remanescente que apresenta grande amplitude (ORMIGA, 2010).

4.5 Extração de características

A extração de informações relevantes dos sinais após o seu pré-processamento é um passo crítico na classificação do padrão de EEG, devido à sua influência direta no desempenho da classificação.

Desta forma, foram propostos dois métodos para se extrair as características mais relevantes dos sinais EEG, que são: A transformada discreta de wavelet (DWT) e o método de Welch, onde as características processadas foram a energia wavelet relativa e a densidade espectral de potência (DSP), respectivamente.

4.5.1 Energia wavelet relativa

A energia wavelet de cada nível de decomposição $i = 1, \dots, L$ foi calculada da seguinte forma (AMIN et al., 2015):

$$E_{D_i} = \sum_{j=1}^N |D_{ij}|^2, i = 1, 2, 3, \dots, L \quad (4.1)$$

$$E_{A_i} = \sum_{j=1}^N |A_{ij}|^2, i = L \quad (4.2)$$

sendo L , o máximo nível de decomposição da DWT. O valor da energia total pode ser definido como:

$$E_{Total} = \left(\sum_{i=1}^L E_{D_i} + E_{A_i} \right) \quad (4.3)$$

E os valores da energia normalizada representam a energia wavelet relativa, para cada sub-banda.

$$E_r = \frac{E_j}{E_{Total}} \quad (4.4)$$

Onde $E_j = E_{D_{i=1,...,L}}$ ou $E_{A_{i=L}}$

Através da equação 4.4 foram extraídas as seguintes características:

Energia relativa Teta (4-7 Hz); Energia relativa Alfa (8-12 Hz); Energia relativa Beta (15-19 Hz); e Relação entre as energias relativas Teta/Beta.

4.5.2 Densidade Espectral de Potência (PSD)

Nesta etapa, os sinais foram transformados do domínio do tempo para o domínio da frequência por meio do método de Welch para se obter o espectro de densidade de potência (DSP).

No método de Welch, os segmentos de dados do sinal são divididos em segmentos de dados L, que possuem pontos M e são sobrepostos por pontos D. Para $D = \frac{M}{2}$, a sobreposição é de 50% e, para $D = 0$, a sobreposição é de 0%. Cada um desses segmentos de dados pode ser multiplicado com uma função de janela (Hamming) e o periodograma do produto é calculado para os segmentos individuais e a média desses periodogramas é o resultado do método de Welch.

Para cada segundo de sinal EEG obtido foi calculada a DSP, afim de descrever a distribuição da potência do sinal em relação à frequência ([LEON-GARCIA, 1994](#)).

Através da DSP, foram extraídas cinco características:

Potência sinal Teta (4-7 Hz); Potência sinal Alfa (8-12 Hz); Potência sinal Beta (15-19 Hz); Relação entre as potências Teta/Beta; e Relação entre as potências Alfa/Beta.

Com as características extraídas, foi gerada uma matriz de treinamento para o classificador. A matriz gerada foi composta de 30 amostras (15 no estado de atenção e 15 no estado de relaxamento) por 30 características, sendo 5 características calculadas para cada eletrodo.

4.6 Análise linear discriminante (LDA)

A Análise linear discriminante (LDA) é mais comumente usada como técnica de redução de dimensionalidade na etapa de pré-processamento para aplicações de classificação de padrões e de aprendizado de máquina (THARWAT et al., 2017). Esse algoritmo tem como objetivo projetar um conjunto de dados em um espaço de menor dimensão com boa separabilidade de classe, a fim de reduzir o custo computacional e evitar o *overfitting*, que pode ser definido como o sobre ajuste dos dados de treinamento, conferindo bons resultados para fase de treino do classificador e resultados ruins na fase de teste do mesmo.

A abordagem geral do LDA é que através de uma combinação linear, seja possível encontrar os eixos componentes que maximizam a variância dos dados e os eixos que maximizam a separação entre múltiplas classes.

Esta técnica foi utilizada neste estudo para reduzir a dimensionalidade das características extraídas dos sinais EEG, afim de comprimir as trinta características extraídas (cinco características por eletrodo) em cinco (uma para cada eletrodo) com a finalidade de facilitar a classificação do SVM.

4.7 Classificação

4.7.1 Support Vector Machine (SVM)

Máquinas de vetores suporte é um tipo de classificador desenvolvido na teoria de aprendizagem estatística (SLT). Ele mapeia não linearmente o espaço de entrada para um espaço de recurso de alta dimensão e, em seguida, constrói um hiperplano de classificação ideal linear no espaço de recurso, que se relaciona a um hiperplano não linear no espaço de entrada (ZHIWEI; MINFEN, 2007).

Os dados de um lado deste hiperplano são classificados como pertencentes a uma classe, enquanto os dados do outro lado pertencem à outra classe.

Aplicando-se SVM, é gerado um modelo de classificação na forma de função linear $f(x) = w * x + b$. A localização do hiperplano é definida como $f(x) = 0 = w * x + b$. O exemplo na Figura 20 mostra alguns círculos azuis no lado esquerdo, que representam dados pertencentes à classe 1, e alguns círculos verdes no lado direito, que representam dados pertencentes à classe 2. Os círculos azuis estão no lado do hiperplano, que corresponde ao caso quando $f(x) > 0$ e os círculos verdes estão no lado do hiperplano, que correspondem ao caso em que $f(x) < 0$. Olhando para a localização dos dados em relação ao hiperplano, a classe à qual os dados pertencem pode ser identificada pelo modelo.




Figura 20 – SVM linear, separando duas classes de dados (LARHMAM, 2018).

A matriz de treinamento gerada é utilizada para que o classificador modele os dados fornecidos de forma a maximizar a separação entre as classes de relaxamento e atenção. Após construído o modelo, as novas amostras fornecidas no treinamento *neurofeedback* são classificadas pelo SVM que atribui à amostra o valor de uma das classes, levando em consideração o modelo construído no treinamento. Este método de classificação foi utilizado, tendo em vista que é um dos mais utilizados na literatura, devido aos bons resultados quando aplicados a sinais EEG (AMIN et al., 2015; HARIHARAN et al., 2014).

4.8 Jogo

A fim de dar continuidade ao desenvolvimento do treinamento *neurofeedback*, o software Unity foi utilizado para elaborar um jogo para interagir com o indivíduo. O desenvolvimento do jogo utilizado nessa pesquisa foi realizado pelos estudantes do grupo BRAEN.

Para aliar diversão ao tratamento, um jogo no estilo espaço sideral foi delineado com intuito de comparar o sistema EEG com um capacete utilizado por pilotos nestes jogos. O ambiente virtual consiste de uma nave espacial que coleta estrelas, que são convertidas em pontuação, ao longo de um caminho criado pelo próprio ambiente. O *feedback* é fornecido através da velocidade da nave espacial, quanto mais prolongado o estado de atenção, maior a velocidade da nave. Quando o usuário entra em estado mental de relaxamento, a nave perde velocidade gradualmente.

O treinamento *neurofeedback* tem como objetivo fazer o indivíduo aprender a manter a nave espacial na maior velocidade possível e coletando as estrelas pelo maior intervalo de tempo. A Figura 21 apresenta a interface gráfica desenvolvida no software.




Figura 21 – Interface do game desenvolvido.

Junto ao jogo é apresentado o tempo restante para o fim do jogo a pontuação (número de estrelas coletadas) atual e uma barra representando a velocidade atual da nave.

5 Validação experimental

O sistema *neurofeedback* desenvolvido foi validado frente aos dados experimentais de acurácia do classificador SVM e a resposta ao usuário, obtidos neste trabalho para os dois métodos de extração de características adotados, o método de Welch e a DWT. Entretanto, o método de Welch foi o que apresentou os melhores resultados, visto que para o método DWT a resposta ao usuário não foi satisfatória, mesmo apresentando altos valores de acurácia do classificador.

5.1 Protocolo experimental

5.1.1 Participantes

Para o estudo, foram realizados o treinamento *neurofeedback* de cinco participantes saudáveis (dois homens e três mulheres com idade entre 21 e 30 anos). Todos participaram de forma voluntária neste estudo.

Cada uma das coletas de dados e treinamentos *neurofeedback* foram realizados no laboratório de pesquisa do grupo BRAEN¹. No momento do experimento, eles estavam livres de qualquer medicação, drogas, distúrbios neurológicos ou lesões que pudessem afetar os resultados experimentais. Nenhum dos indivíduos tinham experimentado a tarefa cognitiva usada neste estudo.

5.1.2 Base de dados

Como citado previamente, antes do treinamento *neurofeedback* de cada usuário, realizou-se um processo de calibração do sistema para respeitar a individualidade cerebral, que consiste em treinar o classificador. Com isso, foi gerada uma base de dados com todos os usuários, possibilitando uma posterior análise offline.

Após a calibração do sistema, cada usuário foi exposto ao treinamento *neurofeedback*, onde a partir dos dados coletados durante o treinamento, foi possível analisar a acurácia do classificador SVM e a resposta do jogo ao usuário de forma online e com isso se validar o sistema proposto.

¹ Brazilian Research Group on Brain and Cognitive Engineering (www.braen.ufes.br)

5.2 Resultados

A utilização da ferramenta *lab streaming layer* para fazer a comunicação do sistema *neurofeedback* foi de grande importância, visto que o sistema tem que trabalhar de forma *online* e com a menor taxa de atraso possível, a fim de garantir ao usuário que o estado mental está sendo exposto a cada instante de tempo. O LSL garantiu ao sistema uma taxa de amostragem regular de 500 Hz, além de armazenar todos os dados coletados em um *buffer* para posterior análise *offline*.

Antes de efetuar o treinamento *neurofeedback*, é necessário fazer um registro da atividade cerebral de cada usuário em um estado de atenção e em um estado de relaxamento, com o intuito de treinar o classificador presente no sistema. Isto é, para que seja respeitada a individualidade cerebral, o classificador precisa identificar os padrões cerebrais dos dois estados cognitivos. Isso se deve ao fato do classificador ser supervisionado, ou seja, Selecionam-se amostras representativas para cada uma das classes (Atenção e Relaxamento) que se deseja classificar.

Para tanto, foi proposto um protocolo de treinamento do classificador em que os registros foram realizados, e deles, foram extraídas as características para um posterior treinamento offline do classificador.

Este estudo inicialmente utilizou uma única característica para classificação, como por exemplo, a potência do sinal captado de apenas um eletrodo; no entanto, a taxa de acurácia não ultrapassou 50%. Portanto, surgiu a necessidade de se combinar características para serem usadas como base para o sistema de classificação e se aumentar o número de eletrodos utilizados.

Foram utilizados 6 eletrodos neste estudo, sendo eles: F3, F4, C3, C4, O1, O2. Inicialmente os sinais adquiridos através dos eletrodos citados passou pela etapa de pré-processamento, que consistia em filtrar os sinais com o intuito de se reduzir os artefatos da rede elétrica (filtro *Notch*, centrado em 60 Hz) e selecionar as bandas de frequência de interesse (filtro *Butterworth* 1-30 Hz). Os filtros utilizados foram capazes de mitigar alguns possíveis artefatos que poderiam interferir nos dados coletados, e assim, inviabilizar o estudo.

Após o pré-processamento dos sinais, as suas características foram extraídas através de dois métodos, a DWT e o método de Welch.

O primeiro método foi através da DWT, que consiste em decompor os sinais cerebrais nas sub-bandas alfa, teta, beta, delta e gama, com a intenção de calcular a energia relativa das mesmas e utiliza-las como características. A decomposição do sinal em suas respectivas bandas de frequência podem ser vistas na Figura 22.




Figura 22 – Decomposição do sinal original em suas sub-bandas.

A Tabela 1 apresenta os valores das energias relativas wavelet nos 5 primeiros segundos de aquisição do sinal EEG na tarefa de atenção de um usuário. A partir destes dados é possível observar que a energia em beta está alta, o que demonstra que o participante se manteve em um estado de atenção. A banda de frequência gama também apresentou valores altos, que de fato está de acordo com o esperado, uma vez que essa banda é modulada pela entrada sensorial e processos internos, como memória de trabalho e atenção (JIA; KOHN, 2011).

	Gamma (%)	Beta (%)	Alfa (%)	Teta (%)	Delta (%)
1º segundo	59,4783	32,2364	2,3955	0,9805	4,9093
2º segundo	72,982	20,3138	4,701	0,315	1,6881
3º segundo	77,7248	20,2392	0,9076	0,2963	0,8321
4º segundo	65,3099	16,4634	10,9369	1,9105	5,3793
5º segundo	44,6705	49,8131	3,0159	0,4982	2,0023

Tabela 1 – Valores das energias relativas wavelet nos 5 primeiros segundos da tarefa de atenção.

Os resultados da classificação para o DWT, não foram proeminentes em todos os níveis de decomposição. O maior desempenho de classificação foi encontrado na energia relativa dos coeficientes de aproximação e coeficientes detalhados de nível 4, que refletiram as dominâncias de baixa frequência.

O segundo método foi a partir do cálculo da densidade espectral de potência de cada segundo do sinal coletado, em que se verifica a frequência mais significativa a cada segundo e, assim, é possível definir se o participante estava em estado de atenção ou não. Na Figura 23 é possível observar a frequência predominante quando o sujeito realizava a

tarefa de atenção, sendo que essa se localizou dentro da banda de frequência beta (14-30 Hz). A Figura 24 apresenta a PSD, com predominância do ritmo alfa (8-14 Hz), para o mesmo sujeito executando a tarefa de relaxamento.




Figura 23 – Gráfico PSD da atividade de atenção.




Figura 24 – Gráfico PSD da atividade de relaxamento.

Para esse método, os resultados de acurácia do classificador foram não só superiores, mas também houve uma melhor resposta do jogo para com o usuário, apresentando menor atraso de resposta e maior veracidade.

Tanto as características de energia wavelet relativa extraída pelo método DWT quanto as características da densidade espectral de potência extraída pelo método de Welch foram classificadas usando o classificador SVM com kernel RBF para ambas as condições de EEG, usuário em atividade de atenção e relaxamento. Vale ressaltar que a escolha das características para cada método empregado foi determinada a partir do grau de influência que cada característica obteve na precisão da classificação. Na figura 25, está presente a representação do classificador SVM para as duas classes (atenção e relaxamento) de um usuário durante o treinamento do classificador. Os pontos vermelhos correspondem ao estado de atenção e os verdes o de relaxamento.




Figura 25 – Plot classificador SVM para as duas classes (atenção e relaxamento) de um usuário durante o treinamento do classificador.

O maior valor de acurácia encontrado foi através do método de Welch, em que o classificador SVM alcançou 92,50% de precisão para o usuário 5. Na Tabela 2, estão presentes as acurácias obtidas através dos dois métodos de extração de características, para todos os 5 usuários. Um dos fatores que favoreceu os altos valores de acurácia para os dois métodos foi a utilização da análise linear discriminante (LDA), uma vez que, reduzindo a dimensionalidade das características extraídas foi facilitada a classificação dos dados pelo classificador.

Usuário	Transformada wavelet discreta (DWT)	Método de Welch (DSP)
	Acurácia (%)	
1	82,50	86,66
2	77,50	83,33
3	85,00	90,00
4	68,00	76,66
5	85,00	92,50

Tabela 2 – Acurácia do classificador SVM para cada método de extração e indivíduo.

A partir da Tabela 2, é possível observar uma variação entre as acurácias dos participantes, podendo chegar a uma diferença de 15,84% para o Método de Welch e de 17% para a DWT. supõe-se que essa diferença se deve a dois fatores. O primeiro fator está relacionado às aquisições dos sinais cerebrais feitas no protocolo de treinamento do classificador, em que os usuários foram submetidos a duas tarefas mentais, uma de atenção e uma de relaxamento. Durante as tarefas, quanto mais o usuário conseguisse distinguir o seu estado mental durante a tarefa de atenção e a de relaxamento, melhor seria a acurácia do classificador, caso contrário, o classificador apresentaria uma baixa acurácia. O segundo fator tem relação com os eletrodos utilizados no estudo. Para todos os usuários, os eletrodos utilizados foram: F3, F4, C3, C4, O1, O2. Com isso, não estão sendo

consideradas as individualidades das atividades cerebrais dos participantes, uma vez que um dado indivíduo possa apresentar mais bandas de frequência beta na região pré-frontal do cérebro do que outras, por exemplo. Para esse caso, um dos trabalhos futuros consiste em se fazer um mapeamento cerebral de cada usuário para se identificar as regiões de maior influência das bandas teta e beta, e assim, selecionar os eletrodos localizados nas posições identificadas.

Após a realização do treinamento *neurofeedback*, utilizando o método Welch, os participantes do estudo relataram que o jogo teve boa resposta com o estado mental realizado pelos mesmos. Poucas vezes a intenção não era correspondida pelo ambiente virtual, isto é, quando o participante prestava atenção, a nave diminuía a velocidade. Já para o treinamento utilizando a DWT para extrair as características, o jogo não respondeu da mesma forma, apresentando falta de concordância entre o estado dos usuários e o retorno do sistema para com o mesmo.

6 Conclusão

6.1 Conclusão

Os resultados mostraram que a melhor acurácia do classificador é alcançada quando cinco características são usadas simultaneamente. No entanto, a influência que cada característica tem na precisão da classificação é diferente. Das características, o valor delta causa as mudanças mais significativas e pode influenciar a precisão da classificação em até 7%. Isso foi raramente observado em estudos anteriores.

Os resultados também indicam que o estado de atenção é um fenômeno contínuo, e que a observação de dados de um período limitado é ligeiramente superior à precisão de classificação de uma única entrada de dados. Além disso, o padrão dos sinais cerebrais de um usuário no estado de atenção são mais fáceis de identificar em comparação com os de relaxamento; isso ocorre porque os sinais de estado de relaxamento do EEG contêm informações adicionais, como por exemplo, movimento da cabeça e movimento ocular.

Um requisito importante para a correta identificação é que, ao se realizar o protocolo de treinamento do classificador, o usuário deve seguir as orientações a risca, já que as ondas cerebrais estão fortemente ligadas ao nível de consciência, fazendo com que o sistema possa cometer erros, pois mesmo estando no estado de atenção solicitado, o usuário poderá estar estimulando a atividade cerebral. Por exemplo, ao se manter a atenção na nave, começar a contar números mentalmente.

O método de Welch se mostrou superior à DWT na etapa de extração de característica, uma vez que além das boas taxas de acurácia, obteve um melhor tempo de resposta ao usuário.

Uma contribuição importante alcançada foi a apresentação de uma abordagem para a identificação de estado mental de atenção, a partir de dois métodos de extração de características, sendo eles a Transformada wavelet discreta (DWT) e a Densidade espectral de potência (PSD), com a utilização do classificador supervisionado SVM.

A aplicação dos métodos propostos resultou num sistema capaz de identificar o estado mental de atenção, obtendo resultados comparáveis aos resultados obtidos na literatura referenciada. Assim, o estudo aqui apresentado pode ser utilizado para a implementação de um sistema de treinamento baseado em *neurofeedback* para reforço de atenção.

Os resultados desse trabalho foram publicados em forma de artigo completo no II Congresso Brasileiro de Pesquisa & Desenvolvimento em Tecnologia Assistiva (CBTA

- 2018), além de ser publicado no livro "Tecnologia Assistiva: Pesquisa e Conhecimento – II" (ISBN: 978-85-7917-513-8) com o título "Identificação de estado mental de atenção através do EEG para aplicação em treinamento Neurofeedback". O mesmo artigo foi publicado em forma de resumo no 5º Congresso BRAINN (*Brazilian Institute of Neuroscience and Neurotechnology*). O trabalho em forma de artigo completo também foi submetido e aprovado no 6th *International Congress on Neurotechnology, Electronics and Informatics* (Neurotechnix - 2018), porém o mesmo não pode ser apresentado.

6.2 Trabalhos futuros

No momento, e como passo subsequente deste estudo, o *feedback* visual e sonoro está sendo aprimorado para um ambiente de realidade virtual, com vistas a propiciar maior imersão/engajamento nas sessões de treinamento NFB.

Pretende-se também, desenvolver um algoritmo capaz de identificar as regiões cerebrais com maior influência das bandas teta e beta, de forma a se respeitar a individualidade cerebral de cada usuário, e consequentemente, obter maiores valores de acurácia do classificador.

Espera-se que seja ampliada a gama de classificadores utilizados no sistema, além do SVM, para se fazer uma comparação e definir qual o que obteve melhores resultados.

Por fim, uma etapa futura de validação em sujeitos com diagnóstico de TDAH poderia indicar o uso deste sistema como terapia de suporte ao tratamento deste distúrbio.

Referências

- AL-GEELANI, N. A.; PIAH, M. A. M.; BASHIR, N. A review on hybrid wavelet regrouping particle swarm optimization neural networks for characterization of partial discharge acoustic signals. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 45, p. 20–35, 2015. Citado 2 vezes nas páginas 11 e 42.
- ALEGRIA, A. A. et al. Real-time f mri neurofeedback in adolescents with attention deficit hyperactivity disorder. *Human brain mapping*, Wiley Online Library, v. 38, n. 6, p. 3190–3209, 2017. Citado na página 18.
- ALVES, L. S. Medição de biopotenciais - o estado da arte. <http://cta.if.ufrgs.br/projects/instrumentacao-fisica/wiki>. Acessado em Outubro, 2018. Citado na página 24.
- AMIN, H. U. et al. Feature extraction and classification for eeg signals using wavelet transform and machine learning techniques. *Australasian physical & engineering sciences in medicine*, Springer, v. 38, n. 1, p. 139–149, 2015. Citado 2 vezes nas páginas 52 e 55.
- APPOLINÁRIO, F. *Avaliação dos efeitos do treinamento em neurofeedback sobre o desempenho cognitivo de adultos universitários*. Tese (Doutorado) — Universidade de São Paulo, 2001. Citado 2 vezes nas páginas 25 e 27.
- ARNS, M. et al. Efficacy of neurofeedback treatment in adhd: the effects on inattention, impulsivity and hyperactivity: a meta-analysis. *Clinical EEG and neuroscience*, SAGE Publications Sage CA: Los Angeles, CA, v. 40, n. 3, p. 180–189, 2009. Citado 2 vezes nas páginas 21 e 24.
- BARBOSA, A. C.; BLITZKOW, D. Ondaletas: Histórico e aplicação. *São Paulo*, 2008. Citado na página 38.
- BARBOSA, G.; BARBOSA, A. d. A. G. Síndrome hiperkinética: sintomas e diagnóstico. *Pediatr Mod*, v. 36, n. 8, p. 544, 2000. Citado na página 17.
- CABALLO, V. E.; CLAUDINO, M. D. *Manual de técnicas de terapia e modificação do comportamento*. [S.l.]: Santos, 1996. Citado na página 21.
- CASSE, R. et al. Positron emission tomography and epilepsy. *Molecular Imaging & Biology*, Elsevier, v. 4, n. 5, p. 338–351, 2002. Citado na página 31.
- COSTA, M. V. C. Compressão de sinais de eletromiografia explorando correlação bidimensional. 2008. Citado na página 41.
- CRISWELL, E. *Biofeedback and somatics: Toward personal evolution*. [S.l.]: Freeperson Press, 1995. Citado 2 vezes nas páginas 22 e 23.
- DEMITRI, M. *Types of Brain Imaging Techniques*. *Psych Central*. 2007. Citado na página 30.
- DEMOS, J. N. *Getting started with neurofeedback*. [S.l.]: WW Norton & Company, 2005. Citado na página 22.

- 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*, BioMed Central, v. 3, n. 1, p. 35, 2007. Citado 2 vezes nas páginas 28 e 29.
- 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*, Frontiers, v. 11, p. 51, 2017. Citado 3 vezes nas páginas 21, 27 e 28.
- EPSTEIN, C. American clinical neurophysiology society guideline 5: Guidelines for standard electrode position nomenclature. *J. Clin. Neurophysiol.*, v. 23, n. 2, p. 107–110, 2006. Citado na página 26.
- FILHO, A. F. et al. *SPIEGEL, MR Análise de Fourier*. [S.l.]: São Paulo: McGraw-Hill do Brasil, 1976. Citado na página 34.
- GABOR, D. Theory of communication. part 1: The analysis of information. *Journal of the Institution of Electrical Engineers-Part III: Radio and Communication Engineering*, IET, v. 93, n. 26, p. 429–441, 1946. Citado 2 vezes nas páginas 11 e 38.
- GEVENSLEBEN, H. et al. Neurofeedback training in children with adhd: 6-month follow-up of a randomised controlled trial. *European child & adolescent psychiatry*, Springer, v. 19, n. 9, p. 715–724, 2010. Citado 2 vezes nas páginas 28 e 29.
- GOLDMAN, L. S. et al. Diagnosis and treatment of attention-deficit/hyperactivity disorder in children and adolescents. *Jama*, American Medical Association, v. 279, n. 14, p. 1100–1107, 1998. Citado na página 17.
- GURGEL, V. C. *Aplicação de técnicas wavelets em análise de séries temporais para detecção de correlações*. 2013. Citado 2 vezes nas páginas 33 e 34.
- HAGINOYA, K. et al. Ictal cerebral haemodynamics of childhood epilepsy measured with near-infrared spectrophotometry. *Brain*, Oxford University Press, v. 125, n. 9, p. 1960–1971, 2002. Citado na página 30.
- HARIHARAN, M. et al. Classification of mental tasks using stockwell transform. *Computers & Electrical Engineering*, Elsevier, v. 40, n. 5, p. 1741–1749, 2014. Citado na página 55.
- HEINRICH, H.; GEVENSLEBEN, H.; STREHL, U. Annotation: Neurofeedback—train your brain to train behaviour. *Journal of Child Psychology and Psychiatry*, Wiley Online Library, v. 48, n. 1, p. 3–16, 2007. Citado na página 18.
- JAHANKHANI, P.; KODOGIANNIS, V.; REVETT, K. Eeg signal classification using wavelet feature extraction and neural networks. In: IEEE. *Modern Computing, 2006. JVA'06. IEEE John Vincent Atanasoff 2006 International Symposium on*. [S.l.], 2006. p. 120–124. Citado na página 46.
- JASPER, H. H. The ten-twenty electrode system of the international federation. *Electroencephalogr. Clin. Neurophysiol.*, v. 10, p. 370–375, 1958. Citado na página 27.
- JIA, X.; KOHN, A. Gamma rhythms in the brain. *PLoS biology*, Public Library of Science, v. 9, n. 4, p. e1001045, 2011. Citado na página 59.

JOHNSTONE, S. J. et al. Game-based combined cognitive and neurofeedback training using focus pocus reduces symptom severity in children with diagnosed ad/hd and subclinical ad/hd. *International Journal of Psychophysiology*, Elsevier, v. 116, p. 32–44, 2017. Citado 2 vezes nas páginas 18 e 21.

JONAS, W. B.; LEVIN, J. S. *Tratado de medicina complementar e alternativa*. [S.l.]: Editora Manole Ltda, 2001. Citado na página 23.

KAISER, D. A.; OTHMER, S. Effect of neurofeedback on variables of attention in a large multi-center trial. *Journal of Neurotherapy*, Taylor & Francis, v. 4, n. 1, p. 5–15, 2000. Citado na página 18.

KOTHE, C. Lab streaming layer (lsl). <https://github.com/scn/labstreaminglayer>. Accessed on January, v. 26, p. 2015, 2018. Citado na página 51.

KROPOTOV, J. *Qualitative EEG, event related potentials and neuropathy*. [S.l.]: San Diego: Academic Press, 2009. Citado na página 24.

KROPOTOV, J. D. et al. Erps correlates of eeg relative beta training in adhd children. *International journal of psychophysiology*, Elsevier, v. 55, n. 1, p. 23–34, 2005. Citado 2 vezes nas páginas 28 e 29.

KRUCOFF, M. O. et al. Enhancing nervous system recovery through neurobiologics, neural interface training, and neurorehabilitation. *Frontiers in neuroscience*, Frontiers, v. 10, p. 584, 2016. Citado na página 21.

LARHMAM. Hiperplano e margem de margem máxima para um svm treinado em duas classes. as amostras nas margens são chamadas de vetores de suporte. <https://commons.wikimedia.org>. Accessed on October, 2018. Citado 2 vezes nas páginas 11 e 55.

LARSEN, S.; SHERLIN, L. Neurofeedback: an emerging technology for treating central nervous system dysregulation. *Psychiatric Clinics*, Elsevier, v. 36, n. 1, p. 163–168, 2013. Citado na página 21.

LEITE, F. E. A. Análise estatística de padrões sísmicos: decomposição em multiescala. Universidade Federal do Rio Grande do Norte, 2007. Citado na página 38.

LEON-GARCIA, A. *Probability and Random Processes for Electrical Engineering: Student Solutions Manual*. [S.l.]: Pearson Education India, 1994. Citado na página 53.

LUBAR, J. F. Neocortical dynamics: Implications for understanding the role of neurofeedback and related techniques for the enhancement of attention. *Applied psychophysiology and biofeedback*, Springer, v. 22, n. 2, p. 111–126, 1997. Citado na página 18.

LUBAR, J. F.; SHOUSE, M. N. Eeg and behavioral changes in a hyperkinetic child concurrent with training of the sensorimotor rhythm (smr). *Biofeedback and Self-regulation*, Springer, v. 1, n. 3, p. 293–306, 1976. Citado na página 24.

MACEDO, D. D. R. R. Análise espectral de eletroencefalografia para registros patológicos. *Horizonte Científico*, v. 5, n. 1, 2011. Citado na página 34.

- MALLAT, S. G. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE transactions on pattern analysis and machine intelligence*, Ieee, v. 11, n. 7, p. 674–693, 1989. Citado na página 45.
- MIHARA, M. et al. Neurofeedback using real-time near-infrared spectroscopy enhances motor imagery related cortical activation. *PloS one*, Public Library of Science, v. 7, n. 3, p. e32234, 2012. Citado na página 21.
- MISITI, M. M.; OPPENHEIM, Y.; POGGI, G. J.-M.: *Wavelet Toolbox User's Guide (Version 2.1)*, The MathWorks. [S.l.]: Inc, 2000. Citado 3 vezes nas páginas 11, 44 e 45.
- MORIYAMA, T. S. et al. Evidence-based information on the clinical use of neurofeedback for adhd. *Neurotherapeutics*, Springer, v. 9, n. 3, p. 588–598, 2012. Citado na página 23.
- MULERT, C. Simultaneous eeg and fmri: towards the characterization of structure and dynamics of brain networks. *Dialogues in clinical neuroscience*, Les Laboratoires Servier, v. 15, n. 3, p. 381, 2013. Citado na página 29.
- NEUPER, C.; PFURTSCHELLER, G. Neurofeedback training for bci control. In: *Brain-computer interfaces*. [S.l.]: Springer, 2009. p. 65–78. Citado na página 21.
- NIEDERMEYER, E.; SILVA, F. L. da. *Electroencephalography: basic principles, clinical applications, and related fields*. [S.l.]: Lippincott Williams & Wilkins, 2005. Citado na página 26.
- NISO, G. et al. Omega: the open meg archive. *Neuroimage*, Elsevier, v. 124, p. 1182–1187, 2016. Citado na página 30.
- 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. Citado na página 25.
- OCAZONEZ, S. A. C. Processamento no domínio da frequência de sinais de eletroencefalografia coletados durante protocolo de estresse moderado. 2009. Citado na página 33.
- OGAWA, S. et al. Intrinsic signal changes accompanying sensory stimulation: functional brain mapping with magnetic resonance imaging. *Proceedings of the National Academy of Sciences*, National Acad Sciences, v. 89, n. 13, p. 5951–5955, 1992. Citado na página 29.
- ORHAN, U.; HEKIM, M.; OZER, M. Eeg signals classification using the k-means clustering and a multilayer perceptron neural network model. *Expert Systems with Applications*, Elsevier, v. 38, n. 10, p. 13475–13481, 2011. Citado 2 vezes nas páginas 44 e 46.
- ORMIGA, A. *Controle de um manipulador robótico através de uma interface cérebro máquina não-invasiva com aprendizagem mútua*. Tese (Doutorado) — M. Sc. Dissertation, PUC-Rio, Rio de Janeiro, Brazil, 2010. Citado na página 52.
- PEEK, C. J. A primer of biofeedback instrumentation. Guilford Press, 1995. Citado 2 vezes nas páginas 21 e 27.

- POLANCZYK, G.; ROHDE, L. A. Epidemiology of attention-deficit/hyperactivity disorder across the lifespan. *Current opinion in psychiatry*, LWW, v. 20, n. 4, p. 386–392, 2007. Citado na página 17.
- PORTUGAL, V. *Olhando para dentro: Insight, consciência e transcendência*. [S.l.]: Gryphus Editora, 2017. Citado na página 25.
- QUIROGA, R. Q.; NADASDY, Z.; BEN-SHAUL, Y. Unsupervised spike detection and sorting with wavelets and superparamagnetic clustering. *Neural computation*, MIT Press, v. 16, n. 8, p. 1661–1687, 2004. Citado na página 45.
- REIS, P. et al. Methodological aspects of eeg and body dynamics measurements during motion. *Frontiers in human neuroscience*, Frontiers, v. 8, p. 156, 2014. Citado na página 51.
- ROGALA, J. et al. The do's and don'ts of neurofeedback training: a review of the controlled studies using healthy adults. *Frontiers in human neuroscience*, Frontiers, v. 10, p. 301, 2016. Citado 2 vezes nas páginas 22 e 28.
- SANCHES, I. J. Compressão sem perdas de projeções de tomografia computadorizada usando a transformada wavelet. 2001. Citado na página 41.
- SANTOS, H. B.; SILVA, M. V. d.; STEDILE, R. *Sistema de identificação de padrões de ondas cerebrais*. Dissertação (B.S. thesis) — Universidade Tecnológica Federal do Paraná, 2014. Citado 4 vezes nas páginas 11, 25, 47 e 48.
- SHERLIN, L. H. et al. Neurofeedback and basic learning theory: implications for research and practice. *Journal of Neurotherapy*, Taylor & Francis, v. 15, n. 4, p. 292–304, 2011. Citado 2 vezes nas páginas 21 e 23.
- SHIN, M.-S. et al. Effects of smart-tablet-based neurofeedback training on cognitive function in children with attention problems. *Journal of child neurology*, SAGE Publications Sage CA: Los Angeles, CA, v. 31, n. 6, p. 750–760, 2016. Citado na página 21.
- SIEVER, D. *History of Biofeedback and Neurofeedback*. [S.l.]: Biofeedback, 2008. Citado na página 23.
- STERMAN, M. B.; EGNER, T. Foundation and practice of neurofeedback for the treatment of epilepsy. *Applied psychophysiology and biofeedback*, Springer, v. 31, n. 1, p. 21, 2006. Citado na página 21.
- SUBASI, A. Eeg signal classification using wavelet feature extraction and a mixture of expert model. *Expert Systems with Applications*, Elsevier, v. 32, n. 4, p. 1084–1093, 2007. Citado na página 46.
- TAYLOR, E. et al. European clinical guidelines for hyperkinetic disorder—first upgrade. *European child & adolescent psychiatry*, Springer, v. 13, n. 1, p. i7–i30, 2004. Citado na página 17.
- THARWAT, A. et al. Linear discriminant analysis: A detailed tutorial. *AI communications*, IOS Press, v. 30, n. 2, p. 169–190, 2017. Citado na página 54.

- TOPLAK, M. E. et al. Review of cognitive, cognitive-behavioral, and neural-based interventions for attention-deficit/hyperactivity disorder (adhd). *Clinical psychology review*, Elsevier, v. 28, n. 5, p. 801–823, 2008. Citado na página 18.
- YOUNG, K. D. et al. Real-time fmri neurofeedback training of amygdala activity in patients with major depressive disorder. *PloS one*, Public Library of Science, v. 9, n. 2, p. e88785, 2014. Citado na página 21.
- ZHIWEI, L.; MINFEN, S. Classification of mental task eeg signals using wavelet packet entropy and svm. In: IEEE. *Electronic Measurement and Instruments, 2007. ICEMI'07. 8th International Conference on*. [S.l.], 2007. p. 3–906. Citado na página 54.
- ZICH, C. et al. Wireless eeg with individualized channel layout enables efficient motor imagery training. *Clinical Neurophysiology*, Elsevier, v. 126, n. 4, p. 698–710, 2015. Citado 2 vezes nas páginas 21 e 28.