

Henrique Luiz de Oliveira Junior

**Interface Cérebro-Computador Voltada a Jogo
Sério para o Suporte ao Tratamento do
Transtorno do Déficit de Atenção e
Hiperatividade**

Vitória - ES

2020

Henrique Luiz de Oliveira Junior

Interface Cérebro-Computador Voltada a Jogo Séri0 para o Suporte ao Tratamento do Transtorno do Déficit de Atenção e Hiperatividade

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: Prof. Dr. Anselmo Frizera Neto

Coorientador: Dr. Denis Delisle Rodriguez

Vitória - ES

2020

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

O48i Oliveira Junior, Henrique Luiz de, 1988-
Interface Cérebro-Computador Voltada a Jogo Séri o para o
Suporte ao Tratamento do Transtorno do Déficit de Atenção e
Hiperatividade / Henrique Luiz de Oliveira Junior. - 2020.
86 f. : il.

Orientador: Anselmo Frizera Neto.
Coorientador: Denis Delisle Rodriguez.
Dissertação (Mestrado em Engenharia Elétrica) -
Universidade Federal do Espírito Santo, Centro Tecnológico.

1. Interface Cérebro-Computador (ICC). 2. Neurofeedback.
3. Transtorno de déficit de atenção e hiperatividade (TDAH). 4.
Geometria Riemannian. 5. Eletroencefalograma (EEG). 6.
Máquina de vetores de suporte (SVM). I. Frizera Neto,
Anselmo. II. Rodriguez, Denis Delisle. III. Universidade Federal
do Espírito Santo. Centro Tecnológico. IV. Título.


CDU: 621.3

Henrique Luiz de Oliveira Junior

Interface Cérebro-Computador Voltada a Jogo SériO para o Suporte ao Tratamento do Transtorno do Déficit de Atenção e Hiperatividade

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, 28 de agosto de 2020:



Prof. Dr. Anselmo Frizera Neto
Programa de Pós-Graduação em Engenharia
Elétrica (PPGEE - UFES) - Orientador



Dr. Denis Delisle Rodriguez
Programa de Pós-Graduação em Engenharia
Elétrica (PPGEE - UFES) - Coorientador



Prof. Dr. André Ferreira
Departamento de Engenharia Elétrica (UFES)
Membro da Banca Avaliadora



Prof. Dr. Diego Roberto Colombo Dias
Departamento de Ciências da Computação (UFSJ)
Membro da Banca Avaliadora

Vitória - ES

2020

Dedico esta Dissertação ao meu querido pai Henrique Luiz de Oliveira. Você é meu grande herói, meu exemplo de homem. Sábias foram as suas palavras de amor que tive a alegria de ouvir nas nossas serenas conversas. Sou grato pelos seus dedicados ensinamentos, mesmo aqueles em que por teimosia não quis ouvir. Saiba que eu tenho o som da sua voz e o brilho do seu olhar guardados na eternidade do meu coração. Dedico também a minha querida mãe, Maria José Gonçalves Oliveira. A senhora é meu porto seguro, o reflexo da minh'alma, o belo frescor do existir, dentre tudo que aprendi nesses 32 anos de vida, jamais consegui extrair os ensinamentos de vida que você me passou, e nem o verdadeiro, eterno e mais real sentimento que já senti em seus cálidos abraços: o amor. Obrigado por ter me dado a vida, Te amo.

Agradecimentos

Agradeço primeiramente aos meus pais, Henrique Luiz de Oliveira e Maria José Gonçalves de Oliveira, minha irmã Byanka Gonçalves de Oliveira Noia e a minha noiva Letícia Aparecida da Silva de Oliveira 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, ao meu coorientador Denis Delisle Rodriguez e a professora Mariane Souza, 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 – Nº 80615503) pelo suporte financeiro a esta pesquisa, e a CAPES pela bolsa de estudos concedida no período do mestrado.

Agradeço aos meus amigos do laboratório BRAEN Wagner Dias Casagrande, Fabiana Vieira dos Santos Machado, Caio Borgo, Giovanna Gomes Andrade, Bruna Ramos Athaydes, Gabriel Machado Barbosa e Jade Carvalho que através de nossa pesquisa conjunta proporcionaram um grande trabalho.

Agradeço ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Espírito Santo pela oportunidade de aprendizado e por ter proporcionado essa grande conquista.

Resumo

O Transtorno do Déficit de Atenção e Hiperatividade (TDAH) é uma síndrome que ocorre inicialmente na infância. Embora o tratamento farmacológico tenha se mostrado eficaz, ainda apresenta reações adversas como alterações do apetite, alterações do sono, náuseas, entre outros. 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 como objetivo modular a dinâmica neural através do aprendizado induzido por *feedback* utilizando um sistema de captura de EEG. As interfaces cérebro-computador (ICCs) medem características específicas da atividade cerebral e as traduzem em comandos de controle de dispositivos. Sendo assim, este trabalho tem como objetivo o desenvolvimento de uma ICC para dar suporte ao tratamento convencional em sujeitos com TDAH, juntamente com um jogo sério com intuito de se gerar o *feedback* visual. Além disso, a ICC utiliza os sinais eletroencefalográficos captados através de um sistema de captura de EEG para classificar a tarefa mental de atenção e não atenção. Para a análise e processamento dos sinais, a geometria de *Riemannian* foi utilizada para extrair padrões a partir de uma análise de matrizes de covariância, a máquina de vetores de suporte (SVM) para o reconhecimento dos padrões de atenção e não atenção. Neste trabalho foi proposto um modelo de velocidades que permite calcular a velocidade do foguete baseado no nível de atenção do sujeito. Também foi proposto um método de seleção de padrões baseado em probabilidade utilizado para retreinar a ICC, com objetivo de selecionar os padrões que mais representam o estado de atenção. Desta maneira, pode-se utilizar a ICC proposta como tratamento complementar em pacientes com TDAH que fazem uso de medicamentos convencionais. Um protocolo experimental de testes foi proposto, e os resultados demonstraram que o sistema foi capaz de adquirir, processar e classificar os sinais. A análise de resultados obtidos da ICC, mostrou que a fase 2 de calibração é capaz de aumentar o seu desempenho. Como melhor performance, houve um aumento no coeficiente kappa(κ) de 0,71 para 0,91, e na acurácia de 85,84% para 95,23%. No treinamento da atenção, houve sujeitos que apresentaram melhoras na modulação cortical em regiões de interesse (frontal e temporal) com o processo de atenção, essa modulação cortical foi representada pela potência relativa θ/β . Trabalhos futuros envolvem o aprimoramento das técnicas utilizadas no processamento dos sinais e a validação do sistema com sujeitos que possuem diagnóstico de TDAH.

Palavras-chave: Interface Cérebro-Computador, ICC, Geometria Riemannian, Eletroencefalografia, Máquina de vetores de suporte (SVM), Transtorno de déficit de atenção e hiperatividade (TDAH).

Abstract

Attention Deficit Hyperactivity Disorder (ADHD) is a syndrome that occurs initially in childhood. Although pharmacological treatment has been shown to be effective, it still presents adverse reactions such as changes in appetite, changes in sleep, nausea, among others. 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 aims to modulate neural dynamics through feedback-induced learning using an EEG capture system. Brain-computer interfaces (BCIs) measure specific characteristics of brain activity and translate them into device control commands. Therefore, this work aims to develop a BCI to support conventional treatment in subjects with ADHD, together with a serious game in order to generate visual feedback. In addition, BCIs based on electroencephalographic signals (EEG) can be used to classify attention and non-attention states. Riemannian geometry was used to extract features from covariance matrices, while support vector machine (SVM) was used for attention state recognition. In this work, a velocity model was proposed to calculate the skyrocket speed based on the subject's attention level. It was also proposed a pattern selection method based on probability which is used to recalibrate the BCI, in order to obtain that most representative feature vectors of attention states. In this way, the proposed BCI can be used as a complementary treatment in ADHD patients who use conventional medications. An experimental protocol was carried out, and the results showed that the system was able to acquire, process and classify the signals. The analysis of results obtained from the BCI, showed that a recalibration is able to increase its performance, achieving kappa values up to 0.91, and accuracy up to 95.23%. During attention training, some subjects improved their cortical modulation over brain regions of interest (frontal and temporal), where the cortical modulation was represented by θ/β ratio. Future works will be addressed on individuals diagnosed with ADHD to test the effectiveness of our BCI for attention training.

Keywords: Brain-Computer Interface, Riemannian geometry, Electroencephalography, Support Vector Machine, Attention Deficit Hyperactivity Disorder (ADHD).

Lista de ilustrações

Figura 1 – (a) - Sistema Internacional 10/20. (b) - Sinais de EEG.	31
Figura 2 – SVM linear (BUCH, 2008).	39
Figura 3 – (a) - Sistema de captura de sinais <i>Cognionics</i> ; (b) - Sistema Internacional 10/20; (c) - Eletrodos secos para o sistema de captura <i>Quick-20</i> . <cognionics.com/index.php/59-products/sensors>	41
Figura 4 – Telas principais do jogo <i>Neurofeedback Space</i> ; (a) - Menu principal; (b) - Cadastro dos sujeitos; (c) - Questionário para avaliar o paciente na experiência após o jogo; (d) - Ambiente do jogo online.	42
Figura 5 – Curvas de velocidade segundo o nível de atenção; (a) - Modelo de velocidade usado com os padrões reconhecido como atenção; (b) - Modelo de velocidade usado com os padrões reconhecido como desatenção.	45
Figura 6 – Diagrama da ICC desenvolvida.	49
Figura 7 – 7a - Ambiente virtual usado na Fase 1 de calibração para coletas de atenção e não atenção. 7b - Ambiente Virtual usado na Fase 2 de calibração para coleta de dados online por 1 minuto.	50
Figura 8 – Tela mostrada ao sujeito durante o treinamento online de 5 minutos.	51
Figura 9 – Comportamento das velocidades para o grupo: (a) - G1; (b) - G2; (c) - G3	53
Figura 10 – Sujeito S2G1 - Curvas de velocidade de atenção e não atenção (a,b). Comportamento das velocidades nas fases online (c,d). Potência relativa θ/β (e, f, g).	60
Figura 11 – Sujeito S5G1 - Curvas de velocidade de atenção e não atenção (a,b). Comportamento das velocidades nas fases online (c,d). Potência relativa θ/β (e, f, g).	62
Figura 12 – Sujeito S6G1 - Curvas de velocidade de atenção e não atenção (a,b). Comportamento das velocidades nas fases online (c,d). Potência relativa θ/β (e, f, g).	63
Figura 13 – Sujeito S2G3 - Curvas de velocidade de atenção e não atenção (a,b). Comportamento das velocidades nas fases online (c,d). Potência relativa θ/β (e, f, g).	65
Figura 14 – Sujeito S6G2 - Curvas de velocidade de atenção e não atenção (a,b). Comportamento das velocidades nas fases online (c,d). Potência relativa θ/β (e, f, g).	67
Figura 15 – Média e desvio padrão das velocidades no treinamento da atenção por minuto.	69
Figura 16 – Potência relativa θ/β por minuto - Grupo 1.	70
Figura 17 – Potência relativa θ/β por minuto - Grupo 2.	72

Figura 18 – Potência relativa θ/β por minuto - Grupo 3. 73

Lista de tabelas

Tabela 1 – Desempenho da ICC nas fases 1 e 2 de calibração.	58
Tabela 2 – Pontuações do teste BPA e atenção concentrada.	74
Tabela 3 – Perguntas e Respostas Comportamentais	75

Lista de abreviaturas e siglas

AA	Atenção Alternada
AC	Atenção Concentrada
AD	Atenção Dividida
BFB	<i>Biofeedback</i>
BPA	Bateria Psicológica para Avaliação da Atenção
BRAEN	<i>Brazilian Research Group on Brain and Cognitive Engineering</i>
CAA	Tecnologias de Comunicação Aumentativa e Alternativa
CAR	<i>Common Average Reference</i>
CSP	<i>Common Spatial Patterns</i>
EEG	Eletroencefalograma
EOG	Eletrooculografia
fastICA	<i>Fast Independent Component Analysis</i>
FFT	<i>Fast Fourier Transform</i>
fMRI	<i>Functional Magnetic Resonance Imaging</i>
HMM	<i>Hidden Markov Model</i>
ICA	<i>Independent Component Analysis</i>
ICC	Interface Cérebro-Computador
IFFT	<i>Inverse Fast Fourier Transform</i>
LAR	<i>Local Average Reference</i>
LDA	<i>Linear Discriminant Analysis</i>
LPM	<i>Laplacian Method</i>
LSL	<i>LabStreamingLayer</i>
MEG	<i>Magnetoencephalography</i>

NFB	<i>Neurofeedback</i>
NIRS	<i>Near-Infrared Spectroscopy</i>
NN	<i>Nearest Neighbors</i>
PCA	<i>Principal Component Analysis</i>
PCHIP	<i>Piecewise Cubic Hermite Interpolating Polynomial</i>
PCL	Potenciais Corticais Lentos
PET	<i>Positron Emission Tomography</i>
RBF	<i>Radial Basis Function</i>
sLORETA	<i>Standardized Low Resolution Brain Electromagnetic Tomography</i>
SPD	Simétrica e Positiva Definida
SVM	<i>Support Vector Machine</i>
TDAH	Transtorno do Déficit de Atenção e Hiperatividade
WAR	<i>Weighted Average Reference</i>

Sumário

1	INTRODUÇÃO	21
1.1	Motivação	21
1.2	Objetivos	24
1.2.1	Objetivo Geral	24
1.2.2	Objetivos Específicos	24
1.3	Justificativa	24
1.4	Estrutura da Dissertação	27
2	EMBASAMENTO TEÓRICO	29
2.1	O sinal do eletroencefalograma	29
2.2	Neurofeedback	32
2.3	Interfaces Cérebro-Computador	33
2.3.1	Processamento dos sinais cerebrais	34
2.3.2	Extração de Características	35
2.3.3	Classificação	37
3	MATERIAIS E MÉTODOS	41
3.1	Materiais	41
3.1.1	Sistema de Captura de EEG - <i>Cognionics Quick-20</i>	41
3.1.2	Jogo Sério - <i>Neurofeedback Space</i>	42
3.1.3	Avaliações Cognitivas	43
3.1.3.1	Bateria Psicológica para Avaliação da Atenção	43
3.1.3.2	Escala de Afetos Positivos e Negativos - PANAS	44
3.2	Métodos	44
3.2.1	Modelo da Velocidade Baseada no Nível de Atenção	44
3.2.2	Seleção de Padrões Baseado em Probabilidade	47
3.2.3	Interface Cérebro-Computador Proposta	48
3.2.4	Calibração da ICC	49
3.2.5	Treinamento online da Atenção	51
3.3	Validação	52
3.3.1	Participantes	52
3.3.2	Protocolo Experimental	52
3.3.3	Análise de Dados	54
4	RESULTADOS E DISCUSSÃO	57
4.1	Calibração da ICC	57

4.2	Treinamento da Atenção	67
5	CONCLUSÃO	77
5.1	Contribuições	78
5.2	Publicações	78
5.3	Trabalhos Futuros	78
	REFERÊNCIAS	81

1 Introdução

1.1 Motivação

O Transtorno do Déficit de Atenção e Hiperatividade (TDAH) é uma síndrome que ocorre inicialmente na infância ([CARMARGOS; HOUNIE, 2005](#)). Segundo dados da Organização Mundial de Saúde (OMS), cerca de 4% da população adulta mundial têm TDAH. Só no Brasil, o transtorno atinge aproximadamente 2 milhões de pessoas adultas ([OMS, 2019](#)). No início dos anos 1990, houve um aumento considerável no interesse de pesquisas relacionadas com o TDAH no Brasil. Esse aumento se deu por causa de grandes dificuldades de convivência entre pais e filhos e a falta de disciplina, principalmente nas escolas ([FERNANDES; MARCONDES, 2017](#)).

No Brasil, foi fundada em 1999 a Associação Brasileira do Déficit de Atenção (ABDA), nela passaram a registrar as histórias de vida contando todos os desafios passados pelas pessoas com o déficit. A partir daí, pais e educadores tiveram mais fácil acesso a locais de tratamento, dicas para lidar com o transtorno, legitimando assim a nova patologia ([FERNANDES; MARCONDES, 2017](#)).

O tratamento mais utilizado para o TDAH é o farmacológico, sendo o cloridrato de metilfenidato o mais indicado. Tal fármaco é uma droga que age como estimulante do sistema nervoso central, tendo um ótimo efeito na concentração, na melhora de atividades, com isso, diminuindo a fadiga mental. O medicamento tem uma ação média de 4 a 5 horas no organismo, devendo continuar com o tratamento ao apresentar sintomas notórios. Porém, possui muitas reações adversas como alterações do apetite, do sono, náuseas, vômitos, dor epigástrica, cólicas abdominais, cefaleia, labilidade de humor, irritabilidade, tristeza, choro fácil e taquicardia. Essas reações adversas podem ser controladas conforme a dosagem do medicamento ([MATOS *et al.*, 2018](#)).

Ao longo dos anos, o tratamento farmacológico para TDAH foi considerado como o único eficaz para reduzir os sintomas da condição ([PALUDO, 2017](#)). Diagnósticos psicopedagógicos e o recente uso do fármaco no transtorno de aprendizagem legitimaram o metilfenidato no Brasil ([FERNANDES; MARCONDES, 2017](#)). Nas últimas décadas, vários estudos têm sido realizados para analisar os efeitos do *neurofeedback* (NFB) como tratamento complementar ao medicamento ([PALUDO, 2017](#)).

O NFB é um campo de especialização do *Biofeedback* (BFB), através do qual o indivíduo pode aprender a controlar de forma consciente um comportamento fisiológico neural, e pode ser realizado com outros métodos que permitam a captura da atividade cerebral. Nesta pesquisa o sistema de captura de EEG foi utilizado por seu baixo custo

e portabilidade. O NFB pode ser usado como treinamento para o estresse, transtorno obsessivo-compulsivo (TOC), dentre outros. Esse sistema de captura mede as oscilações do potencial bioelétrico usando eletrodos colocados no couro cabeludo (HERNÁNDEZ, 2015). No caso do NFB o processo psicofisiológico é detectado por meio da eletroencefalografia (EEG), ressonância magnética funcional (fMRI), espectroscopia no infravermelho próximo (NIRS), magnetoencefalografia (MEG), dentre outros (HERNÁNDEZ, 2015).

O treinamento NFB surgiu como tratamento complementar ao suporte farmacológico visando estimular a ativação cortical, especialmente em transtornos que exigem intervalos crescentes de atenção/regulação e controle de habilidades, como TDAH. Estudos prévios justificam o aumento da ativação por treinamento em NFB, não apenas devido ao *feedback* imediato fornecido pelo instrumento, mas também devido ao estabelecimento de novas vias e conexões neurais (GONZÁLEZ-CASTRO *et al.*, 2016).

Nesse sentido, os clínicos utilizam três tipos básicos de protocolos de treinamento por NFB para a intervenção em TDAH (HOLTMANN *et al.*, 2014). Primeiro, um protocolo convencional para reduzir a desatenção e a impulsividade, que consiste na supressão operante da atividade teta (θ , 4-7 Hz) e no aumento da atividade beta (β , 13-30 Hz). O segundo consiste em reduzir os sintomas de hiperatividade, aumentando o ritmo sensorimotor (SMR - 12-15 Hz), que é algumas vezes usado em adição ao protocolo teta/beta (θ/β) anteriormente mencionado. O terceiro visa modificar os Potenciais Corticais Lentos (PCL), com objetivo de regular os limiares de excitação cortical. Nas variedades de protocolos NFB, o procedimento θ/β é um dos melhores avaliados cientificamente (GONZÁLEZ-CASTRO *et al.*, 2016).

No estudo realizado por Leins *et al.* (2007), utilizando o NFB em crianças com TDAH, houve uma comparação entre dois protocolos utilizados, que são os PCL e a relação θ/β , sendo que um dos objetivos era verificar se os pacientes eram capazes de demonstrar aprendizado da auto-regulação cortical, uma melhoria da cognição (atenção e inteligência) com o treinamento e comportamento (hiperatividade e impulsividade). Como resultados, houve a satisfação dos pais relatando que seus filhos começaram a fazer a lição de casa e apresentaram melhora na atenção e a redução na distração. Os pais tiveram mais confiança no tratamento utilizando PCL, do que o tratamento utilizando θ/β . As crianças com TDAH aprenderam a auto-regular o PCL e essa auto-regulação permaneceu estável até 6 meses após o término do tratamento. Já os participantes do grupo θ/β aprenderam a diferenciar entre as tarefas de ativação e desativação e aprimoraram as tarefas de desativação, de fato, as realizações nas tarefas de ativação também melhoraram, mas não significativamente.

Atualmente, muitas crianças com diagnóstico de TDAH apresentam muitas diferenças na atividade elétrica cerebral quando comparadas a crianças sem o transtorno, principalmente em relação à atividade da onda cerebral entre 4 e 7 Hz, que está associada

com a hipoativação. No maior estudo de Eletroencefalograma (EEG) em mais de 400 crianças com TDAH, Chabot & Serfontein (1996) descobriram que crianças com TDAH exibem um aumento na onda cerebral entre 4-7 Hz , 8-13 Hz e uma redução entre 14-30 Hz (PALUDO, 2017). Além disso, eles identificaram melhor funcionamento acadêmico e intelectual, por isso, sugerem que esse tipo de tratamento é uma intervenção útil para alunos com TDAH. Isso deve ser levado em conta, pois o suporte farmacológico produz um benefício no comportamento e na atenção, mas normalmente não melhora o desempenho acadêmico ou a capacidade de interação (GONZÁLEZ-CASTRO *et al.*, 2016).

Tecnologias avançadas, como a Interface Cérebro-Computador (ICC), robótica e realidade virtual estão começando a encontrar seu caminho em tratamentos como do TDAH (JIANG *et al.*, 2011). Uma ICC fornece caminho de comunicação direta entre um cérebro e o mundo real. O EEG atualmente é o mais utilizado, devido principalmente à sua resolução temporal, facilidade no uso, portabilidade e baixo custo de instalação, mostrando grandes potenciais para reabilitação, aplicação assistida como aumentar ou reparar funções cognitivas ou motoras sensoriais humanas. Entretanto, devido à variabilidade do EEG ao ruído, é necessário em várias aplicações, treinamento extensivo antes que os usuários possam trabalhar com a tecnologia (JIANG *et al.*, 2011).

No estudo realizado por Díaz-Baquero e Camelo-Roa (2019), foram recrutados 46 adolescentes do sexo masculino, sendo 23 usuários de drogas e 23 estudantes de uma escola estadual com idade entre 12 e 17 anos. Foi utilizado o sistema Emotiv EPOC com 14 eletrodos e 2 referências. A ICC foi composta de um programa virtual de treinamento cerebral, este módulo permite medir e avaliar a atenção sustentada e seletiva, e também obter o tempo de resposta de cada participante. Esta ICC consiste em apresentar uma série de figuras geométricas de diferentes cores e formas. Os resultados mostram que o consumo de substâncias psicoativas geram mudanças na atividade elétrica cerebral dos sujeitos. Esta atividade é refletida nos déficits atencionais observados nos sujeitos. Este estudo contribui para planejar novas estratégias de intervenção, como *feedback* para usuários de drogas e também para vincular novas tecnologias para analisar melhor os registros fisiológicos no consumo de drogas.

Esta pesquisa tem como objetivo melhorar a qualidade de vida por meio da tecnologia, com o desenvolvimento de uma nova ICC para o tratamento complementar em crianças com TDAH, visando a diminuição dos sintomas que mais as prejudicam.

1.2 Objetivos

1.2.1 Objetivo Geral

O objetivo geral desta pesquisa de mestrado consiste no desenvolvimento de uma ICC que possibilite a análise dos dados coletados por meio de um sistema de captura de EEG e que seja capaz de identificar o estado mental de atenção e não atenção. Dessa maneira, fornecer para o 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.

1.2.2 Objetivos Específicos

1. Desenvolvimento de uma ICC para aquisição e processamento de dados online coletados através do EEG e implementação de técnicas de processamento de sinais para a detecção de atenção e não atenção do sujeito para realização de treinamento cognitivo através do EEG.
2. Realização de experimentos para validar a ICC proposta com voluntários saudáveis segundo protocolo em desenvolvimento pela equipe do “Núcleo de pesquisa *neurofeedback*: Aplicação nas Desordens Neuropsiquiátricas” aprovado no Edital FAPES-PRONEM 2017.

1.3 Justificativa

O tratamento farmacológico para o TDAH é um dos assuntos mais pesquisados na área de saúde mental (PLISZKA, 2007). O uso de anfetaminas em crianças com distúrbios comportamentais foi descrito em 1937 por Bradley e antecede o uso de antibióticos. Felizmente tem disponível uma grande variedade de agentes farmacológicos para o tratamento do TDAH. Os fármacos de ação curta raramente têm uma duração de ação superior a seis horas, exigindo doses múltiplas por dia. Os efeitos colaterais mais comuns desses fármacos são dor de cabeça, insônia e perda de apetite, além de relatos de mau humor, dor abdominal, perda de peso e etc, e isso gera debates em relação a segurança desses estimulantes (PLISZKA, 2007). Visto que os fármacos possuem muitos efeitos indesejados, são necessários tratamentos complementares comprovados para diminuir o consumo desses medicamentos.

O NFB é amplamente aplicado como intervenção não farmacológica, com o objetivo de reduzir os sintomas do TDAH. Alterações neuronais durante a intervenção do NFB que se assemelham à aprendizagem podem fornecer evidências cruciais para a viabilidade e especificidade das intervenções (JANSSEN *et al.*, 2017).

Bluschke *et al.* (2016) recrutaram dezenove crianças (idade entre 8 e 14 anos) com TDAH para realizar o treinamento de NFB por oito semanas utilizando o protocolo θ/β e outras dezessete crianças (idade entre 9 e 13 anos) que ficaram no grupo controle (fila de espera) e realizarem a tarefa Go/NotGo. A relação θ/β das crianças foram mostradas por meio de um software SAM (Auto-regulação e gerenciamento de atenção, Universidade de Erlangen). Os dados foram gravados utilizando um sistema de captura de EEG com 60 eletrodos a uma taxa de amostragem de 500 Hz. As impedâncias dos eletrodos foram mantidas abaixo dos $5k\Omega$. Durante o processamento de dados offline, a taxa de amostragem foi de 256 Hz com um filtro passa-banda de 0.5-20 Hz. Artefatos técnicos foram removidos durante a inspeção manual dos dados brutos. Foi utilizado uma ICA para remover artefatos que ocorrem periodicamente (movimentos oculares e musculares) e para examinar a neuro-modulação foi utilizado o *Standardized Low Resolution Brain Electromagnetic Tomography* (sLORETA). Comparados com o pré-teste, os resultados após o NFB, os sintomas do TDAH foram relativamente menores e no grupo controle não houve essa diferença entre pré e pós-teste. Foram encontrados também melhoras na atenção no grupo NFB, mas não houve essa melhora no grupo controle. Considerando a hiperatividade/impulsividade houve uma melhora no grupo NFB e não houve nenhum efeito no grupo controle. Na análise comportamental, após o NFB, os pacientes com TDAH cometeram menos alarmes falsos que no pré-teste, indicando uma redução na impulsividade. Já no grupo controle não foram encontradas diferenças entre pré e pós-teste.

Posteriormente, Mohammadpour e Mozaffari (2017) desenvolveram um sistema de reconhecimento baseado em EEG com o objetivo de reconhecer quatro estados de atenção (linha de base, leitura silenciosa, tarefa matemática e atenção sustentada). Cada tentativa desses quatro estados de atenção constitui quinze segundos de gravação de EEG e cada sessão inclui cinco dessas tentativas, a cada sessão o sujeito pediu para descansar por alguns minutos. Foram recrutados quatro voluntários (entre 20 e 32 anos, 1 masculino e 3 femininos) para participarem dos experimentos propostos. Todos os voluntários estão saudáveis e sem hábitos que poderiam prejudicar as coletas. Os dados do EEG foram gravados pelo software *Open-Source Brain-Computer Interface* (OpenBCI) e para a classificação foi utilizando o *Support Vector Machine (Gaussian - SVM)*. Como resultado o classificador conseguiu reconhecer as quatro classes, e utilizando a matriz de confusão ficaram 78% para linha de base, 61% para leitura, 57% para tarefa matemática e 64% para atenção sustentada.

No estudo realizado por Qian *et al.* (2018), foram recrutados sessenta e seis meninos com TDAH de um Instituto de Saúde Mental em Cingapura. Eles foram divididos em dois grupos, dezoito sujeitos para o grupo de intervenção e onze sujeitos para o grupo de não intervenção. Houve uma redução na quantidade de pessoas devido aos dados incompletos na ressonância magnética, desistência entre outros. O sistema de jogo consistia em utilizar um sistema de captura de EEG com eletrodos secos localizados na região

frontal (Fp1 e Fp2). O jogo utilizado foi o Cogoland, em que cada participante controla um avatar para concluir uma certa tarefa, por exemplo, fazendo o avatar rodar em uma ilha no menor tempo possível. A velocidade do avatar irá aumentar na medida em que os sujeitos ficassem mais atentos. Após 8 semanas, o grupo de intervenção teve uma redução significativa na desatenção em relação ao grupo de não intervenção. A redução de problemas de internalização da lista de comportamento infantil no grupo de intervenção foi um pouco maior do que o grupo de não intervenção.

Geladé (2019) recrutou noventa e duas crianças com diagnóstico de TDAH com idade entre 7 a 13 anos. As crianças foram divididas em três grupos, sendo cada grupo recebeu treinamentos/tratamentos diferentes. Trinta e três crianças receberam NFB, vinte e oito receberam metilfenidato (MPH) e trinta e um receberam atividades psicológicas (AP). Para o grupo NFB foi aplicado o protocolo θ/β , havendo uma redução bem sucedida do índice, foi recompensada para a criança o aparecimento de um sol e pontuações foram adicionadas. Quanto o uso do MPH, foram feitos testes em todo grupo para determinar a dose individual ideal para cada um dos sujeitos. Para a AP, começou com cinco minutos de aquecimento, seguidos por cinco exercícios de intensidade moderada de dois minutos, após setenta e dois intervalos de cinco minutos, foram realizados cinco exercícios de alta intensidade de dois minutos. Para o NFB foi utilizado o sistema *THERAPRAX EEG Biofeedback* (Neuroconn GmbH, Alemanha), taxa de amostragem de 128 Hz. Como resultados os sujeitos que fizeram NFB e atividades psicológicas mostraram menos uso de medicamentos estimulantes. Os resultados dos relatórios dos pais mostraram que, desde a intervenção até o acompanhamento, as crianças inicialmente randomizadas para o NFB alcançaram as crianças que participaram do grupo usando MPH. Não houve diferenças ao longo do tempo entre crianças que receberam NFB e AP. Os relatórios dos professores mostraram que, desde a intervenção até o acompanhamento, as crianças que receberam NFB alcançaram as crianças do grupo MPH, comparando os grupos NFB e AP, o NFB teve uma boa melhora em comparação ao grupo AP.

Em estudo recente, Bielas e Michalczyk (2020) avaliaram a eficácia do treinamento de NFB como um método para melhorar o funcionamento executivo em idosos. O treinamento consistia em utilizar a onda β (12 - 22 Hz), fazer vinte sessões (30 minutos cada). Quinze estudantes da Universidade da Terceira idade participaram deste estudo e tinham idades entre 66 e 75 anos e todos eles tinham pelo menos o ensino superior completo. Somente sujeitos sem nenhum problema neuropsiquiátrico diagnosticado foram recrutados. A apresentação do estímulo e a coleta foram controlados por tarefas comportamentais executadas pelo software DMDX (usado em laboratórios de psicologia em todo o mundo para medir o tempo de reação a estímulos visuais e auditivos.), enquanto o software BioGraph Infiniti e o hardware ProComp 5 Infiniti foi usado para o treinamento NFB. Os resultados desse estudo mostraram evidências preliminares de que o treinamento NFB modulando a onda β está associado as melhorias na inibição da resposta Stroop e na

inibição motora de Simon em idosos como aspectos de seu funcionamento executivo. Logo, pode ser um ferramenta a ser desenvolvida para melhorar as habilidades cognitivas e a qualidade de vida da população idosa em geral.

Considerando que o NFB pode fornecer uma abordagem alternativa para o treinamento da atenção, foi proposto no presente trabalho um novo sistema NFB utilizando geometria de *Riemannian* para extrair características, uma análise de probabilidade não supervisionada para obter os padrões mais associados à atenção, com isso obtendo uma melhor classificação do estado de atenção, e como novidade o método de regressão com ordem cúbica foi usado para obter uma função de velocidade (de 0 a 100%) associado ao nível da atenção.

1.4 Estrutura da Dissertação

Este documento está organizado da seguinte forma: apresentação da motivação inicial no Capítulo 1, o Capítulo 2 apresenta os conceitos e definições sobre o NFB e ICC, mostra também de forma geral, métodos utilizados para o processamento do sinal cerebral. Neste Capítulo também é realizada uma revisão da literatura.

No Capítulo 3 são apresentados a ICC proposta, os materiais e métodos utilizados para a aquisição dos dados, o protocolo experimental proposto, as técnicas utilizadas no processamento dos dados obtidos e o retorno ao usuário do sistema em forma de jogo sério.

No Capítulo 4 são apresentados os resultados preliminares, bem como uma discussão destes resultados.

No Capítulo 5 apresenta as conclusões deste trabalho, o que se espera até a finalização do projeto de pesquisa e recomendações para trabalhos futuros.

2 Embasamento Teórico

2.1 O sinal do eletroencefalograma

EEG é uma técnica de medição não invasiva de potenciais elétricos cerebrais por meio de eletrodos colocados sob a superfície do crânio (Figura 1b) (CORREIA *et al.*, 2018). O córtex é a camada mais externa do cérebro e possui uma espessura de 2 a 3 mm. A superfície cortical é altamente envolvida por sulcos e vales de diversos tamanhos, sendo formado por dois hemisférios simétricos (esquerdo e direito) que são separados pela profunda fissura sagital (o sulco central). Cada hemisfério é dividido em quatro lobos diferentes, sendo lobo frontal, temporal, parietal e occipital. A informação sensorial é processada em várias partes dos lobos. Quando os neurônios são ativados, as correntes sinápticas são produzidas dentro dos dendritos e geram um campo elétrico secundário sobre o couro cabeludo mensurável pelo EEG (LIMA *et al.*, 2018).


O EEG tem sido uma gigantesca fonte de dados indispensáveis para diversas tecnologias atuais com ICC, e em reabilitações neurológicas (WANG; WANG; HOU, 2019). Em 1920 Hans Berger começou a estudar sinais de EEG em humanos, sendo o responsável por realizar o primeiro registro do sinal de EEG, que durou cerca de três minutos, em seu primeiro relatório. Berger incluiu o ritmo alfabético como componente principal, sendo assim o nome alfa (de 8 a 12 Hz) foi dado, para o primeiro ritmo que registrou (LIMA *et al.*, 2018).

A diversidade de ritmos do EEG é enorme e depende do estado mental do indivíduo, como grau de atenção, despertar, sono, entre outros. Os ritmos são convencionalmente caracterizados por sua faixa de frequência e amplitude relativa. A amplitude do sinal EEG está relacionada ao grau de sincronia com o qual os neurônios corticais interagem. A faixa de frequência de um ritmo de EEG é parcialmente sustentada pela atividade inicial do tálamo, e este ritmo é mais uma expressão de um mecanismo de *feedback* que pode ocorrer em um circuito neuronal. Os ritmos de alta frequência / baixa amplitude refletem um cérebro ativo associado ao estado de alerta, enquanto os ritmos de baixa frequência / grande amplitude estão associados à sonolência e a estados de sono (LIMA *et al.*, 2018). Ritmos eletroencefalográficos, também conhecidos como ritmos de fundo, são convencionalmente classificados em cinco bandas de frequência diferentes. As cinco bandas de frequência mais conhecidas são: Delta (δ), Teta (θ), Alfa (α), Beta (β) e Gama (γ) (LIMA *et al.*, 2018).


- Ritmo Delta (< 4 Hz, δ): ritmo tipicamente encontrado durante o sono profundo com uma grande amplitude e normalmente não é observado em adultos (saudáveis) acordados, seu aparecimento para este caso é indicativo de, por exemplo, lesão cerebral ou doença cerebral (encefalopatia) (SÖRNMO; LAGUNA, 2005).
- Ritmo Teta (4 a 7 Hz, θ): ritmo ocorre durante a sonolência e em certos estágios do sono (SÖRNMO; LAGUNA, 2005).
- Ritmo Alfa (8 a 12 Hz, α): ritmo é mais proeminente em indivíduos saudáveis que estão relaxados e acordados com os olhos fechados, a atividade é reduzida quando os olhos estão abertos (SÖRNMO; LAGUNA, 2005).
- Ritmo Beta (13 a 30 Hz, β): é um ritmo rápido com baixa amplitude, associado a um córtex ativado e que pode ser observado, por exemplo, durante certos estágios do sono. O ritmo beta é observado principalmente nas regiões frontal e central do couro cabeludo (SÖRNMO; LAGUNA, 2005).
- Ritmo Gama (> 30 Hz, γ): é relacionado a um estado de processamento ativo de informações do córtex, o ritmo gama pode ser observado durante os movimentos dos dedos (SÖRNMO; LAGUNA, 2005) e no processo de atenção (COSTA *et al.*, 2016).

O EEG clínico geralmente é registrado usando o sistema internacional 10/20 (Figura 1a), que é um sistema padronizado para colocação de eletrodos. Este sistema consiste em vinte e um eletrodos ligados ao couro cabeludo em locais definidos. O espaçamento dos eletrodos é de aproximadamente 4,5 cm em uma cabeça adulta típica (LIMA *et al.*, 2018).

Os eletrodos devem ser colocados corretamente, verificando se há ruído interno ou externo. Gravações contínuas de sinais de EEG podem ser altamente contaminadas por artefatos fisiológicos, como movimentos oculares, piscadas e atividade cardíaca ou muscular. Durante a coleta e gravação dos sinais, esses tipos de artefato podem interferir na detecção e análise de eventos de interesse. Como exemplo tem a análise de crises epiléticas, os sinais são gravados com muitos artefatos devido por grandes movimentos oculares e artefatos piscantes que imediatamente aparecem no início da crise. Com o avanço do EEG, tornou-se um procedimento desejável tentar corrigir artefatos nos dados gravados. O principal objetivo da correção de artefato é remover os artefatos o mais completamente possível, sem distorcer o sinal de interesse (ILLE; BERG; SCHERG, 2002).



(a)



(b)

Figura 1 – (a) - Sistema Internacional 10/20. (b) - Sinais de EEG.

2.2 Neurofeedback

O NFB é uma técnica derivada do BFB que tem como objetivo de fornecer um caminho para o indivíduo modular sua dinâmica neural. Esse *feedback* pode ser obtido através estimulações internas ou externas, sendo os estímulos visuais e auditivos os mais comuns (MASCARO, 2017; DAVELAAR, 2018). No NFB as variáveis de interesse são cerebrais, o que pode levar, eventualmente, a resultados mais profundos e rápidos se tratando de distúrbios cerebrais (DIAS, 2010). Nos últimos quinze anos, o NFB cresceu em popularidade como uma opção de intervenção para o treinamento de atenção em pacientes com diagnóstico de TDAH (BLUSCHKE; ROESSNER; BESTE, 2016; RUBIA, 2018).

Durante o treinamento de NFB, várias técnicas não invasivas são empregadas para registrar a ativação cortical, como MEG (FOLDES *et al.*, 2020), fMRI (WATANABE *et al.*, 2017), NIRS (KIMMIG *et al.*, 2019), PET (JARDIM, 2017), e o EEG (BLUSCHKE; ROESSNER; BESTE, 2016), muito utilizado atualmente.

O uso de ferramentas computacionais tem auxiliado na busca de metodologias que sejam eficazes para o tratamento de dependentes, visto que ainda não existe uma metodologia padronizada. Existem protocolos específicos para cada tipo de vício, visto que cada substância age em áreas específicas do cérebro (DIAS, 2010). O uso do treinamento NFB para a redução do nível de estresse tem como objetivo induzir o relaxamento, tendo a banda α o mais relacionado, e tem como objetivo o aumento de seu nível (SÁ; SOARES, 2003). Com esse aumento, é possível haver uma melhora, por exemplo, na qualidade do sono (DIAS, 2010).

Sujeitos com o espectro autista mostram irregularidades e anomalias nos padrões de ativação cerebral, sendo elas uma grande redução na onda α (CHAN; SZE; CHEUNG, 2007), e um grande aumento na onda θ , δ (CORNEW *et al.*, 2012) e γ (LUSHCHEKINA *et al.*, 2012). A modificação dos padrões atípicos de atividade cerebral presentes no autismo poderia ser considerada como objetivo prioritário, o que poderia ser conseguido através do NFB (GARCÍA-BERJILLOS *et al.*, 2015).

No protocolo criado por Rosenfeld (1997), valida o papel da assimetria α frontal na depressão (protocolo ALAY). Esse protocolo é baseado em uma assimetria $\left(\frac{F4-F3}{F3+F4}\right)$, com um eletrodo de referência em Cz (HAMMOND, 2005). Outro protocolo aplicado é a redução da onda θ (MASCARO, 2017).

Para alcoolismo e abuso de drogas, os indivíduos geralmente apresentam baixos níveis nas ondas α e θ e um aumento na onda β . Usando o treinamento NFB, é necessário reduzir a onda β e aumentar a onda α e θ (HAMMOND, 2007).

Dentre os problemas citados acima nos protocolos, atualmente o NFB tem um amplo espectro na aplicação. Nos quais, o NFB pode ser aplicado para dificuldade de aprendizagem, problemas de desenvolvimento, aumento das capacidades cognitivas, memória, epilepsia, acidente vascular cerebral (AVC), personalidade antissocial, insônia, dores de cabeça e enxaqueca. Logo, esses problemas podem ser aplicados e estudados usando o treinamento NFB, observando mais profundamente o progresso dos sujeitos com o treinamento (HAMMOND, 2007).

No NFB tem como grande importância sua ICC, pois é nele que contém todo o sistema para capturar os sinais cerebrais, processar tais sinais e gerar o *feedback* para o usuário. A ICC será apresentada na próxima seção.

2.3 Interfaces Cérebro-Computador

Muitas pessoas com deficiências motoras graves precisam de Tecnologias de Comunicação Aumentativa e Alternativa (CAA) para terem a possibilidade de realizar tarefas normais do cotidiano (SCHALK *et al.*, 2004). A CAA refere-se a uma área de pesquisa, bem como a prática clínica e educacional (BEUKELMAN; MIRENDA *et al.*, 1998). Entretanto, aqueles que estão com algum tipo de paralisia parcial ou total, não conseguem utilizar as CAA convencionais, pois necessitam de algum tipo de controle muscular. Nas últimas décadas, vários estudos avaliaram a possibilidade em utilizar os sinais cerebrais nas CAA que não requer controle muscular (SCHALK *et al.*, 2004).

As ICCs medem características específicas da atividade cerebral e as traduzem em comandos de controle de dispositivos (SCHALK *et al.*, 2004). Elas fornecem aos usuários um canal de comunicação e controle que não dependem das vias normais de saída do cérebro (nervos e músculos periféricos) (WOLPAW *et al.*, 2000). O interesse atual no desenvolvimento da ICC tem como principal objetivo fornecer uma nova opção de comunicação para pessoas com deficiências motoras graves, pois os impedem de usar CAA convencionais, ou seja, todas aquelas que requerem algum controle muscular voluntário (SCHALK *et al.*, 2004).

As ICCs podem usar métodos invasivos ou não invasivos. ICCs invasivas usam atividade de neurônio único registrada no cérebro. Embora tenha uma resolução espacial mais alta e possam fornecer sinais de controle com muitos graus de liberdade, as ICCs que dependem de eletrodos no córtex enfrentam problemas na obtenção e manutenção de gravações estáveis a longo prazo (LEUTHARDT *et al.*, 2004). ICCs não invasivas usam atividade de EEG que são convenientes, seguros e baratos, mas tem uma resolução espacial relativamente baixa, são suscetíveis a artefatos como sinais de eletromiografia (EMG), eletrooculografia (EOG), eletrocardiografia (ECG), interferência da rede elétrica, ao colocar os eletrodos, impedância eletrodo-pele, que geralmente exigem treinamento

extensivo do usuário. Muitos fatores determinam o desempenho de uma ICC, incluem os sinais cerebrais coletados, métodos de processamento de sinal, algoritmos que convertem sinais em comandos a serem enviado a um dispositivo final (*feedback* fornecido ao usuário) (SCHALK *et al.*, 2004).

2.3.1 Processamento dos sinais cerebrais

Com o avanço das ICCs, métodos para a detecção de artefatos são propostos com objetivo de deixar os sinais coletados mais “puros”, com isso o artefato poderá ser rejeitado após sua identificação. Métodos adaptativos, como o *Principal Component Analysis* (PCA), *Independent Component Analysis* (ICA) e a fastICA, são usados para remover artefatos nos processamentos offline. Pode-se também combinar filtros espaciais citados anteriormente com a ICA, a fim de reduzir interferências e artefatos comuns e melhorar o reconhecimento de padrões que forem desejados (MCFARLAND *et al.*, 1997).

Artefatos de EOG, por exemplo, podem ser totalmente evitados, mas sua rejeição pode resultar em perda de informações neurais. Outros tipos de artefatos como piscadas e mastigação também são comuns nas coletas de dados e precisam ser retirados para o melhor processamento dos sinais (DELISLE-RODRIGUEZ *et al.*, 2017). Sabendo que esses efeitos podem prejudicar os sinais coletados, prejudicando o reconhecimento de padrões, os filtros espaciais são métodos que podem ajudar a retirar esses efeitos indesejados, deixando os sinais em melhores condições para serem processados, assim, obtendo resultados mais desejados.

Filtros espaciais, como o *Common Average Reference* (CAR), *Local Average Reference* (LAR), *Weighted Average Reference* (WAR) e *Laplacian Method* (LPM) são usados nas ICCs para reduzir interferências comuns nos sinais de EEG (DELISLE-RODRIGUEZ *et al.*, 2017). O filtro CAR calcula a média dos sinais em todos os eletrodos. O valor calculado é subtraído dos sinais de interesse (MCFARLAND *et al.*, 1997). O filtro LAR calcula a média dos sinais dos eletrodos que estão em volta de um eletrodo central, levando em conta as distâncias reais entre os eletrodos (PFURTSCHELLER; NEUPER; BERGER, 1994). O filtro WAR é uma modificação do CAR levando em consideração as distâncias reais entre os eletrodos (PFURTSCHELLER; NEUPER; BERGER, 1994). O filtro LPM é usado somente quando os eletrodos estão dispostos em uma matriz retangular, levando em conta apenas os quatro vizinhos retangulares. Esse método foi usado para comparar com os resultados obtidos pelo filtro espacial LAR (MCFARLAND *et al.*, 1997).

Outro filtro importante é o passa-baixa *Butterworth*, pois ele tem sido muito utilizado para preservar componente de interesse. Projetando corretamente o filtro, pode-se selecionar as bandas de frequência relacionadas a banda de interesse e pode-se ter uma resposta mais plana na banda passante (AMIN *et al.*, 2015).

Neste trabalho foi escolhido um filtro passa-banda que usa a *Fast Fourier Transform* (FFT) e a *Inverse Fast Fourier Transform* (IFFT), com banda de interesse de 1 a 30 Hz. A análise de Fourier é de grande importância para matemáticos e engenheiros e é um dos assuntos mais antigos sobre a análise na matemática. Esse estudo realiza decomposição de funções periódicas em séries trigonométricas convergente, denominado análise de Fourier, em homenagem a Jean Baptistes Joseph Fourier (1768 - 1830) (GURGEL, 2013).

Para a filtragem, para cada seguimento a FFT é usada no domínio da frequência para zerar as componentes fora da banda de interesse (1-30 Hz), multiplicando uma função retangular de filtro de banda. Após a FFT, é usada uma IFFT para retornar ao seguimento filtrado no domínio do tempo. Esse filtro é adequado para o processamento online em comparação com outros filtros, sendo aplicado com sucesso em ICC (ROMERO-LAISECA *et al.*, 2020).

2.3.2 Extração de Características

Algoritmos usados extração ou classificação de padrões são importantes para análise dos dados e devem otimizar o desempenho da ICC utilizada (MCFARLAND *et al.*, 2006). Podem ser usados para reconhecimento de padrões de uma maneira que facilite a análise (KHALID; KHALIL; NASREEN, 2014). Além disso, é desejável que esses algoritmos permitam discernir e interpretar os processos usados pelos sujeitos para resolver a tarefa imposta pela ICC na qual são confrontados (MCFARLAND *et al.*, 2006).

Os padrões podem ser extraídos no domínio do tempo, frequência, tempo-frequência e no domínio espacial. Com os padrões extraídos corretamente, há uma grande chance do algoritmo entender o que é preciso reconhecer (REALITY AI, 2017). Vários métodos foram desenvolvidos para encontrar padrões adequados, dentre eles o PCA, ICA, densidade espectral de potência, energia, *Common Spatial Patterns* (CSP), filter-bank CSP e geometria de *Riemannian* são exemplos de algoritmos para extrair padrões. Neste trabalho foi escolhida a geometria de *Riemannian* para extrair as características.

A geometria de *Riemannian* é o ramo da matemática que estuda espaços suavemente curvados que se comportam localmente como espaços euclidianos. Embora possa parecer uma ferramenta matemática exótica, o conceito do espaço topológico de *Riemannian* é mais comum do que se pode esperar (YGER; BERAR; LOTTE, 2016).

Seja $\mathbf{e}_i \in \mathbb{R}^{E \times n}$ seja um trial i de EEG bruto, onde E o número de canais de EEG, e n o número total de amostras. Então o conjunto de treinamento $\mathbf{Ct} = \{\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_i, \dots, \mathbf{e}_N\}$, formado por N segmentos das classes $c1$ e $c2$, é usado primeiramente no estágio de calibração após a filtragem para calcular uma matriz de referência SPD, denotada como $\mathbf{C}_{ref}$. $\mathbf{C}_{ref}$ é a média de todo o conjunto de covariâncias rotuladas, mostrado na Equação 2.2 (BARACHANT *et al.*, 2011).

$$\mathbf{C}_p = \frac{1}{n-1} \mathbf{X}_p \mathbf{X}_p^T, \quad (2.1)$$

$$\mathbf{C}_{ref} = \mathfrak{A}(\mathbf{C}_1, \dots, \mathbf{C}_p) = \frac{1}{P} \sum_{p=1}^P \mathbf{C}_p, \quad (2.2)$$

onde $\mathbf{X}_p \in \mathbb{R}^{E \times Ct}$ é um segmento filtrado, que corresponde a classe $y_p \in (c1, c2)$, p é o número de rótulos, E é o número de canais de EEG, $\mathbf{C}_p \in \mathbb{R}^{E \times E}$ é uma amostra da matriz de covariância (SPD), e n é a duração da época em número de amostras. Todas as matrizes de covariância $\{\mathbf{C}_p\}_{p=1}^P$, são projetadas no plano tangente pela Equação 2.3, enquanto a operação inversa que projeta um elemento do espaço tangente de volta ao espaço topológico, ou seja, mapa exponencial é definida pela Equação 2.4 (DELISLE-RODRIGUEZ *et al.*, 2019).

$$\mathbf{S}_p = \log \left(\mathbf{C}_{ref}^{-\frac{1}{2}} \mathbf{C}_p \mathbf{C}_{ref}^{-\frac{1}{2}} \right), \quad (2.3)$$

$$\mathbf{C}_p = \exp \left(\mathbf{C}_{ref}^{-\frac{1}{2}} \mathbf{S}_p \mathbf{C}_{ref}^{-\frac{1}{2}} \right), \quad (2.4)$$

onde $\mathbf{S}_p$ é a projeção no plano tangencial, $\log(\cdot)$ denota o logaritmo e $\exp(\cdot)$ denota a exponencial. Além disso, a distância de *Riemannian* entre $\{\mathbf{C}_p\}_{p=1}^P$ e $\mathbf{C}_{ref}$, e a média geométrica pode ser calculada pelas Equações 2.5 e 2.6.

$$\delta_R(\mathbf{C}_p, \mathbf{C}_{ref}) = \left\| \log \left(\mathbf{C}_{ref}^{-1}, \mathbf{C}_p \right) \right\|_F = \left[\sum_{i=1}^E \log^2 \lambda_i \right]^{\frac{1}{2}}, \quad (2.5)$$

$$\mathfrak{G}(\mathbf{C}_1, \dots, \mathbf{C}_p) = \arg \min_{\mathbf{C}_{ref}} \left(\mathbf{C}_{ref}^{-1}, \mathbf{C}_p \right) \sum_{p=1}^P \delta_R^2(\mathbf{C}_p, \mathbf{C}_{ref}), \quad (2.6)$$

onde $\{\lambda_i\}_{i=1}^E$ são os autovalores reais de $\mathbf{C}_{ref}^{-1} \mathbf{C}_p$. A média geométrica é calculada por um processo iterativo que tem como objetivo projetar as matrizes de covariância no espaço tangente, estimando a média aritmética no espaço tangente e projetando a média aritmética no espaço topológico. Em seguida, precisa-se repetir os passos acima até sua convergência (DELISLE-RODRIGUEZ *et al.*, 2019).

Finalmente, a matriz de projeção $\mathbf{C}_{ref}$ é usada nos estágios de calibração e validação, para projetar as matrizes de covariância $\{\mathbf{C}_p\}_{p=1}^P$ na tangente espacial e essas matrizes de covariância podem ser usadas como recurso em um classificador considerando os seguintes operadores de vetorização modificados que empilha, com pesos apropriados, a parte superior triangular de $\mathbf{S}_p$ em $(E+1)E/2 \times 1$ vetor coluna, como mostrado na Equação 2.7. O coeficiente $\sqrt{2}$ é aplicado aos elementos não diagonais de $\mathbf{S}_p$, a fim de preservar a igualdade de normas $\|\mathbf{S}_p\|_F = \|\text{Vet}(\mathbf{S}_p)\|_2$.

$$\text{Vet}(\mathbf{S}_p) = [S_{p1,1}; \sqrt{2}S_{p1,2}; S_{p2,2}; \sqrt{2}S_{p1,3}; \sqrt{2}S_{p2,3}; \dots; S_{pE,E}] \quad (2.7)$$

Abaixo é apresentado o pseudo-algoritmo de *Riemannian*, que utiliza as funções *covariances*, *meancovariances*, e *tangentspace*, disponibilizado no site <<https://github.com/alexandrebarachant>>. E é o número de canais, n é o número de amostras de EEG por canal, i é o número de cada segmento e T indica o operador de transposição.

Pseudo-algoritmo de *Riemannian*

1. Seja $\mathbf{A}_{E,n,i}$ e $\mathbf{B}_{E,n,i}$, um set de validação e treinamento, respectivamente;
2. $\mathbf{X}_{E,n,i}$ e $\mathbf{Y}_{E,n,i}$ são os set de validação e treinamentos filtrados;
3. $\mathbf{C}_{train} = \text{covariances}(\mathbf{X})$;
4. $\mathbf{C}_{ref} = \text{meancovariances}(\mathbf{C}_{train}, 'riemann')$; calculando a média de riemannian
5. $\text{Trainingset} = \text{Tangentspace}(\mathbf{C}_{train}, \mathbf{C}_{ref})^T$; extraindo as características
6. $\mathbf{C}_{val} = \text{covariances}(\mathbf{Y})$;
7. $\text{Validationset} = \text{Tangentspace}(\mathbf{C}_{val}, \mathbf{C}_{ref})^T$; extraindo as características

2.3.3 Classificação

Algoritmos de classificação são usados para identificar padrões da atividade cerebral. O desempenho de um padrão depende do algoritmo de classificação empregado. Para escolher um classificador mais apropriado para um determinado conjunto de dados, as propriedades devem ser conhecidas (LOTTE *et al.*, 2007; LOTTE *et al.*, 2018). Principais definições usadas para descrever os diferentes tipos de classificadores disponíveis, são mostrados abaixo:

Generativo/Discriminativo Classificadores generativos (Quadrático de Bayes), aprendem os modelos de classe. Para classificar um vetor de recurso, os classificadores generativos calculam a probabilidade de cada classe e escolhem a mais provável. Já os discriminativos (SVM), aprendem a forma de discriminar as classes com o objetivo de classificar diretamente o vetor de características (LOTTE *et al.*, 2007).

Estático/Dinâmico A análise do comportamentos humano não-verbal podem ser realizadas observando os padrões *frame a frame* ou considerando uma sequência de *frames* como em uma série temporal. Essas duas abordagens são chamadas de classificação estática (baseada em *frames*) e classificação dinâmica (baseada em sequências de frames). Os classificadores estáticos mais utilizados são, o SVM, NN e árvore de decisão e tem sido utilizados no campo de reconhecimento de emoções. HMM e suas variações constituem-se como classificadores dinâmicos e são mais utilizados para melhorar a precisão de alguns tipos de reconhecimentos de padrões, como o reconhecimento de afeto a partir de modalidades visuais ou de áudio (PETRIDIS *et al.*, 2009).

Estável/Instável Classificadores estáveis (*Linear Discriminant Analysis* - LDA), têm baixa complexidade. Eles são considerados estáveis, pois pequenas variações no conjunto de treinamento não afetam consideravelmente o desempenho. Já os classificadores instáveis (Perceptrons multi camadas) têm uma alta complexidade, pois pequenas variações do conjunto de treinamento podem levar a importantes mudanças no desempenho (LOTTE *et al.*, 2007).

Regularizado Regularizar consiste em controlar com cuidado a complexidade do classificador com objetivo de evitar o excesso de treinamento. Um classificador regularizado tem bons desempenhos de generalização e é mais robusto em relação aos valores discrepantes (LOTTE *et al.*, 2007).

O classificador SVM consiste em um método de aprendizado para problemas de reconhecimento padrão. Esse método foi criado por Vapnik (VILELA, 2011), e vem sendo usado com grande sucesso em problemas, como a previsão de séries temporais, para enfrentar o reconhecimento, para o processamento de dados biológicos e para o diagnóstico médico. Esse método é essencialmente uma abordagem geométrica para o problema de classificação. Cada vetor de características do nosso conjunto de treinamento pode ser visto como um ponto x em um espaço $\mathbb{R}^n$ e o aprendizado consiste em “dividir” os elementos positivos dos negativos neste espaço euclidiano (VILELA, 2011).

Os SVM foram projetadas originalmente para classificações binárias, mas muitas aplicações práticas consistem em problemas de multi-classificação, que geralmente são convertidos em binários. Até o momento, vários métodos foram propostos para decompor e reconstruir problemas de multi-classificação, os quais se podem referir a uma boa visão desses métodos escritos por Rifkin (LIU; HAO; YANG, 2005).

O SVM gera um modelo de classificação na forma de função linear $f(x) = w * x + b$. Sendo w os valores dos pesos e b o valor dos bias e x são os valores de entrada. A localização do hiperplano é definida como $f(x) = 0 = w * x + b$. O exemplo na Figura 2 mostra um plano cartesiano sendo que os eixos x e y mostram as características, pontos pretos no lado esquerdo representam dados pertencentes à classe 1 e alguns pontos brancos no lado direito que representam dados pertencentes à classe -1. Os pontos pretos estão no lado do hiperplano que corresponde ao caso quando $f(x) > 0$ e os pontos brancos 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 de classificação (CASAGRANDE *et al.*, 2019).




Figura 2 – SVM linear (BUCH, 2008).

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 atenção e desatenção. Após construído o modelo, as novas amostras fornecidas no treinamento NFB 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, devido aos bons resultados quando aplicados a sinais EEG, lembrando que precisa também de bons dados para ensinar o SVM a interpretar o que são as classes (AMIN *et al.*, 2015; HARIHARAN *et al.*, 2014).

O hiperplano pode assumir diversas formas a fim de separar o máximo possível dois ou mais estados. Nesse sistema proposto, o SVM tem total importância, pois ele será o responsável em classificar o que é atenção e não atenção dos dados coletados.

O sistema de captura também possui eletrodos ativos, blindagem ativa para maior qualidade do sinal, facilidade no posicionamento dos eletrodos secos (não precisam de gel), oferecendo menor tempo para colocá-lo nos sujeitos (Figura 3c).

Para a aquisição e processamento do sinal cerebral foi usado um computador com processador i7-7700, um placa de vídeo GeForce GTX 1070 com 6 GB de memória, HDD 1 TB, SSD 120 GB, e 16 GB de memória RAM. A aquisição de dados foi realizada com um software da empresa *Cognionics*.

3.1.2 Jogo Sérió - *Neurofeedback Space*

O jogo *Neurofeedback Space* foi desenvolvido pela equipe do BRAEN com objetivo de proporcionar uma experiência de conforto e imersão para crianças com TDAH. Para processar o jogo foi utilizado um computador com processador i7-7700, placa de vídeo GTX 1080 com 6 GB de memória, HDD 1 TB, SSD 120 GB, e 16 GB de memória RAM. O tema espacial foi escolhido, pois o sistema de captura de EEG pode ser comparado a um capacete espacial usado pelos pilotos (MACHADO *et al.*, 2019).

O menu principal (Figura 4a) do jogo é dividido em três partes. Antes de jogar, o astronauta, como é chamado o jogador, deverá escrever seu nome, data de nascimento, o número da sessão e a data desta sessão (Figura 4b) (MACHADO *et al.*, 2019).




Figura 4 – Telas principais do jogo *Neurofeedback Space*; (a) - Menu principal; (b) - Cadastro dos sujeitos; (c) - Questionário para avaliar o paciente na experiência após o jogo; (d) - Ambiente do jogo online.

Na opção *Games*, presente no menu principal, estão presentes 3 modos do jogo com diferentes níveis de dificuldade, sendo o nível 1 o mais fácil, o nível 2 o intermediário e o nível 3 o mais difícil. Nesta pesquisa de mestrado foi utilizado somente o nível 1 do jogo, com novas adaptações implementadas de acordo com a ICC proposta na Seção 3.2. O jogo consiste em um foguete no espaço onde os sujeitos devem controlar sua velocidade por meio do sistema de captura de EEG, quanto mais alto seja o nível de atenção maior a velocidade do foguete (podendo chegar a 100%) a fim de capturar o máximo de estrelas possíveis. O jogo salva o total de estrelas capturadas no período do jogo (Figura 4d).

A opção *Comportamento*, presente no menu principal, é dedicada para avaliar a experiência do sujeito. Uma vez selecionada, é aberto um ambiente onde é possível registrar algumas informações sobre a experiência pós jogo (Figura 4c) (MACHADO *et al.*, 2019).

3.1.3 Avaliações Cognitivas

3.1.3.1 Bateria Psicológica para Avaliação da Atenção

A Bateria Psicológica para Avaliação da Atenção (BPA) tem como objetivo avaliar a capacidade da atenção. São avaliadas três tipos de atenção, a atenção concentrada (AC) com tempo de duração para fazer o teste de dois minutos, atenção dividida (AD) com tempo de duração para fazer o teste de quatro minutos e atenção alternada (AA) com tempo de duração para fazer o teste de dois minutos e trinta segundos (RUEDA; MONTEIRO, 2013).

A análise dos três testes em conjunto fornece uma medida de atenção geral. Os testes foram criados a partir de vários estímulos abstratos, com isso serviram para construir as três folhas de respostas (AC, AD e AA). A distribuição dos estímulos em cada teste, contém quatrocentos estímulos distribuídos em vinte linhas com vinte estímulos cada, sendo cento e vinte estímulos-alvo e duzentos e oitenta são estímulos distratores (RUEDA; MONTEIRO, 2013).

O resultado final é obtido considerando o estímulo-alvo de cada teste, subtraído pelos erros e das omissões que o sujeito cometeu. No caso da nota geral de atenção é obtido por meio da somatória dos pontos totais de cada teste (AC+AD+AA), sendo trezentos e sessenta a pontuação máxima possível (RUEDA; MONTEIRO, 2013).

3.1.3.2 Escala de Afetos Positivos e Negativos - PANAS

Afetos positivos (AP) e afetos negativos (AN) são indicados com o vigor e a frequência em que as pessoas vivenciam as emoções. Sujeitos com escores altos de AP tem grande experiência com episódios frequentes de prazer, logo, eles se consideram alegres entusiasmados e confiantes. Sujeitos com altos níveis de AN mostram repetidamente, experiências de desprazer, logo, são pessoas de forma geral que se acham tristes, desanimadas e preocupadas (ZANON *et al.*, 2013).

A Escala de Afetos Positivos e Negativos (PANAS) é uma breve medida de autocorrelato criada para fornecer índices independentes de AP e AN. Originalmente o PANAS foi criado ao selecionar empiricamente itens de um conjunto maior de descritores de humor que funcionavam como indicadores relativamente “puros” de AP e AN para adultos no idioma natural do inglês americano. Desde o desenvolvimento do PANAS, diferentes versões foram elaboradas com sucesso em diferentes idiomas, para crianças e para adolescentes (CARVALHO *et al.*, 2013). Além disso, o PANAS também tem sido amplamente empregado em pesquisas que visam entender o bem-estar subjetivo. De fato, o AP é considerado como elemento principal do bem-estar e da adaptabilidade geral (CARVALHO *et al.*, 2013).

3.2 Métodos

3.2.1 Modelo da Velocidade Baseada no Nível de Atenção

Com objetivo de enviar ao jogo valores de velocidades relacionado com os níveis de atenção dos sujeitos no momento do jogo, foi proposto um modelo utilizando regressão cúbica e interpolação para obter a velocidade no jogo online, e sua obtenção é explicada no texto que segue. Na Figura 5 são mostrados os modelos de velocidades para o estado de atenção e não atenção.

Sabendo que $\mathbf{X}$ é a matriz de vetores de características (ou padrões) formando um *cluster* de padrões relacionados ao estado de atenção com valor médio μ_A , e outro *cluster* de padrões relacionados ao estado de desatenção com valor médio μ_D . Nesse método são criados vetores de velocidades e coeficientes polinomiais para os estados de atenção e desatenção. Para melhor entendimento, padrões de atenção foram utilizados para explicar o funcionamento do método. Para calcular a distância de todos os padrões $\mathbf{x}_i$ até μ_A , foi aplicada a equação euclidiana (Equação 3.1)




Figura 5 – Curvas de velocidade segundo o nível de atenção; (a) - Modelo de velocidade usado com os padrões reconhecido como atenção; (b) - Modelo de velocidade usado com os padrões reconhecido como desatenção.

$$d_i = \sqrt{(\boldsymbol{\mu}_A - \mathbf{x}_i)(\boldsymbol{\mu}_A - \mathbf{x}_i)^T}, \quad (3.1)$$

onde d_i é a distâncias obtida entre o padrão $\mathbf{x}_i$ e a média $\boldsymbol{\mu}_A$. Para a curva da atenção, quando mais perto de $\boldsymbol{\mu}_A$ maior é a velocidade obtida, e quanto mais longe menor é a velocidade. A histerese é uma recompensa para o sujeito que está jogando, sendo ativada quando a velocidade chegar em seu valor máximo (100%), com isso a velocidade não irá diminuir até que o sujeito consiga manter um nível de atenção, tal que $d_i < D_{média}$. Esse valor $D_{média}$ é associado à velocidade média ($V_{média}$) obtida a partir das velocidades acima de 40% adquiridas pelo sujeito no jogo online da fase 2 de calibração (ver Figura 5a). O modelo facilita manter a velocidade máxima modificando o valor de $D_{média}$ mais próximo à velocidade mínima (V_{min}) correspondente a d_{min} , deixando o modo de jogo mais fácil. A partir das distâncias obtidas, no texto que segue, será explicado como obter o modelo da Figura 5a correspondente ao estado de atenção.

O conjunto de distâncias calculadas é analisado por meio do quartil para obter os valores de distâncias associados aos quartis em 25%, 50%, 75% e 100%. Os quartis ou percentis, dividem os valores ordenados em quartos. Logo, o 1º quartil do vetor de distâncias, é o menor valor do vetor que supera o 25% dos valores, o 2º quartil é a mediana, o 3º quartil é o menor valor do vetor que supera o 75% dos valores e o 4º quartil é o maior valor do vetor (100%) (CARVALHO *et al.*, 2011). Com os quartis calculados, foi necessário criar um limite superior e um limite inferior mais robustos para o vetor de distâncias, com objetivo de identificar *outliers*. São considerados *outliers* valores acima do limite superior e valores abaixo do limite inferior, e são representados pelas equações: $L_{inf} = 3^\circ \text{ quartil} - 1,5 \times (3^\circ \text{ quartil} - 1^\circ \text{ quartil})$ e $L_{sup} = 3^\circ \text{ quartil} + 1,5 \times (3^\circ \text{ quartil} - 1^\circ \text{ quartil})$.

Sabendo que $V_{min}=40$, $V_{med}=70$ e $V_{max}=100$ são valores que foram definidos pelos pesquisadores e estão relacionados ao limite inferior (L_{inf}), ao 2º quartil (mediana) e ao limite superior (L_{sup}), e que d_{min} é o valor mais próximo do L_{inf} , d_{med} é o valor mais próximo da mediana e d_{max} é o valor mais próximo do L_{sup} (ver Figura 5a). Foi utilizado os limites de velocidades (V_{min} , V_{med} e V_{max}), os limites das distâncias (d_{min} , d_{med} e d_{max}) e o conjunto de distâncias calculadas sobre os padrões de atenção em $\mathbf{X}$ para se obter um vetor de velocidades $\mathbf{V}$ usando a interpolação cúbica (*Piecewise Cubic Hermite Interpolating Polynomial* - PCHIP).

PCHIP é um método matemático desenvolvido para interpolação a partir de um determinado conjunto de pontos de dados em um plano para ajustar uma curva suave aos pontos. Este método permite construir uma curva que segue os valores predefinidos suavemente (AKIMA, 1970).

Com as distâncias e as velocidades geradas, próximo objetivo é utilizar essas distâncias e velocidades para obter os coeficientes de um polinômio de grau 3 (cúbico) que vai ser usado como modelo durante o estado de atenção no jogo. As equações abaixo mostram como obter o polinômio.

$$f = W_0 + W_1d^1 + W_2d^2 + W_3d^3 + \dots + W_nd^n + (S \times 40); \quad (3.2)$$

sendo f uma função de grau $n = 3$, $\mathbf{d}$ são os valores das distâncias obtidas pela Equação 3.1, $\mathbf{W}$ são os coeficientes polinomiais e S é referente ao modo *sham* podendo ter valores $S = 1$ (ativado) ou $S = 0$ (desativado). Supondo que a matriz coluna $\mathbf{V}$ contém N valores de velocidades, e a matriz $\mathbf{D}$ contém N valores de distâncias correspondentes:

$$\mathbf{V} = \begin{bmatrix} V_1 \\ V_2 \\ V_3 \\ \vdots \\ V_N \end{bmatrix} \quad \mathbf{D} = \begin{bmatrix} 1 & d_1 & d_1^2 & d_1^3 \\ 1 & d_2 & d_2^2 & d_2^3 \\ 1 & d_3 & d_3^2 & d_3^3 \\ & & \vdots & \\ 1 & d_N & d_N^2 & d_N^3 \end{bmatrix}, \quad (3.3)$$

onde $\mathbf{V}$ é uma matriz coluna com todos os valores de velocidades obtidos pelo PCHIP, e $\mathbf{D}$ é a matriz que contém todos os valores de distâncias obtidos da Equação 3.1. A estimativa dos coeficientes $\mathbf{W}$ é realizada através da Equação 3.4

$$\mathbf{W} = (\mathbf{D}^T \mathbf{D})^{-1} \mathbf{D}^T \mathbf{V}. \quad (3.4)$$

Finalmente, o polinômio cúbico foi usado como modelo pela ICC para obter a velocidade corresponde de um novo padrão $\mathbf{x}_i$ como distância d_i reconhecido como estado de atenção.

Para o estado de não atenção o procedimento para gerar a curva de velocidades é a mesma, porém o $V_{min} = 0$ (relacionado com L_{inf}), $V_{med} = 20$ (relacionado com a mediana) e $V_{max} = 40$ (relacionado com L_{sup}), d_{min} é o valor mais próximo do L_{inf} , d_{med} é o valor mais próximo da mediana e d_{max} é o valor mais próximo do L_{sup} . Os três valores são calculados com base nas distâncias obtidas entre os padrões de desatenção a média μ_D . O sentido da curva sobe de d_{min} para d_{max} , ou seja, quanto mais perto de μ_D menor a velocidade gerada, e quanto mais longe de μ_D mais rápido é a velocidade gerada (ver Figura 5b).

Para realizar a interpolação dos dados, foi utilizada a função *1-D data interpolation*¹ (*interp1*) do Matlab. A função *Polynomial curve fitting*² (*polyfit*) do Matlab foi utilizada para obter os coeficientes polinomiais. Para analisar o grau do polinômio e verificar a separação das curvas de atenção e não atenção, foi utilizado a função *Polynomial evaluation*³ (*polyval*) do Matlab.

3.2.2 Seleção de Padrões Baseado em Probabilidade

Com o objetivo de obter os vetores de características com maior probabilidade de corresponder ao estado de atenção, e obter um modelo mais confiável para o reconhecimento dos estados de atenção e não atenção, foi proposto um método baseado na análise de probabilidade para rejeitar padrões que supostamente são do estado de atenção mas não confiáveis, ou seja são padrões com maior probabilidade de corresponder ao estado de não atenção. Supondo que temos um conjunto de padrões ou vetores de características $\mathbf{X}$ que contém estados de atenção e não atenção. Então, seja $\mathbf{X} \in \mathbb{R}^{N \times f}$ um conjunto de vetores com f características contendo N objetos $\mathbf{x}_i \in \mathbb{R}^{1 \times f}$ cujos dados correspondentes ao estado de atenção obtido na fase de calibração são os primeiros $N/3$ objetos com laço aberto, seguidos por $N/3$ vetores característicos do estado de atenção coletados na fase de calibração com laço fechado, e contendo por último $N/3$ objetos do estado de repouso.

Denominamos calibração de laço aberto quando o sujeito foca sua atenção sob um objetivo, sem fazer uma ação ou controle (exemplo a velocidade do foguete da Figura 7a) usando o próprio nível de atenção. Calibração em laço fechado é quando o sujeito foca sua atenção sob um objetivo, fazendo uma ação ou controle (exemplo na velocidade do foguete da Figura 4d) usando o próprio nível de atenção. As duas fases de calibração descritas acima serão explicadas em detalhes na Seção 3.2.3. A probabilidade de cada padrão de atenção foi calculada usando as Equações 3.5, 3.6 e 3.7.

¹ <<https://www.mathworks.com/help/matlab/ref/interp1.html>>

² <<https://www.mathworks.com/help/matlab/ref/polyfit.html>>

³ <<https://www.mathworks.com/help/matlab/ref/polyval.html>>

$$d_{ij} = \sqrt{(\mathbf{x}_i - \mathbf{x}_j)(\mathbf{x}_i - \mathbf{x}_j)^T}, i \neq j \quad (3.5)$$

$$p_{ij} = \frac{\exp(-d_{ij})}{\sum_{i, i \neq j} \exp(-d_{ij})}, \quad (3.6)$$

$$p_j = \sum_{i=2N/3+1}^N p_{ij}, \quad (3.7)$$

onde i representa os objetos de 1 até N , j representa os objetos de 1 até $2N/3$, d_{ij} é a distância euclidiana entre $\mathbf{x}_i$ e $\mathbf{x}_j$, p_{ij} é a probabilidade de $\mathbf{x}_i$ e $\mathbf{x}_j$ corresponderem a uma mesma classe, p_j é a probabilidade de $\mathbf{x}_j$ de não corresponder ao estado de desatenção.

Os valores de p_j são usados para calcular um limiar, conforme mostrado na Equação 3.8, que é empregado posteriormente para selecionar ($p_j \leq p_{th}$) os padrões de atenção mais prováveis.

$$p_{th} = \max \{p_j\}_{j=1}^{N/3} \times \left(1 - \left| \max \{p_j\}_{j=1}^{N/3} - \max \{p_j\}_{j=N/3+1}^{2N/3} \right| \right). \quad (3.8)$$

Com os padrões mais prováveis de atenção escolhidos, foi preciso balancear os *clusters* contendo padrões do estado de atenção e não atenção por meio de uma amostragem aleatória. Por fim, um novo conjunto de calibração contendo padrões de atenção mais prováveis ($p_j \leq p_{th}$) é formado. Esse conjunto de padrões mais prováveis de atenção e não atenção, são balanceados, para obter uma ICC calibrada mais robusta para o reconhecimento de ambos estados estudados.

3.2.3 Interface Cérebro-Computador Proposta

Nesta pesquisa foi criada uma ICC usando as metodologias de análise descritas anteriormente para reconhecimento dos estados de atenção e não atenção. O sistema de captura de EEG foi configurado para que as coletas dos dados cerebrais fossem realizadas a uma frequência de amostragem de 500 Hz, com filtro passa-banda de 0,5 a 100 Hz com escala de amplitude de 500 μV . Os eletrodos utilizados na pesquisa foram: Fp1, Fp2, F3, F4, F7, F8, Fz, C3, C4, Cz, T3, T4, P3, P4, P7, P8, Pz, O1 e O2. A ferramenta utilizada para importar os dados de EEG para o software *Matlab* será o *LabStreamingLayer* (LSL). Para melhor entendimento, o sistema proposto usado foi dividido em 3 fases: 1) Calibração com laço aberto durante 5 min, 2) Calibração com laço fechado durante 1 min, e 3) Treinamento da Atenção durante 5 min. Na Figura 6 a ICC desenvolvida é apresentada.




Figura 6 – Diagrama da ICC desenvolvida.


De forma geral, na ICC proposta é usado um filtro passa-banda sob janelas de 2 segundos para eliminar as frequências fora da banda de interesse, a geometria de *Riemannian* para extrair os padrões a partir de uma análise de matrizes de covariância (ver Seção 2.3.2), o SVM com *kernel* RBF para reconhecimento dos padrões de atenção e não atenção e um modelo usado na Fase 2 “Calibração com laço fechado” e na Fase 3 “Treinamento da Atenção” que permite calcular a velocidade do foguete segundo o estado de atenção. Então, no treinamento online da atenção o sujeito pode usar seu estado de atenção para jogar, acelerando ou desacelerando um foguete.

3.2.4 Calibração da ICC


Nessa seção são apresentadas a Fase 1 e a Fase 2 de calibração da ICC. As coletas de dados foram realizadas em dez ciclos de atenção e não atenção. Essas coletas foram divididas em duas partes, cada uma com cinco ciclos. Na Fase 1 de calibração são utilizados os cinco primeiros ciclos para calibrar a ICC, e na Fase 2 são utilizados os cinco últimos ciclos para validar a ICC (Figura 7a).

Os sinais de EEG adquiridos são filtrados por meio de janelas de dois segundos na banda de frequências entre 1 a 30 Hz aplicando um filtro passa-banda baseado na FFT e IFFT, pois os estados de atenção e não atenção estão relacionados com essa faixa (Seção 2.3.1).

A geometria de *Riemannian* (ver Seção 2.3.2) foi utilizada para realizar a extração de características a partir da análise de matrizes de covariância. Essa geometria é aplicada sobre o conjunto de matrizes de covariâncias obtidas dos dados oriundos da filtragem. Os dados de EEG dos primeiros cinco ciclos são usados na geometria de *Riemannian* para



(a)



(b)

Figura 7 – 7a - Ambiente virtual usado na Fase 1 de calibração para coletas de atenção e não atenção. 7b - Ambiente Virtual usado na Fase 2 de calibração para coleta de dados online por 1 minuto.

calibrar a ICC. Cada segmento de dois segundos, é filtrado e usado para calcular matriz de covariância. Então, utilizando essas matrizes, é obtido uma matriz de projeção, usada para projetar as matrizes de covariância no plano tangencial, obtendo o vetor de padrões (ou características) (ver Seção 2.3.2). Em seguida, aplicando o classificador SVM com kernel RBF (ver Seção 2.3.3), é gerado o primeiro modelo de classificação.

Os dados correspondentes aos últimos cinco ciclos foram utilizados para validar a ICC, aplicando o mesmo processo de filtragem e de extração de características. A matriz de projeção é a mesma obtida nos cinco primeiros ciclos. Foi utilizado um preditor, com objetivo verificar se o modelo de classificação gerado anteriormente está reconhecendo corretamente os estados de atenção e não atenção. Os padrões de atenção e não atenção corretamente reconhecidos na validação do classificador são utilizados para obter um modelo de velocidades (ver Seção 3.2.1).

Com o primeiro modelo de classificação criado e testado, o modelo de velocidades e a matriz de projeção de *Riemannian* obtido para calibrar e validar a ICC, o sujeito é requisitado a controlar a velocidade do foguete com seu nível de atenção durante 1 minuto, o qual denominamos calibração Fase 2 com laço fechado (Figura 7b).

Os novos dados de atenção capturados na Fase 2 são usados junto aos dados de atenção e não atenção para calibrar a ICC na Fase 1, com o objetivo de obter um conjunto de dados balanceado com padrões dos estados de atenção e não atenção mais confiáveis ou prováveis (ver Seção 3.2.2). Esse novo conjunto de dados balanceado é usado para obter novamente a matriz de projeção a partir da geometria de *Riemannian*, baseado na análise de matrizes de covariância. Os vetores de padrões obtidos a partir da nova matriz de projeção são usados para obter um novo modelo de classificação. O conjunto de padrões obtidos para validar na Fase 1 de calibração é usado para avaliar a ICC calibrada, e obter padrões corretamente reconhecidos que são usados para calcular um novo modelo de velocidade (ver Seção 3.2.1).

Os padrões de atenção e não atenção reconhecidos corretamente na validação do modelo do classificador foram usados para gerar a curva de velocidades. Esses padrões passam pelo mesmo procedimento citado na Seção 3.2.1. Com isso a nova matriz de projeção de *Riemannian*, o novo modelo de classificação e o novo modelo de velocidades foram usados no treinamento da atenção.

3.2.5 Treinamento online da Atenção

Gerado o segundo modelo, o sujeito passa controlar a velocidade do foguete de acordo com seu nível de atenção durante um período de cinco minutos (Figura 8). Com o fim do treinamento, dados de EEG, pontuação, velocidade do foguete foram salvas para posterior análise da efetividade do jogo para o treino da atenção.




Figura 8 – Tela mostrada ao sujeito durante o treinamento online de 5 minutos.

3.3 Validação

3.3.1 Participantes

Para o estudo, o treinamento da ICC foi realizado em dezoito sujeitos saudáveis (dez homens e oito mulheres com idade entre 20 e 45 anos). Todos participaram de forma voluntária neste estudo.

As coletas de dados e treinamentos da ICC foram realizados no laboratório de pesquisa do grupo BRAEN. 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.

3.3.2 Protocolo Experimental

Antes de iniciar as coletas os voluntários eram questionados quanto seu estado de saúde e se faziam uso de medicamentos. E aqueles que faziam uso de substâncias psicotrópicas que afetam a cognição (metilfenidato, rivotril, entre outros), que estavam grávidas ou lactantes, e com diagnóstico conhecido de doenças psiquiátricas (depressão, TDAH, entre outros), neurológicas (AVC, entre outros) e crônicas (diabetes e câncer) não foram admitidas no treinamento.

Esse protocolo foi submetido e aprovado pelo Comitê de Ética e Pesquisa (CEP) e está registrado sob o nº 30035620.6.0000.5542. O protocolo consistia em três grupos (G1, G2, G3), sendo cada grupo composto por seis participantes. Os três grupos são de intervenção, e para cada grupo as velocidades se comportam de maneira diferente.

O G1, não usa o efeito da histerese, ou seja, não é recompensado por atingir a velocidade máxima. O sujeito consegue se manter na velocidade máxima, caso seu nível de atenção aumente, ou seja, o valor distância fique menor possível (limite inferior) com isso mais perto do *cluster* de atenção (Figura 9a).

Para o G2, foi usado um limiar de 40% o qual coincide com a velocidade mínima no estado de atenção, e a histerese é ativada. O sujeito consegue chegar na velocidade máxima facilmente e como recompensa a velocidade não cairá até que a ICC reconheça o estado de não atenção (Figura 9b), melhor explicado na Seção 3.2.1.

No G3 (Figura 9c) a histerese é ativada. A recompensa é ativada quando o sujeito chegar na velocidade máxima, deste modo, ele ficará mais tempo em V_{max} . Depois da fase 2 de calibração, a velocidade de recompensa é calculada. Primeiramente é definido um limiar (V_{limiar}) com valor de 0,80 (80%), logo após, é definida uma média de todas as velocidades obtidas acima de 40% ($V_{\mu 40}$) no jogo online para a fase 2 de calibração. Por fim, a velocidade de recompensa $V_{média}$ é calculada (ver Figura 5a), representada pela




Figura 9 – Comportamento das velocidades para o grupo: (a) - G1; (b) - G2; (c) - G3

equação: $V_{média} = V_{\mu 40} + (V_{max} - V_{\mu 40}) \times V_{limiar}$.

No primeiro dia, assim que o sujeito chegou no laboratório, foi aplicado primeiramente o teste psicológico BPA, que mede o nível de atenção dos sujeitos. Também foi aplicado uma escala de afeto positivo e negativo (PANAS) com o objetivo de medir o bem estar dos sujeitos. Esses dois testes foram aplicados pela Psicóloga e mestranda em Psicologia da UFES, Jade Carvalho. Para fazer esse teste de atenção foi pedido que todos que estavam na sala, com exceção do aplicador, saíssem da sala, pois é obrigatório um ambiente mais silencioso e tranquilo para conseguir fazer um teste mais efetivo e sem interferência externa. O objetivo desses testes iniciais são para verificar se os sujeitos podem ter ou não problemas cognitivos.

Feitos os testes de atenção e aplicado o PANAS, foi pedido ao sujeito que se sentasse em uma cadeira confortável em frente ao computador com as pés completamente no chão e as mãos em cima das coxas. Antes de começar foi comunicado ao sujeito como iria funcionar todo treinamento NFB. Para a coleta de dados, foi mencionado que o tempo total da coleta seria de cinco minutos, sendo dez sequências de trinta segundos (quinze

segundos para atenção e quinze segundos para não atenção, Figura 7a).

A coleta de dados para o estado de atenção consiste em uma tela com um foguete e o sujeito deve escolher um ponto na tela do computador que consiga sentir mais confortável, e quando o foguete desaparecer, o sujeito é orientado a não focar em nenhum ponto da tela. Logo após o treinamento, o sujeito passa por um jogo online com duração de um minuto (Figura 7a), onde é recomendado a focar no mesmo ponto do treinamento, pois serão utilizados esses dados de atenção para retreinar o sistema. Depois que o sistema é retreinado o teste online começa, e tem duração de cinco minutos (Figura 8), e o sujeito é aconselhado novamente a focar no mesmo ponto do treinamento.

Ao final de cada sessão, foram feitas quatro perguntas: “Durante o jogo você sentiu mais agitado ou mais relaxado?”, “Você está mais concentrado ou mais distraído?”, “Como está sua motivação?” e “O quão difícil você achou o jogo?”. Os dois últimos foram respondidos em uma escala *Likert* de 5 pontos. A escala na terceira opção foi: 1-não motivada, 2-menos motivada, 3-neutra, 4-motivada e 5-muito motivada. E na ultima pergunta: 1-muito fácil, 2-fácil, 3-neutro, 4-difícil e 5-muito difícil (Figura 4c) (MACHADO *et al.*, 2019).

3.3.3 Análise de Dados

Nesta seção são apresentados alguns métodos de análise dados que foram usados para analisar a eficiência da ICC proposta. Acurácia é uma métrica que verifica o desempenho de um conjunto de dados. Para uma classificação binária, as representações da matriz de confusão para a acurácia são mostradas pelas Equações 3.9.

$$Acc = \frac{VP + VN}{VP + FP + VN + FN}, \quad (3.9)$$

onde Acc é o valor da acurácia, VP a quantidade de verdadeiros positivos que foi reconhecido, FP a quantidade de falsos positivos reconhecidos, VN a quantidade de verdadeiros negativos reconhecidos, FN a quantidade de falsos negativos reconhecidos.

O coeficiente κ pode ser definido como uma medida usada para testar o grau de concordância (confiabilidade e precisão) em um classificador (PERROCA; GAIDZINSKI, 2003). Na Equação 3.10 é mostrado como é calculado esse coeficiente.

$$\kappa = \frac{P_o - P_a}{1 - P_a}, \quad (3.10)$$

onde P_o é a concordância relativa observada entre os avaliadores e P_a é a concordância hipotética de probabilidade de chance, usando os dados observados para calcular as probabilidades de cada observador ver aleatoriamente cada categoria (FONSECA; SILVA; SILVA, 2007).

Apesar de ser utilizado para o estudo de confiabilidade, este método apresenta limitações na medida em que não fornece informações a respeito da estrutura de concordância e discordância, muitas vezes, não considerando aspectos importantes presentes nos dados. As faixas de confiabilidade para os valores de κ são: $< 0,40$ mostra uma confiabilidade ruim, entre $0,40 - 0,75$ mostra uma confiabilidade mediana e $> 0,75$ mostra uma confiabilidade excelente (PERROCA; GAIDZINSKI, 2003).

No caso de avaliar a precisão corrigida por acaso de um classificador em relação a um processo “verdadeiro” de geração de rótulo, o κ é uma estatística muito relevante nessas configurações. Logo, uma estimativa mais realista da eficácia do classificador é a proporção de rótulos que o classificador consegue reconhecer, isso é o que o κ representa (JAPKOWICZ; SHAH, 2011).

A potência relativa (PR) permite analisar as ativações cerebrais nos sujeitos, calculada para a Fases 1 e Fase 2 de calibração, e para o treinamento da atenção. Os sinais de EEG capturados foram transformados no domínio da frequência usando a FFT (ver Seção 2.3.1), calculando a potência das ondas teta (4 a 7 Hz, θ) e beta (13 a 30 Hz, β) e a relação entre elas (θ/β). Neste estudo a PR é calculada através da Equação 3.11:

$$PR_{\%} = \frac{A_{\theta/\beta} - R_{\theta/\beta}}{R_{\theta/\beta}} \times 100, \quad (3.11)$$

sendo $A_{\theta/\beta}$ a potência da relação θ/β para o estado de atenção e $R_{\theta/\beta}$ a potência da relação θ/β para o estado de não atenção. A relação θ/β foi escolhida devido que ela está relacionada aos tratamentos de atenção para pessoas com TDAH, sendo que é recomendado reduzir o nível da banda θ e aumentar o nível β (YANG *et al.*, 2015; LIU *et al.*, 2016).

4 Resultados e Discussão

Neste capítulo são apresentados os resultados e discussão do presente estudo. Ele está dividido em duas seções. Na seção 4.1 são analisados os modelos de velocidade das duas fases de calibração, o comportamento das velocidades na coleta para a Fase 2 de calibração e no treinamento da atenção, e a potência relativa θ/β . Na seção 4.2 são expostas e analisadas as médias por minuto de cada sujeito no treinamento da atenção e o desvio padrão para cada minuto por sujeito. Além disso, analisa a potência relativa θ/β por sujeito a cada minuto, expõe os resultados dos testes cognitivos e as respostas das perguntas comportamentais realizadas ao fim da sessão de cada sujeito.

4.1 Calibração da ICC

Na Tabela 1 são apresentados os coeficientes κ e as acurácias obtidas na Fase 1 e Fase 2 de calibração, obtidos sob o mesmo conjunto de dados de validação, e a pontuação da coleta online para a Fase 2. Esses dados de validação foram coletados nos últimos cinco ciclos da coleta para a Fase 1, e a pontuação foi obtida a partir da coleta online para a Fase 2 de todos os sujeitos que participaram da pesquisa.

É possível observar que no G1 houve um aumento no coeficiente κ e na acurácia da Fase 1 para Fase 2 para os sujeitos S3G1 e S6G1. Esse aumento do coeficiente κ e da acurácia da Fase 1 para a Fase 2 de calibração, mostra que o protocolo utilizado (dez ciclos de coleta para atenção e não atenção) na coleta de dados para a primeira calibração da ICC, auxiliou na obtenção de dados reais de atenção e não atenção. Visto que esses dados reais significam que os sujeitos conseguiram manter o foco enquanto o foguete estava sendo exibido na tela, e quando a tela preta com as estrelas foi apresentada, os sujeitos conseguiram não focar em nenhum ponto da tela.

Outro motivo pelo qual a acurácia e o coeficiente κ tiveram esse aumento, foi devido ao uso da geometria de *Riemannian* a partir da análise de matrizes de covariância (ver Seção 2.3.2). Na Fase 1 de calibração obtém-se da geometria de *Riemannian* uma matriz de projeção, essa matriz é usada para as Fases 1 e 2 de calibração e para o treinamento da atenção, sendo importante no reconhecimento dos estados de atenção e não atenção. Atualmente, a geometria de *Riemannian* é utilizada para extração de características de dados de imagem motora, obtendo resultados eficientes para o coeficiente κ e para as acurácias, mostrando que esse método obtém padrões mais confiáveis em um conjunto de dados filtrados (DELISLE-RODRIGUEZ *et al.*, 2019; ROMERO-LAISECA *et al.*, 2020; GAUR *et al.*, 2018; BARACHANT *et al.*, 2013).

Além disso, o aumento no coeficiente κ e nas acurácias da Fase 1 para a Fase 2, foi também devido ao método de seleção de padrões baseado em probabilidade (ver Seção 3.2.2). Esse método permitiu reconhecer os padrões de atenção que melhor representam o estado de atenção, fazendo com que tenha uma matriz de padrões de atenção mais confiáveis. No estudo feito por [Gaur et al. \(2018\)](#), foi proposto um método de filtragem baseado em decomposição de modo empírico multivariado (MEMD) específico do sujeito. O método MEMD decompõe simultaneamente os sinais EEG multicanal em um grupo de funções de modo intrínseco multivariado. Essa decomposição nos permite extrair as informações entre canais. Foi usado a geometria de Riemannian para extrair as características, e o desempenho da ICC foi verificado usando coeficientes κ e acurácias.

Tabela 1 – Desempenho da ICC nas fases 1 e 2 de calibração.

Grupo 1	Calibração				
	Fase 1		Fase 2		
	κ	Acurácia (%)	κ	Acurácia (%)	Pontuação
S1G1	0,70	85,00	0,70	85,23	12
S2G1	0,88	93,00	0,86	92,30	17
S3G1	0,66	83,00	0,70	85,38	12
S4G1	0,64	83,20	0,63	81,40	17
S5G1	0,29	64,53	0,17	58,63	12
S6G1	0,71	85,84	0,91	95,23	13
Média	0,65	82,42	0,66	83,02	14

Grupo 2	κ	Acurácia (%)	κ	Acurácia (%)	Pontuação
S1G2	0,50	72,92	0,40	71,46	26
S2G2	0,57	78,38	0,61	79,84	25
S3G2	0,64	82,23	0,44	70,61	24
S4G2	0,18	58,76	0,23	61,15	29
S5G2	0,52	76,38	0,70	84,76	15
S6G2	0,06	52,76	-0,04	48,23	28
Média	0,31	70,23	0,39	69,24	25

Grupo 3	κ	Acurácia (%)	κ	Acurácia (%)	Pontuação
S1G3	0,05	52,46	0,12	56,84	11
S2G3	0,97	98,30	0,93	96,61	13
S3G3	0,90	94,92	0,84	92,07	12
S4G3	0,36	68,15	0,40	72,53	14
S5G3	0,71	85,69	0,81	90,92	14
S6G3	0,68	84,07	0,69	84,30	12
Média	0,61	80,59	0,63	82,22	14

Outros sujeitos tiveram uma queda nos coeficientes κ e nas acurácias da Fase 1 para a Fase 2 de calibração, como exemplo o sujeito S5G1 obteve uma redução no coeficiente κ de 0,29 para 0,17 e nas acurácias de 64,53% para 58,63%. Essa redução pode ter ocorrido devido ao estímulo visual, pois mesmo o classificador estando treinado para reconhecer padrões de atenção e não atenção, a ICC pode responder aos estímulos visuais de forma inadequada. Além disso, barulhos externos e movimentos corporais podem afetar a atenção dos sujeitos no momento da coleta, e isso pode refletir negativamente na qualidade dos dados.

Os sujeitos do G1, de forma geral, apresentaram altos valores nos coeficientes κ e nas acurácias, e alguns sujeitos tiveram melhoras no desempenho da ICC da Fase 1 para a Fase 2 de calibração, mostrando que mesmo com alguns problemas já citados é possível obter uma ICC calibrada mais robusta. Com isso, acredita-se que a Fase 2 de calibração e o método proposto para obter padrões com maior probabilidade de corresponder ao estado de atenção foram essenciais para o desempenho da ICC.

Os sujeitos do G2 apresentaram pontuações altas, mas os valores das acurácias e os coeficientes κ ficaram baixos em comparação ao sujeitos do G1. Isso está relacionado ao efeito facilitador da histerese do modelo de velocidade proposto (ver Seção 3.2.1). O sujeito S3G2 apresentou uma redução no coeficiente κ de 0,64 para 0,44 e uma redução na acurácia de 82,23% para 70,61% com 24 pontos no online para a Fase 2, já o sujeito S5G2 houve um aumento no coeficiente κ de 0,52 para 0,70 e um aumento na acurácia de 76,38% para 84,76% com 15 pontos no online para Fase 2. Ambos os sujeitos apresentaram um efeito contrário em relação as pontuações obtidas (Tabela 1). Esse efeito contrário na pontuação pode ter sido causado pelo impacto negativo do estímulo visual na resposta de saída da ICC, pois o jogo pode funcionar sem o sujeito usar seu nível de atenção.

Os sujeitos do G3, exceto os S3G3 e S2G3, tiveram um aumento no coeficiente κ e nas acurácias da Fase 1 para a Fase 2 de calibração. As maiores pontuações observadas são dos sujeitos que possuem maiores valores de κ e de acurácias. Esses resultados estão relacionados com o efeito de recompensa que o grupo possui, com os resultados dos testes cognitivos da Tabela 2 e com as respostas comportamentais da Tabela 3. O sujeito S2G3 será analisado mais a frente (Figura 13), pois ele possui diagnóstico de TDAH e seus resultados foram excelentes, em comparação ao seu próprio grupo. Com diagnóstico de TDAH, o sujeito S2G3 comparado aos outros sujeitos apresentou valores tais que demonstram que o mesmo conseguiu manter sua atenção, e ele será analisado mais a frente (Figura 13).

O sujeito S2G1, teve bons resultados tanto no coeficiente κ (0,88 para 0,86), quanto na precisão (93,00% para 92,30%). Logo, ele foi escolhido para ser melhor analisado, verificando como ficaram os modelos de velocidades da atenção e não atenção na Fase 1 e Fase 2 de calibração. Foi verificado o comportamento da velocidade na Fase online de calibração e no treinamento da atenção e como ficou a potência relativa θ/β na coleta de dados, na coleta para a Fase 2 de calibração, e no treinamento da atenção (Figura 10).




Figura 10 – Sujeito S2G1 - Curvas de velocidade de atenção e não atenção (a,b). Comportamento das velocidades nas fases online (c,d). Potência relativa θ/β (e, f, g).

Os resultados do sujeito S2G1 são mostrados na Figura 10. É possível observar na Figura 10a, que o modelo da Fase 2 de calibração se ajusta melhor em relação a Fase 1, logo, demanda um pouco mais de atenção do sujeito para o foguete atingir a maior velocidade ficando mais próximo do *cluster* de atenção. Entretanto, o efeito contrario é obtido na Figura 10b que está relacionado com o estado de não atenção. Nesta Figura é possível observar que também houve um melhor ajuste na Fase 2 em relação a Fase 1, na qual o sujeito também necessita de um maior esforço para que o foguete consiga chegar na velocidade máxima, ficando mais distante do *cluster* de não atenção. Esse melhor ajuste referente a Fase 1 e a Fase 2 da curva de velocidade, foi devido aos padrões extraídos pela geometria de *Riemannian* a partir da análise de matrizes de covariância (ver Seção 2.3.2). Outro motivo para o melhor ajuste foi devido a seleção de padrões baseado em

probabilidade (ver Seção 3.2.2) na coleta online para Fase 2 de calibração, onde o método conseguiu identificar os padrões de atenção mais relacionados com o estado de atenção, com isso obtendo um melhor modelo de velocidades.

Na Figura 10c e 10d são mostrados os comportamentos das velocidades na Fase 2 de calibração e no treinamento de atenção. Na Figura 10c é possível observar que o sujeito conseguiu chegar nas velocidades mais altas, e não houve redução abaixo de 40%. Já na Figura 10d, o sujeito consegue manter por um bom tempo sua atenção, havendo poucas reduções de velocidade para zero. Além disso, a possibilidade do sujeito conseguir se manter por mais tempo em velocidades altas não havendo muitas reduções, foi possível devido geometria de *Riemannian* através da análise de matrizes de covariância, obtendo padrões mais representativos usados para a calibração e a validação do classificador, obtendo um melhor reconhecimento dos estados de atenção e não atenção. Um modelo de velocidades bem ajustado deixa o jogo online mais fluído e real, de tal maneira que o sujeito possa sentir que a velocidade do foguete aumenta de acordo com seu esforço na atenção.

Nas Figuras 10e, 10f e 10g, são mostrados três mapas topográficos cerebrais, onde estão representadas as médias das potências relativas θ/β para cada eletrodo (representados pelos pontos pretos). As Figuras 10e e 10f, foram geradas a partir dos padrões do conjunto de validação, que foram reconhecido ou confirmado como estado de atenção ou não atenção, nas Fases 1 e 2, respectivamente. Mapas topográficos são usados como visualização para diversos tipos de tratamento.

Nas Figuras 10e e 10f o sujeito conseguiu recrutar mais a região frontal (Fp1, Fp2, F7, F8) para a coleta e para a Fase 2 de calibração. Na Figura 10g, observa-se que houve uma melhora na ativação em relação as Fases anteriores, conseguindo recrutar também a região temporal esquerda (T3). No estudo feito por Yang *et al.* (2015), mostrou um treinamento NFB utilizando como protocolo o aumento do nível de β (15 a 18 Hz) e a redução do nível θ (4 a 7 Hz), os resultados mostraram uma redução significativa em θ , enquanto não houve alteração significativa encontrada na banda β , com isso os valores da relação θ/β foram aumentados devido a redução do nível θ ao longo do treinamento. As regiões parietal, frontal e central, tiveram um aumento na relação θ/β ao longo do treinamento, sendo o lobo parietal foi a região cerebral que teve valores mais significativos. A Figura 10g em relação as Figuras 10e e 10f mostram que o sujeito precisou ter um maior nível de atenção para conseguir jogar e fazer com que o foguete chegasse na velocidade máxima. Esse esforço resultou no recrutamento da região temporal esquerda do cérebro.

O sujeito S5G1 obteve o menor desempenho na ICC no G1, havendo reduções no coeficiente κ de 0,29 para 0,17, e na acurácia de 64,53% para 58,63%. Logo, o sujeito S5G1 foi escolhido para ser melhor analisado, verificando como ficou os modelos de velocidades da atenção e não atenção na Fase 1 e na 2 de calibração. Foi verificado o comportamento da velocidade na Fase online de calibração e no treinamento da atenção e como ficou as médias das potências relativas θ/β na coleta de dados, na coleta para a Fase 2 de calibração e no treinamento da atenção (Figura 11).




Figura 11 – Sujeito S5G1 - Curvas de velocidade de atenção e não atenção (a,b). Comportamento das velocidades nas fases online (c,d). Potência relativa θ/β (e, f, g).

Na Figura 11a é possível observar que as curvas da Fase 1 e Fase 2 de calibração estão bem ajustadas, havendo uma pequena diferença de ajuste na subida das curvas. Já na Figura 11b, mostra que a curva da Fase 1 de calibração ficou mais ajustada em relação a Fase 2. Na Figura 11c é mostrado o comportamento das velocidades na coleta para a Fase 2 de calibração. Observa-se que a velocidade do foguete ficou variando muito entre a curva de atenção e não atenção, seu nível de atenção fez o foguete chegar a 80% de velocidade e houve muitas quedas na velocidade do foguete para 20%. Já na Figura 11d é possível analisar que o sujeito até na metade da sessão conseguiu fazer com que o foguete chegasse a velocidades mais altas, entretanto, a velocidade do foguete foi reduzida da metade até o final do treinamento, mostrando que o sujeito ficou cansado. Na Figura 16, mostra uma

redução na ativação a partir do segundo minuto mostrando que o sujeito possa realmente ter ficado cansado nesses momentos, o mesmo relata na Tabela 3 que achou o jogo difícil. Nas Figuras 11e, é possível observar que em todo escalpo cerebral, não houve uma boa ativação, havendo em sua maioria valores com porcentagem positiva. Já na Figura 11f, há uma melhora na ativação nas regiões frontal, temporal e occipital. Na Figura 11g, ele apresentou uma modulação cortical na região temporal, o qual é relacionada com o estado de atenção.

O sujeito S6G1 teve o melhor desempenho na ICC no G1, havendo um aumento no coeficiente κ de 0,71 para 0,91, e um aumento na acurácia de 85,84% para 95,23%. Logo, ele foi escolhido pelos pesquisadores para ser melhor analisado, verificando como ficou os modelos de velocidades da atenção e não atenção na Fase 1 e na 2 de calibração. Foi verificado o comportamento da velocidade na Fase online de calibração e no treinamento da atenção e como ficou as médias das potências relativas θ/β na coleta de dados, na coleta para a Fase 2 de calibração e no treinamento da atenção (Figura 12).




Figura 12 – Sujeito S6G1 - Curvas de velocidade de atenção e não atenção (a,b). Comportamento das velocidades nas fases online (c,d). Potência relativa θ/β (e, f, g).

Na Figura 12a é possível observar que houve pouca diferença no ajuste das curvas da Fase 1 e Fase 2 de calibração, estando bem sobrepostas, mostrando que o nível de atenção para as duas Fases de calibração foram parecidas. Já na Figura 12b é mais nítido observar que a curva da Fase 2 de calibração ficou melhor ajustado em relação a curva da Fase 1, mostrando que a segunda calibração foi importante para obter um melhor modelo de velocidade para o estado de não atenção.

Na Figura 12c é observado o comportamento das velocidades na coleta para a Fase 2 de calibração. Observa-se que o sujeito se esforçou em manter seu nível de atenção de modo que a ICC reconheceu o estado de atenção várias vezes, pois na maioria do tempo a velocidade do foguete foi $\geq 40\%$. Já na Figura 12d é apresentado o comportamento das velocidades no treinamento da atenção. O sujeito conseguiu manter a velocidades do foguete acima de 40% por mais tempo comparado com a Figura 12c, chegando até a 80%, confirmando a melhora no desempenho da ICC mostrado na Tabela 1.

Nas Figuras 12e, 12f e 12g são apresentados as médias das potências relativas θ/β das coletas para a Fase 1 e 2 de calibração e do treinamento da atenção. Na Figura 13e é possível ver que o sujeito conseguiu recrutar mais a região frontal do cérebro, sendo Fp1, F7 e F8 os eletrodos com maior ativação, esse resultado foi igual na Fase 2 de calibração (Figura 13f) tendo os mesmos eletrodos mais ativados. Na Figura 12g, é possível observar uma melhora na ativação em quase todo escalpo cerebral, pois as porcentagens ficaram com valores mais negativos (cor mais azul). O sujeito recrutou mais regiões do cérebro para conseguir manter sua atenção por mais tempo, tendo Fp1, F8, T3 e Pz as regiões mais ativadas. Essa maior ativação é devido ao esforço que o sujeito precisou fazer para aumentar seu nível de atenção, com isso a velocidade do foguete poderia chegar a uma velocidade máxima.

De modo geral, o sujeito S6G1 obteve melhores resultados no desempenho da ICC da Fase 1 para a Fase 2 de calibração (Tabela 1), nos modelos de velocidade e nas ativações cerebrais. Esses bons dados é devido ao reconhecimento de padrões mais confiáveis de atenção e não atenção utilizando a geometria de *Riemannian* através de análises de matrizes de covariância, o método de seleção de padrões baseado em probabilidade conseguiu identificar os padrões que mais representam o estado de atenção, com isso obtendo uma melhor matriz de projeção, um modelo mais confiável de classificação e de velocidade.

O sujeito S2G3 (Figura 13) é um caso especial a se analisar, pois ele possui diagnóstico de TDAH. Foi verificado as curvas do modelo de velocidade para atenção e não atenção, como se comportaram as velocidades na coleta para a Fase 2 de calibração e no treinamento da atenção, e como ficou a ativação cerebral usando a média das potências relativas θ/β para cada eletrodo, e por fim foi feito uma comparação com o sujeito S2G1 (Figura 10) descrito acima. O sujeito S2G3 obteve altos valores nos coeficientes κ e acurácias, havendo uma redução no desempenho da Fase 1 para a Fase 2 de calibração (κ

de 0,97 para 0,93 e acurácia de 98,30% para 96,60%).




Figura 13 – Sujeito S2G3 - Curvas de velocidade de atenção e não atenção (a,b). Comportamento das velocidades nas fases online (c,d). Potência relativa θ/β (e, f, g).

Nas Figuras 13a e 13b são apresentados os modelos de velocidades da Fase 1 e Fase 2 de calibração para o estado de atenção não atenção (Seção 3.2.1). As duas curvas de atenção e não atenção estão muito bem ajustadas, houve pouca diferença nos ajustes. e as curvas estão de acordo com o limites de distância e de velocidades propostos (V_{min} , V_{max} , L_{inf} e L_{sup}).

Na Figura 13c é mostrado como ficou o comportamento das velocidades na coleta para a Fase 2 de calibração. Foi observado que o sujeito conseguiu se manter acima dos 40% de velocidade em quase toda a coleta, havendo uma pequena queda somente no início da coleta. Já na Figura 13d o sujeito conseguiu chegar na velocidade máxima algumas vezes, porém ele conseguiu manter a velocidade do foguete acima dos 40% de velocidade em todo treinamento da atenção. Esse resultado é muito interessante, pois a ICC reconheceu somente o estado de atenção, mostrando que o sujeito estava realmente muito focado em todo treinamento.

Nas Figuras 13e, 13f e 13g são apresentados as médias das potências relativas θ/β da coleta para a Fase 1 e para a Fase 2, e do treinamento da atenção. Na Figura 13e é possível ver que o sujeito conseguiu recrutar muitas regiões do cérebro, sendo as mais ativadas foram Fp1, Fp2, F7, F8, T3, P3 e O1, esse resultado foi igual na Fase 2 de calibração (Figura 13f), tendo os mesmos eletrodos mais ativados. No estudo feito por Heinrich *et al.* (2014), foi analisado o comportamento da relação θ/β , α e θ em crianças com TDAH. No grupo TDAH-I (desatenção predominante), uma relação θ/β significativamente mais alta foi observada nos eletrodos únicos (F3, Fz) e uma tendência para uma relação θ/β mais alta quando considerados todos os eletrodos. Os resultados fornecem uma justificativa para a aplicação de protocolos *NFB* direcionados à atividade θ (e α) e à relação θ/β em subgrupos de crianças com TDAH.

Na Figura 13g são mostradas as médias das potências relativas θ/β para cada eletrodo no treinamento da atenção. É possível perceber a grande diferença nas ativações nos lobos frontal, temporal, parietal e occipital, e somente no lobo central não houve essa grande ativação. É interessante destacar que o sujeito conseguiu elevar seu nível de atenção muito bem em relação as outras Fases, isso aconteceu devido ao efeito da histerese, em que é necessário um maior nível de atenção do sujeito para manter em uma velocidade mais alta.

O sujeito S6G2 apresentou o pior desempenho em comparação com os outros sujeitos do G2. Ele apresentou uma redução no desempenho da Fase 1 para a Fase 2 de calibração (κ de 0,06 para -0,04 e acurácia de 52,76% para 48,23%) (Tabela 1).

As Figuras 14a e 14b apresentam as curvas dos modelos de velocidades para atenção e não atenção do S6G2. Na Figura 14a é possível observar que a curva da Fase 2 de calibração ficou mais ajustada em relação a curva da Fase 1. Já na Figura 14b há uma nítida diferença entre as duas curvas, mostrando que a curva da Fase 2 também ficou melhor ajustada em relação a Fase 1. A Figura 14c é apresentada o comportamento das velocidades na coleta para a Fase 2 de calibração. Observa-se que o sujeito conseguiu fazer com que o foguete ficasse em velocidades altas, e essas velocidades não foram reduzidas abaixo de 40%. Na Figura 14d é exposto o comportamento das velocidades no treinamento da atenção. É possível observar que o sujeito conseguiu manter o foguete com velocidades altas. Nas Figuras 14e, 14f e 14g são mostradas os mapas topográficos contendo as médias das potências relativas para cada eletrodo na coleta para as Fases 1 e 2 de calibração e no treinamento da atenção. Nas Figuras 14e e 14f a região frontal é a mais ativada, apresentando uma pequena diferença de ativação nas regiões central e parietal. Já na Figura 14g, houve uma diferença na ativação cerebral nas regiões parietal (P7, P8, P3, P4 e Pz), occipital (O1 e O2) e central (C4 e Cz) em comparação com as Figuras 14e e 14f.




Figura 14 – Sujeito S6G2 - Curvas de velocidade de atenção e não atenção (a,b). Comportamento das velocidades nas fases online (c,d). Potência relativa θ/β (e, f, g).

Considerando os resultados da Tabela 1, é possível observar que o efeito facilitador da histerese, presente somente no G2, mostrou que independente dos valores de acurácia e coeficiente κ , os sujeitos conseguiram fazer que o foguete atingisse velocidades altas, obtendo maiores pontuações com um baixo nível de atenção 15.

4.2 Treinamento da Atenção

Na Figura 15 são apresentadas as médias das velocidades por minuto para cada sujeito, com seu respectivo desvio padrão no treinamento da atenção. Para o G1 é possível analisar que a maioria dos sujeitos ficaram abaixo dos 60% de velocidade, exceto o sujeito S5G1 ficou nos dois primeiros minutos acima dos 60% o desvio padrão mostra o quão dispersos estão os valores de velocidades, ou seja, para a grande maioria do G1 a velocidade teve uma grande variação.

Para o G2, as médias das velocidades estão bem acima em comparação ao G1 e o G3, isso se deve ao efeito facilitador da histerese (ver Seção 3.2.1). Para esse grupo as médias estão mais dispersas, como exemplo, o sujeito S1G2 que as médias estão todas acima dos 90%, já o sujeito S3G2 somente a média do primeiro minuto está acima dos

80%, isso pode apresentar que o sujeito teve dificuldades em conseguir aumentar seu nível de atenção, mesmo que para esse grupo tenha um efeito que facilite o jogo. Analisando os outros sujeitos, o efeito da histerese funcionou bem, pois a maioria estão com médias de velocidades altas, e pontuações altas.

Para o G3, nenhuma das médias ultrapassou dos 60% de velocidade, sendo os sujeitos S1G3, S3G3, S6G3 não chegaram a ultrapassar os 40% de velocidade e a dispersão dos dados para esses sujeitos são os menores dentre os 3 grupos. Valores baixos das médias das velocidades mostram as dificuldades que os sujeitos tiveram em aumentar o nível de atenção, fazendo com que o foguete não tenha velocidades altas.

De forma geral, os sujeitos que tiveram velocidades altas por mais tempo conseguiram as maiores pontuações. O G2 foi o grupo que obteve as maiores pontuações ultrapassando os 100 pontos, isso se deve ao fato que eles possuem as maiores velocidades. Isso mostra que o efeito facilitador da histerese para o G2, independente do desempenho da ICC, os sujeitos conseguiram velocidades e pontuações altas (Tabela 1). Para o G3, somente os sujeitos S2G3 e S4G3 conseguiram chegar na velocidade máxima, ou seja, o efeito recompensa foi ativado para esses sujeitos, ajudando a ficarem por mais tempo em velocidades e pontuações altas.

Nas Figuras 16 (G1), 17 (G2) e 18 (G3) são apresentadas as médias das potências relativas θ/β dos treinamentos de atenção por minuto. Nos 3 grupos houveram ativações nas regiões frontal, temporal, parietal e occipital, e essas ativações apresentam o nível de atenção que o sujeito estava naquele momento. Houve também uma nítida diferença nas ativações para cada grupo. Na Figura 16 é possível observar que a maioria dos indivíduos, tiveram ativação nas regiões frontal e temporal nos mapas topográficos (quanto menor as porcentagens maior é a ativação). Alegria *et al.* (2017), Rubia *et al.* (2019) fizeram um estudo controlado randomizado com objetivo em testar a eficácia do NFB por fMRI em tempo real no córtex pré-frontal inferior direito, uma região comprometida no TDAH e melhorada por psicoestimulantes. O grupo que teve como alvo o córtex pré-frontal, mostrou um efeito que se correlacionou com o TDAH, havendo melhora na atenção concentrada e houve um aumento progressivo na ativação em duas regiões do córtex pré-frontal inferior direito, podendo estar associadas à melhora clínica dos sintomas do TDAH.

Em destaque são os sujeitos S2G1 e S4G1. O sujeito S2G1 manteve sua maior ativação cerebral em todas regiões frontal e temporal no treinamento da atenção. Essa ativação mostra que para o sujeito conseguir manter o foco por mais tempo, precisou recrutar as regiões frontal e temporal do cérebro, aumentando a velocidade do foguete. O sujeito S4G1 manteve mais ativa a região frontal e algumas vezes as regiões parietal, temporal e occipital. Comparando as ativações cerebrais dos sujeitos S2G1 e S4G1 com os resultados da Tabela 1 e da Figura 15 é possível ver que o desempenho da ICC para ambos sujeitos foram altos, as pontuações de ambos sujeitos foram as maiores na coleta para a




Figura 15 – Média e desvio padrão das velocidades no treinamento da atenção por minuto.

Fase 2 de calibração e no treinamento da atenção. É importante destacar o uso de todos os eletrodos do sistema de captura de EEG, pois foi respeitado as individualidades cerebrais de cada sujeito. O sujeito S3G1 teve variações interessantes ao longo do treinamento, começando por Fp1, Fp2, C4 e T4 e a partir do segundo minuto houve uma redução nas regiões central e temporal, ficando somente a região frontal ativa (Fp1 e Fp2). Já o sujeito S6G1 teve variações entre Fp1, T4, um pouco de ativação no quarto minuto em Pz. Para a maioria dos sujeitos a região central foi a que teve menor ativação. O sujeito S5G1 foi o que apresentou a menor ativação de todo o grupo, pois a partir do segundo minuto é possível ver a porcentagem de algumas regiões chegando a valores positivos. Isso pode estar relacionado ao baixo desempenho na calibração da ICC ($\kappa = 0,29$ para 0,17 e acurácia = 64,53% para 58,63%) apresentado na Tabela 1, e na Figura 15 apresenta uma redução da velocidade média a partir do segundo minuto, podendo ter relação com a redução da ativação cerebral, no mesmo minuto mostrado na Figura 16.




Figura 16 – Potência relativa θ/β por minuto - Grupo 1.

No G2 (Figura 17) é possível observar que para a maioria dos sujeitos, a região do cérebro mais ativada é a frontal. Os sujeitos S1G2, S5G2 e S6G2 tiveram mais ativações ao longo do treinamento da atenção. Para o sujeito S1G2 as melhores ativações tiveram variações entre Fp1, Fp2, T3 e T4, olhando a partir do primeiro minuto F4 teve uma redução em sua ativação, e no quinto minuto Fz e P3 tiveram também uma redução em

suas ativações. É interessante destacar o baixo nível de ativação para todos os sujeitos do G2 em comparação aos grupos G1 e G3, mostrando que alguns sujeitos tiveram a maioria da ativação cerebral com valores de porcentagens positivas. Isso mostra que o efeito facilitador da histerese funcionou, pois não foi necessário um alto nível de atenção para o foguete chegar em velocidades altas. O sujeito S3G2 foi o que teve menor ativação em todo escalpo cerebral, observando em conjunto com a Tabela 1 é possível ver que o desempenho da ICC foi reduzida da Fase 1 para a Fase 2 no coeficiente κ (0,64 para 0,44) e nas acurácias (82,23% para 70,61%), e na Figura 15 mostrou que a média das velocidades foram reduzindo a partir do segundo minuto, com uma melhora no quinto minuto. Já na Figura 18, mostra que para o sujeito S3G2 houve uma redução na ativação a partir do segundo minuto, obtendo uma melhora no quinto minuto. Na Tabela 1 é mostrado que os sujeitos do G2 tiveram um baixo desempenho comparando os 3 grupos, os valores do coeficiente κ foram baixos para todos os sujeitos, chegando a um valor negativo para o sujeito S6G2, mostrando que a eficiência de classificação também foi baixa. As acurácias tiveram poucas melhorias como exemplo o sujeito S1G1 que obteve uma melhora da Fase 1 para a Fase 2 de calibração menor que 1%, e na Figura 15 mostrou que todos os sujeitos do G2 mesmo com o desempenho da ICC baixa, as pontuações do treinamento da atenção e as velocidades médias foram as maiores dos três grupos, comprovando novamente o efeito facilitador da histerese.

No G3 (Figura 18) é possível observar que as ativações cerebrais para os sujeitos apresentaram variações interessantes em comparação aos grupos G1 e G2. O sujeito S3G3 teve uma melhora nas ativações nas regiões frontal, parietal e occipital. A partir do segundo minuto, manteve as velocidades médias mostradas na Figura 15 bem próximas (todas as médias próximas de 40%) com desvios padrões baixos, e o desempenho da ICC tiveram valores altos ($\kappa = 0,90$ para 0,84, acurácia = 94,92% para 92,07%). Mesmo obtendo altos valores no desempenho da ICC, as velocidades médias ficaram próximas de 40%, isso pode ser devido a ativação cerebral, onde mesmo tendo uma melhora a partir do segundo minuto, as regiões relacionadas a atenção (frontal e temporal) não foram muito ativadas, além disso o sujeito sentiu distraído, desmotivado e achou a dificuldade do jogo mediana no dia do treinamento (ver Tabela 3). Esses resultados citados acima, podem ser os motivos da baixa média das velocidades ocorridos no treinamento da atenção.

O sujeito S2G3 obteve a melhor ativação do grupo, mantendo sempre as regiões frontal, parietal, occipital e temporal ativadas em todo treinamento da atenção. O desempenho da ICC para o sujeito S2G3 obteve valores altos ($\kappa = 0,97$ para 0,93, acurácia = 98,30% para 96,61%), as médias das velocidades foram as maiores em todo grupo G3 com 78 pontos em todo treinamento da atenção (ver Tabela 15). O sujeito relatou que o jogo estava fácil, pelo fato que ele estava tranquilo, concentrado, e motivado a jogar.




Figura 17 – Potência relativa θ/β por minuto - Grupo 2.

O sujeito S1G3 obteve uma redução nas ativações cerebrais ao longo do tempo. Essa redução começou a partir do segundo minuto em C3, e expandiu para C3, T3, P3, P7, O1, Fz, F3 e F4. O desempenho da ICC para o sujeito apresentou valores baixos e houve uma melhora da Fase 1 para a Fase 2 de calibração ($\kappa = 0,05$ para 0,12, acurácia = 52,46% para 56,84%). As velocidades médias por minuto não tiveram valores maiores que 50% (ver Tabela 15), e tiveram uma pequena redução a partir do segundo minuto. Um dos motivos pela redução das atividades cerebrais é mostrado na Tabela 3, onde o sujeito relatou que o jogo estava difícil, porque ele estava distraído, e com uma motivação mediana. De forma geral, os sujeitos tiveram dificuldades em manter sua atenção no treinamento da atenção (com exceção do sujeito S2G3), pois alguns estavam com sua AC inferior, e a maioria estava distraído na hora do treinamento.

A Tabela 2 apresenta os resultados da BPA e AC (ver Seção 3.1.3.1). Para AC, o G1 foi o grupo que obteve mais indivíduos com níveis de atenção superior e somente um indivíduo com nível de atenção inferior. O G2 teve somente um indivíduo com a atenção nível superior e dois com níveis de atenção inferior e o G3 tiveram dois indivíduos com níveis de atenção superior e dois com níveis de atenção inferior. AC é importante nessa pesquisa, pois é a AC que foi usada em todo treinamento NFB. No teste BPA, três sujeitos




Figura 18 – Potência relativa θ/β por minuto - Grupo 3.

do G1 atingiram nível de atenção superior e um apresentou um nível de atenção inferior. Para o G2, somente um sujeito obteve um nível de atenção superior e um com nível de atenção inferior, o G3 obteve a mesma quantidade de sujeitos para o nível de atenção superior e inferior.

Observando os resultados do BPA e AC para os sujeitos analisados na Seção 4.1, o sujeito S2G1 obteve altos valores no desempenho da ICC, mas houve uma pequena redução da Fase 1 para a Fase 2 de calibração. No dia do treinamento o sujeito tirou uma boa pontuação no teste BPA obtendo um nível de atenção médio superior, e para AC obteve uma classificação inferior. AC é o tipo de atenção usada nesse treinamento devido ao foco que se deve manter no foguete. Essa pequena redução que houve na Fase 1 para a Fase 2 mostrado na Tabela 1, pode ser devido ao seu nível de AC naquele dia, com isso, não conseguindo ficar focado por muito tempo na coleta online para a Fase 2 e para o treinamento da atenção. Esse motivo deve ter interferido na ativação mostrado na Figura 10g, aonde houve pouca diferença de ativação em comparação com as Figuras 10e e 10f. Outro dado importante está mostrado na Tabela 3, que mostra perguntas e respostas que foram feitas ao término do treinamento da atenção. O sujeito respondeu que durante a sessão ele estava tranquilo, concentrado, estava motivado para jogar e achou fácil a

Tabela 2 – Pontuações do teste BPA e atenção concentrada.

Grupo 1	Idade	Escolaridade	Pontuação BPA	Classificação BPA	Pontuação AC	Classificação AC
S1G1	27	SC	352	Superior	120	Superior
S2G1	22	EMC	211	Médio Inferior	66	Inferior
S3G1	25	SC	223	Inferior	111	Médio Superior
S4G1	45	SC	307	Médio Superior	120	Superior
S5G1	31	SC	344	Superior	118	Superior
S6G1	27	SC	336	Superior	118	Superior

Grupo 2	Idade	Escolaridade	Pontuação BPA	Classificação BPA	Pontuação AC	Classificação AC
S1G2	23	SC	314	Médio Superior	80	Inferior
S2G2	23	EMC	231	Inferior	74	Inferior
S3G2	21	EMC	350	Superior	120	Superior
S4G2	24	SC	277	Médio Superior	99	Médio Superior
S5G2	26	SC	251	Médio Inferior	95	Médio
S6G2	25	SC	322	Médio Superior	104	Médio Superior

Grupo 3	Idade	Escolaridade	Pontuação BPA	Classificação BPA	Pontuação AC	Classificação AC
S1G3	26	SC	299	Médio Superior	95	Médio
S2G3	50	SC	321	Superior	116	Superior
S3G3	31	SC	294	Médio Superior	116	Superior
S4G3	43	SC	328	Superior	120	Superior
S5G3	20	EMC	281	Médio Inferior	85	Inferior
S6G3	24	EMC	129	Inferior	5	Inferior

Legendas: SC - Superior Completo
 EMC - Ensino Médio Completo
 AC - Atenção Concentrada

difficuldade do jogo.

O sujeito S6G1, no dia do treinamento da atenção, obteve uma classificação superior no teste BPA e uma classificação superior para AC. Esses resultados do teste BPA são coerentes com os resultados obtidos na ICC, pois o coeficiente κ teve um aumento de 0,71 para 0,91 e a acurácia teve um aumento de 85,85% para 95,23% e houve uma melhora na ativação mostrado na Figura 12g. O nível de AC obtido no teste pode ter sido de grande ajuda para o sujeito obter um alto desempenho nos resultados em seu treinamento da atenção comparado com o sujeito S2G1, onde seu teste AC foi inferior, e com isso houve uma redução no desempenho da ICC para ele. Isso pode ter ocorrido porque o sujeito S2G1 no dia do treinamento disse que estava tranquilo, distraído, muito motivado para jogar, mas achou o jogo difícil (Tabela 3).

O sujeito S2G3, no dia do treinamento da atenção, obteve uma alta pontuação no teste BPA obtendo uma classificação superior, e para o teste AC obteve também uma classificação superior. Esses resultados ficaram coerentes com os resultados dos coeficientes κ (0,97 para 0,93) e das acurácias (98,30% para 96,61%) mostradas na Tabela 1, com os ajustes das curvas de velocidades, e com as ativações mostradas na Figura 13. Na Tabela 3, o sujeito respondeu que ficou tranquilo no treinamento, ficou concentrado, ficou motivado a jogar e achou o jogo fácil.

Um caso especial é o sujeito S6G2, a ICC para ele teve um baixo desempenho com um coeficiente κ de 0,06 para -0,04 e acurácia de 52,76% para 48,23%. Esse sujeito obteve uma classificação médio superior tanto no teste de BPA quanto no teste de AC (Tabela 2) no dia do treinamento da atenção. O desempenho da ICC foi baixo, as curvas dos modelos de velocidades não tiveram bons ajustes, e não teve melhora na ativação cerebral. Isso mostra que o efeito facilitador ($S_{mode} = 1$), funcionou bem para esse sujeito, pois independente do desempenho da ICC, o sujeito pode conseguir velocidades e pontuação alta.

Tabela 3 – Perguntas e Respostas Comportamentais

Perguntas feitas aos sujeitos no término da sessão				
Grupo 1	Aagitado ou Tranquilo?	Concentrado ou Distráido?	Motivação para jogar (1 a 5)	Dificuldade do jogo (1 a 5)
S1G1	Tranquilo	Concentrado	4	4
S2G1	Tranquilo	Concentrado	5	2
S3G1	Tranquilo	Distráido	3	3
S4G1	Tranquilo	Concentrado	5	1
S5G1	Tranquilo	Concentrado	4	4
S6G1	Tranquilo	Distráido	5	4

Grupo 2	Aagitado ou Tranquilo?	Concentrado ou Distráido?	Motivação para jogar (1 a 5)	Dificuldade do jogo (1 a 5)
S1G2	Aagitado	Concentrado	4	2
S2G2	Tranquilo	Concentrado	3	2
S3G2	Tranquilo	Concentrado	4	3
S4G2	Tranquilo	Distráido	4	1
S5G2	Tranquilo	Distráido	5	4
S6G2	Tranquilo	Concentrado	4	1

Grupo 3	Aagitado ou Tranquilo?	Concentrado ou Distráido?	Motivação para jogar (1 a 5)	Dificuldade do jogo (1 a 5)
S1G3	Tranquilo	Distráido	3	4
S2G3	Tranquilo	Concentrado	4	2
S3G3	Tranquilo	Distráido	3	3
S4G3	Tranquilo	Concentrado	5	1
S5G3	Tranquilo	Distráido	4	3
S6G3	Tranquilo	Distráido	5	3

Escala motivação do jogo :				
1 - muito desmotivado ; 2 - desmotivado; 3 - médio; 4 - motivado ; 5 - muito motivado				
Escala dificuldade do jogo:				
1 - muito fácil; 2 - fácil; 3 - médio; 4 - difícil; 5 - muito difícil				

5 Conclusão

Esta dissertação de mestrado atingiu os objetivos propostos, pois obteve resultados que foram capazes de calibrar a ICC criada atingindo altos valores de desempenho (coeficiente κ e acurácia), e indicando sua efetividade para produzir modulação cortical nas regiões de interesse (frontal e temporal).

O modelo de velocidade proposto foi essencial para que os sujeitos sentissem a fluidez do jogo baseada em sua atenção. Diferente do proposto em outros trabalhos, o sujeito sentia que estava controlando o foguete e isso refletiu nos resultados. Além disso, esses modelos foram utilizados pela primeira vez em um trabalho da linha de pesquisa que esta inserido. Esse modelo pode ser utilizados dentro da linha de pesquisa com o mesmo propósito ou podem ser melhorados de acordo com a necessidade do pesquisa.

A partir da seleção de padrões baseado em probabilidade foi possível selecionar os padrões que mais se relacionam com a atenção. Com isso, o desempenho da ICC foi aumentado, gerando um modelo mais confiável de classificação e um modelo de velocidades mais ajustado de acordo com os limites propostos (V_{min} , V_{max} , L_{inf} e L_{sup}).

A geometria *Riemannian* baseado em análise de matrizes de covariância consegue obter padrões mais relevantes de atenção e não atenção, ou seja, por ser um método não supervisionado (dados não rotulados), consegue achar uma representação mais representativa dos dados coletados. Como visto no desempenho da ICC, os coeficientes κ e as acurácias apresentaram valores altos, houve melhora dos mesmos da fase 1 para a fase 2 de calibração, mostrando que a geometria de *Riemannian* consegue obter os padrões que melhor representam os estados de atenção e não atenção.

A divisão em grupos, onde cada um possuía um comportamento diferente das velocidades foi importante, pois mostrou que cada grupo respondeu ao que foi proposto de forma distinta, no caso dos grupos que não possuía nenhum tipo de ajuda (G1 e G3) mostrou os métodos propostos foram satisfatórios, pois os mesmos obtiveram bons resultados. Além disso, havia um sujeito com TDAH que apresentou alto desempenho, o que pode ser uma forma de fomentar seu uso em sujeitos que apresentam essa síndrome. Quando se considera a divisão de grupos e os resultados observados, conclui-se que cada grupo atingiu o desempenho esperado.

A aplicação dos métodos propostos resultou em um sistema capaz de melhor identificar os estados mentais de atenção e não atenção, podendo comparar os resultados obtidos com os artigos referenciados. Assim, esta pesquisa de mestrado aqui apresentado está avançando bem para que no futuro possa ser utilizado como tratamento complementar no TDAH.

5.1 Contribuições

As contribuições do trabalho desta dissertação de mestrado é o desenvolvimento de uma ICC baseado em jogo sério para a reabilitação neurológica de crianças com TDAH. As contribuições técnicas e científicas mais importantes desta pesquisa estão listadas abaixo.

1. Desenvolvimento de uma ICC para ser utilizada pelo grupo de pesquisa *BRAEN* para futuros testes e publicações.
2. Desenvolvimento de um método para envio de velocidades baseado no nível de atenção, para obter mais fluidez no controle do foguete.
3. Desenvolvimento de um método de seleção de padrões baseado em probabilidade, para aumentar a eficiência da ICC.
4. A geometria de *Riemannian* foi utilizada pela primeira vez neste trabalho do grupo de pesquisa *BRAEN*.

5.2 Publicações

A pesquisa desenvolvida nesta dissertação de mestrado permitiu a publicação do seguinte trabalho:

1. OLIVEIRA JUNIOR, H. L. ; CASAGRANDE, W. D. ; MACHADO, F. S. V. ; DELISLE-RODRIGUEZ, D. ; SOUZA, M. ; BASTOS FILHO, Teodiano ; FRIZERA NETO, A. . Towards an EEG Based BCI for Neurofeedback Assisted Rehabilitation of Attention Deficit Hyperactivity Disorder. In: IBERDISCAP, 2020, Buenos Aires. 2019 Iberdiscap. X Congreso Iberoamericano de Tecnologías de Apoyo a la Discapacidad: memorias, 2019. p. 219-222.

5.3 Trabalhos Futuros

Trabalhos futuros devem ser realizados para que o algoritmo e o protocolo sejam melhorados. Além disso, acertos no ambiente virtual para melhor imersão e engajamento nas sessões de treinamento NFB também deve ser feitos. Essas melhorias são necessárias para que os sujeitos sintam mais a vontade com o ambiente, com maior redução de barulhos externos.

Pretende-se também deixar o algoritmo mais automático, fazendo com que a ICC faça calibrações automáticas de acordo com os dados obtidos nos treinamentos, obtendo modelos de classificação, de velocidades e matrizes de projeção mais confiáveis, melhorando o engajamento no jogo online e o reconhecimento dos estados de atenção e não atenção.

Verificar se há necessidade de ter um melhor isolamento na sala contra ruídos, pois houve reclamações sobre barulhos, mesmo a sala estando fechada com uma placa do lado de fora pedindo silêncio.

Por fim, depois de fazer mais coletas testar a eficácia do novo sistema NFB, pretende-se validar o sistema com sujeitos com TDAH, com objetivo de ser utilizado para tratamento complementar para o transtorno.

Referências

- AKIMA, H. A new method of interpolation and smooth curve fitting based on local procedures. *Journal of the ACM (JACM)*, ACM New York, NY, USA, v. 17, n. 4, p. 589–602, 1970. Citado na página 46.
- ALEGRIA, A. A. *et al.* Real-time fMRI 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 68.
- 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 34 e 39.
- BARACHANT, A. *et al.* Multiclass brain–computer interface classification by riemannian geometry. *IEEE Transactions on Biomedical Engineering*, IEEE, v. 59, n. 4, p. 920–928, 2011. Citado na página 36.
- BARACHANT, A. *et al.* Classification of covariance matrices using a riemannian-based kernel for bci applications. *Neurocomputing*, Elsevier, v. 112, p. 172–178, 2013. Citado na página 57.
- BEUKELMAN, D. R.; MIRENDA, P. *et al.* *Augmentative and alternative communication*. [S.l.]: Paul H. Brookes Baltimore, 1998. Citado na página 33.
- BIELAS, J.; MICHALCZYK, Ł. Beta neurofeedback training improves attentional control in the elderly. *Psychological Reports*, SAGE Publications Sage CA: Los Angeles, CA, p. 0033294119900348, 2020. Citado na página 26.
- BLUSCHKE, A. *et al.* The neuronal mechanisms underlying improvement of impulsivity in adhd by theta/beta neurofeedback. *Scientific reports*, Nature Publishing Group, v. 6, n. 1, p. 1–9, 2016. Citado na página 25.
- BLUSCHKE, A.; ROESSNER, V.; BESTE, C. Editorial perspective: How to optimise frequency band neurofeedback for adhd. *Journal of Child Psychology and Psychiatry*, Wiley Online Library, v. 57, n. 4, p. 457–461, 2016. Citado na página 32.
- BUCH, P. *Svm max sep hyperplane with margin*. 2008. Disponível em: <https://commons.wikimedia.org/wiki/File:Svm_max_sep_hyperplane_with_margin.png>. Citado 2 vezes nas páginas 13 e 39.
- CARMARGOS, W.; HOUNIE, A. Manual clínico do transtorno de déficit de atenção/hiperatividade. *Editora Info Ltda. Belo Horizonte*, 2005. Citado na página 21.
- CARVALHO, A. *et al.* Inteligência artificial—uma abordagem de aprendizado de máquina. *Rio de Janeiro: LTC*, 2011. Citado na página 45.
- CARVALHO, H. W. d. *et al.* Structural validity and reliability of the positive and negative affect schedule (panas): evidence from a large brazilian community sample. *Brazilian Journal of Psychiatry*, SciELO Brasil, v. 35, n. 2, p. 169–172, 2013. Citado na página 44.

CASAGRANDE, W. D. *et al.* Identificação de Estado Mental de Atenção Através do EEG para Aplicação em Treinamento Neurofeedback. Dissertação (Mestrado) — Universidade Federal do Espírito Santo, 2019. Citado na página 39.

CHAN, A. S.; SZE, S. L.; CHEUNG, M.-c. Quantitative electroencephalographic profiles for children with autistic spectrum disorder. *Neuropsychology*, American Psychological Association, v. 21, n. 1, p. 74, 2007. Citado na página 32.

CORNEW, L. *et al.* Resting-state oscillatory activity in autism spectrum disorders. *Journal of autism and developmental disorders*, Springer, v. 42, n. 9, p. 1884–1894, 2012. Citado na página 32.

CORREIA, L. C. *et al.* Codificação eficiente para caracterização de eletroencefalograma de pacientes epiléticos. Universidade Federal do Maranhão, 2018. Citado na página 29.

COSTA, Á. *et al.* Decoding the attentional demands of gait through eeg gamma band features. *PLoS one*, Public Library of Science, v. 11, n. 4, p. e0154136, 2016. Citado na página 30.

DAVELAAR, E. J. Mechanisms of neurofeedback: a computation-theoretic approach. *Neuroscience*, Elsevier, v. 378, p. 175–188, 2018. Citado na página 32.

DELISLE-RODRIGUEZ, D. *et al.* System based on subject-specific bands to recognize pedaling motor imagery: towards a bci for lower-limb rehabilitation. *Journal of neural engineering*, IOP Publishing, v. 16, n. 5, p. 056005, 2019. Citado 2 vezes nas páginas 36 e 57.

DELISLE-RODRIGUEZ, D. *et al.* Adaptive spatial filter based on similarity indices to preserve the neural information on eeg signals during on-line processing. *Sensors*, Multidisciplinary Digital Publishing Institute, v. 17, n. 12, p. 2725, 2017. Citado na página 34.

DIAS, Á. M. Tendências do neurofeedback em psicologia: revisão sistemática. *Psicologia em estudo*, SciELO Brasil, v. 15, n. 4, p. 811–20, 2010. Citado na página 32.

DÍAZ-BAQUERO, A. A.; CAMELO-ROA, S. M. Actividad eléctrica cerebral de la atención en adolescentes policonsumidores por medio de un equipo de bci (brain control interface). *Acta Colombiana de Psicología*, v. 22, n. 1, p. 175–188, 2019. Citado na página 23.

FERNANDES, C. T.; MARCONDES, J. F. Tdah: Transtorno, causa, efeito e circunstância. *Revista de Ensino, Educação e Ciências Humanas*, v. 18, n. 1, p. 48–52, 2017. Citado na página 21.

FOLDES, S. T. *et al.* Effects of meg-based neurofeedback for hand rehabilitation after tetraplegia: preliminary findings in cortical modulations and grip strength. *Journal of Neural Engineering*, IOP Publishing, 2020. Citado na página 32.

FONSECA, R. J. R. M. d.; SILVA, P. J. d. S. P. d.; SILVA, R. R. d. Acordo inter-juízes: O caso do coeficiente kappa. *Laboratório de Psicologia*, Instituto Superior de Psicologia Aplicada, p. 81–90, 2007. Citado na página 54.

- GARCÍA-BERJILLOS, E. *et al.* Eficacia del neurofeedback para el tratamiento de los trastornos del espectro autista: Una revisión sistemática. *Revista de Psicopatología y Psicología Clínica*, v. 20, n. 2, p. 151–163, 2015. Citado na página 32.
- GAUR, P. *et al.* A multi-class eeg-based bci classification using multivariate empirical mode decomposition based filtering and riemannian geometry. *Expert Systems with Applications*, Elsevier, v. 95, p. 201–211, 2018. Citado 2 vezes nas páginas 57 e 58.
- GELADÉ, K. Neurofeedback in children with adhd. 2019. Citado na página 26.
- GONZÁLEZ-CASTRO, P. *et al.* Efficacy of neurofeedback versus pharmacological support in subjects with adhd. *Applied psychophysiology and biofeedback*, Springer, v. 41, n. 1, p. 17–25, 2016. Citado 2 vezes nas páginas 22 e 23.
- GURGEL, V. Aplicação de técnicas wavelets em análise de séries temporais para detecção de correlações. 2013. 62f. *Monografia (Graduação em Ciência e Tecnologia)–Universidade Federal Rural do Semiárido-UFERSA. Angicos*, 2013. Citado na página 35.
- HAMMOND, D. C. Neurofeedback treatment of depression and anxiety. *Journal of Adult Development*, Springer, v. 12, n. 2-3, p. 131–137, 2005. Citado na página 32.
- HAMMOND, D. C. What is neurofeedback? *Journal of neurotherapy*, Taylor & Francis, v. 10, n. 4, p. 25–36, 2007. Citado 2 vezes nas páginas 32 e 33.
- 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 39.
- HEINRICH, H. *et al.* EEG spectral analysis of attention in ADHD: implications for neurofeedback training? *Frontiers in human neuroscience*, Frontiers, v. 8, p. 611, 2014. Citado na página 66.
- HERNÁNDEZ, E. D. *Neurofeedback como tratamiento para el trastorno por deficit de atención (TDA)*. Tese (Doutorado) — Universidad Complutense de Madrid, 2015. Citado na página 22.
- HOLTMANN, M. *et al.* Neurofeedback for adhd: a review of current evidence. *Child and Adolescent Psychiatric Clinics*, Elsevier, v. 23, n. 4, p. 789–806, 2014. Citado na página 22.
- ILLE, N.; BERG, P.; SCHERG, M. Artifact correction of the ongoing eeg using spatial filters based on artifact and brain signal topographies. *Journal of clinical neurophysiology*, LWW, v. 19, n. 2, p. 113–124, 2002. Citado na página 30.
- JANSSEN, T. W. *et al.* Learning curves of theta/beta neurofeedback in children with adhd. *European child & adolescent psychiatry*, Springer, v. 26, n. 5, p. 573–582, 2017. Citado na página 24.
- JAPKOWICZ, N.; SHAH, M. *Evaluating learning algorithms: a classification perspective*. [S.l.]: Cambridge University Press, 2011. Citado na página 55.
- JARDIM, D. d. S. *Remoção de artefatos em EEG para Neurofeedback*. Dissertação (Mestrado) — Universidade Federal de Pernambuco, 2017. Citado na página 32.

- JIANG, L. *et al.* Brain computer interface based 3d game for attention training and rehabilitation. In: IEEE. *2011 6th IEEE conference on industrial electronics and applications*. [S.l.], 2011. p. 124–127. Citado na página 23.
- KHALID, S.; KHALIL, T.; NASREEN, S. A survey of feature selection and feature extraction techniques in machine learning. In: IEEE. *2014 Science and Information Conference*. [S.l.], 2014. p. 372–378. Citado na página 35.
- KIMMIG, A.-C. S. *et al.* Feasibility of nirs-based neurofeedback training in social anxiety disorder: behavioral and neural correlates. *Journal of Neural Transmission*, Springer, v. 126, n. 9, p. 1175–1185, 2019. Citado na página 32.
- LEINS, U. *et al.* Neurofeedback for children with adhd: a comparison of scp and theta/beta protocols. *Applied psychophysiology and biofeedback*, Springer, v. 32, n. 2, p. 73–88, 2007. Citado na página 22.
- LEUTHARDT, E. C. *et al.* A brain–computer interface using electrocorticographic signals in humans. *Journal of neural engineering*, IOP Publishing, v. 1, n. 2, p. 63, 2004. Citado na página 33.
- LIMA, I. N. O. *et al.* Desenvolvimento de uma plataforma para o processamento estatístico de sinal eletroencefalográfico (eeg). Universidade Federal de Uberlândia, 2018. Citado 2 vezes nas páginas 29 e 30.
- LIU, B.; HAO, Z.-F.; YANG, X.-W. Nesting support vector machine for multi-classification [machine read machine]. In: IEEE. *2005 International Conference on Machine Learning and Cybernetics*. [S.l.], 2005. v. 7, p. 4220–4225. Citado na página 39.
- LIU, Y. *et al.* Individual theta/beta based algorithm for neurofeedback games to improve cognitive abilities. In: *Transactions on Computational Science XXVI*. [S.l.]: Springer, 2016. p. 57–73. Citado na página 55.
- LOTTE, F. *et al.* A review of classification algorithms for eeg-based brain–computer interfaces: a 10 year update. *Journal of neural engineering*, IOP Publishing, v. 15, n. 3, p. 031005, 2018. Citado na página 37.
- LOTTE, F. *et al.* A review of classification algorithms for eeg-based brain–computer interfaces. *Journal of neural engineering*, IOP Publishing, v. 4, n. 2, p. R1, 2007. Citado 2 vezes nas páginas 37 e 38.
- LUSHCHEKINA, E. *et al.* A comparative eeg study in normal and autistic children. *Neuroscience and Behavioral Physiology*, Springer, v. 42, n. 3, p. 236–243, 2012. Citado na página 32.
- MACHADO, F. S. *et al.* Development of serious games for neurorehabilitation of children with attention-deficit/hyperactivity disorder through neurofeedback. In: IEEE. *2019 18th Brazilian Symposium on Computer Games and Digital Entertainment (SBGames)*. [S.l.], 2019. p. 91–97. Citado 3 vezes nas páginas 42, 43 e 54.
- MASCARO, L. *Para que Medicação?: O Treinamento Neurológico por Neurofeedback Voltado ao Tratamento Não Medicamentoso de Depressão, Ansiedade e Pânico, Déficit de Atenção, Dislexia, Au.* [S.l.]: Elsevier Brasil, 2017. Citado na página 32.

- MATOS, H. P. de *et al.* O uso da ritalina em crianças com tdah: uma revisão teórica. *REVISTA HUM@ NAE*, v. 12, n. 2, 2018. Citado na página 21.
- MCFARLAND, D. J. *et al.* Bci meeting 2005-workshop on bci signal processing: feature extraction and translation. *IEEE transactions on neural systems and rehabilitation engineering*, IEEE, v. 14, n. 2, p. 135–138, 2006. Citado na página 35.
- MCFARLAND, D. J. *et al.* Spatial filter selection for eeg-based communication. *Electroencephalography and clinical Neurophysiology*, Elsevier, v. 103, n. 3, p. 386–394, 1997. Citado na página 34.
- MOHAMMADPOUR, M.; MOZAFFARI, S. Classification of eeg-based attention for brain computer interface. In: IEEE. *2017 3rd Iranian Conference on Intelligent Systems and Signal Processing (ICSPIS)*. [S.l.], 2017. p. 34–37. Citado na página 25.
- OMS. *TDAH*. 2019. Disponível em: <<https://www.folhavoria.com.br/saude/noticia/08/2019/oms-transtorno-de-hiperatividade-atinge-2-milhoes-de-brasileiros>>. Citado na página 21.
- PALUDO, M. R. O uso do neurofeedback como uma ferramenta de reabilitação no déficit de atenção e/ou hiperatividade (tdah) de crianças. 2017. Citado 2 vezes nas páginas 21 e 23.
- PERROCA, M. G.; GAIDZINSKI, R. R. Avaliando a confiabilidade interavaliadores de um instrumento para classificação de pacientes: coeficiente kappa. *Revista da Escola de Enfermagem da USP*, SciELO Brasil, v. 37, n. 1, p. 72–80, 2003. Citado 2 vezes nas páginas 54 e 55.
- PETRIDIS, S. *et al.* Static vs. dynamic modeling of human nonverbal behavior from multiple cues and modalities. In: *Proceedings of the 2009 international conference on Multimodal interfaces*. [S.l.: s.n.], 2009. p. 23–30. Citado na página 38.
- PFURTSCHELLER, G.; NEUPER, C.; BERGER, J. Source localization using eventrelated desynchronization (erd) within the alpha band. *Brain Topography*, Springer, v. 6, n. 4, p. 269–275, 1994. Citado na página 34.
- PLISZKA, S. R. Pharmacologic treatment of attention-deficit/hyperactivity disorder: efficacy, safety and mechanisms of action. *Neuropsychology review*, Springer, v. 17, n. 1, p. 61–72, 2007. Citado na página 24.
- QIAN, X. *et al.* Brain-computer-interface-based intervention re-normalizes brain functional network topology in children with attention deficit/hyperactivity disorder. *Translational psychiatry*, Nature Publishing Group, v. 8, n. 1, p. 1–11, 2018. Citado na página 25.
- REALITY AI. *It's all about the features*. 2017. Disponível em: <<https://reality.ai/it-is-all-about-the-features/>>. Citado na página 35.
- ROMERO-LAISECA, M. A. *et al.* A low-cost lower-limb brain-machine interface triggered by pedaling motor imagery for post-stroke patients rehabilitation. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 28, n. 4, p. 988–996, 2020. Citado 2 vezes nas páginas 35 e 57.

RUBIA, K. Cognitive neuroscience of attention deficit hyperactivity disorder (adhd) and its clinical translation. *Frontiers in human neuroscience*, Frontiers, v. 12, p. 100, 2018. Citado na página 32.

RUBIA, K. *et al.* Functional connectivity changes associated with fMRI neurofeedback of right inferior frontal cortex in adolescents with ADHD. *NeuroImage*, Elsevier, v. 188, p. 43–58, 2019. Citado na página 68.

RUEDA, F. J. M.; MONTEIRO, R. de M. Bateria psicológica para avaliação da atenção (bpa): desempenho de diferentes faixas etárias. *Psico-USF*, Universidade São Francisco, v. 18, n. 1, p. 99–108, 2013. Citado na página 43.

SÁ, Â. A. R. de; SOARES, A. B. Sistema de neurofeedback para tratamento de estresse. 2003. Citado na página 32.

SCHALK, G. *et al.* Bci2000: a general-purpose brain-computer interface (bci) system. *IEEE Transactions on biomedical engineering*, IEEE, v. 51, n. 6, p. 1034–1043, 2004. Citado 2 vezes nas páginas 33 e 34.

SÖRNMO, L.; LAGUNA, P. *Bioelectrical signal processing in cardiac and neurological applications*. [S.l.]: Academic Press, 2005. v. 8. Citado na página 30.

VILELA, P. Classificação de sentimento para notícias sobre a petrobras no mercado financeiro. *Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro*, p. 52, 2011. Citado na página 38.

WANG, J.; WANG, W.; HOU, Z.-G. Towards improving engagement in neural rehabilitation: Attention enhancement based on brain-computer interface and audiovisual feedback. *IEEE Transactions on Cognitive and Developmental Systems*, IEEE, 2019. Citado na página 29.

WATANABE, T. *et al.* Advances in fmri real-time neurofeedback. *Trends in cognitive sciences*, Elsevier, v. 21, n. 12, p. 997–1010, 2017. Citado na página 32.

WOLPAW, J. R. *et al.* Brain-computer interface technology: a review of the first international meeting. *IEEE transactions on rehabilitation engineering*, Citeseer, v. 8, n. 2, p. 164–173, 2000. Citado na página 33.

YANG, L. *et al.* Beta/theta ratio neurofeedback training effects on the spectral topography of eeg. In: IEEE. *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. [S.l.], 2015. p. 4741–4744. Citado 2 vezes nas páginas 55 e 61.

YGER, F.; BERAR, M.; LOTTE, F. Riemannian approaches in brain-computer interfaces: a review. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 25, n. 10, p. 1753–1762, 2016. Citado na página 35.

ZANON, C. *et al.* Desenvolvimento e validação de uma escala de afetos positivos e negativos. *Psico-USF*, SciELO Brasil, v. 18, n. 2, p. 193–201, 2013. Citado na página 44.