

DM 18/2022

Universidade Federal do Pará
Faculdade de Engenharia Elétrica
Programa de Pós Graduação

**Análises de Atividades Oscilatórias de EEG Durante Treinamento Cognitivo
e Análise Espectral de Holo-Hilbert**

Suzana Cescon de Souza

DM 18/2022

Brasil

2022

Universidade Federal do Pará
Faculdade de Engenharia Elétrica
Programa de Pós Graduação

Suzana Cescon de Souza

**Análises de Atividades Oscilatórias de EEG Durante Treinamento
Cognitivo Utilizando a Análise Espectral de Holo-Hilbert**

Dissertação submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica da UFPA para a obtenção do Grau de Mestre em Engenharia Elétrica na área de Telecomunicações

Orientador: Antônio Pereira Junior

Coorientador: Bruno Duarte Gomes

Brasil

2022

Suzana Cescon de Souza

Análises de Atividades Oscilatórias de EEG Durante Treinamento Cognitivo Utilizando a Análise Espectral de Holo-Hilbert/ Suzana Cescon de Souza. -- Brasil, 2022-

69 p. : il. (algumas color.) ; 30 cm.

Orientador: Antônio Pereira Junior

Dissertação (Mestrado) -- Universidade Federal do Pará
Faculdade de Engenharia Elétrica
Programa de Pós Graduação, 2022.

1. Análise Espectral de Holo-Hilbert. 2. EEG. 3. Neurofeedback.
4. Treinamento Cognitivo.
I. Antônio Pereira Junior. II. Universidade Federal do Pará. III.
Faculdade de Engenharia Elétrica. IV. Análises de Atividades
Oscilatórias de EEG Durante Treinamento Cognitivo Utilizando a
Análise Espectral de Holo-Hilbert.

**“ANÁLISES DE ATIVIDADES OSCILATÓRIAS DE EEG DURANTE TREINAMENTO
COGNITIVO E ANÁLISE ESPECTRAL DE HOLO-HILBERT”**

AUTORA: SUZANA CESCUN DE SOUZA

DISSERTAÇÃO DE MESTRADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO
COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO
JULGADA ADEQUADA PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA
ELÉTRICA NA ÁREA DE TELECOMUNICAÇÕES.

APROVADA EM: 19/07/2022

BANCA EXAMINADORA:

Prof. Dr. Antônio Pereira Junior
(Orientador – PPGEE/UFPA)

Prof. Dr. Bruno Duarte Gomes
(Coorientador – ICB/UFPA)

Prof.^a Dr.^a Adriana Rosa Garcez Castro
(Avaliadora Interna - PPGEE/UFPA)

Prof.^a Dr.^a Valquíria Gusmão Macedo
(Avaliadora Externa ao Programa - ITEC/UFPA)

VISTO:

Prof. Dr. Carlos Tavares da Costa Júnior
(Coordenador do PPGEE/ITEC/UFPA)

A todos que me ajudaram.

Agradecimentos

Agradeço primeiramente à **Deus** pela a continuação da minha jornada.

Agradeço aos meus pais **Elizabeth Cescon e João Batista**, pelo carinho e suporte que sempre proporcionaram e principalmente pelos ensinamentos e incentivos durante todos estes anos. Agradeço também aos meus familiares que sempre estiveram presentes direta ou indiretamente em todos os momentos da minha formação.

A todos meus amigos e amigas, colegas de trabalho, amigos do **Laboratório de Neuroprocessamento (LABNEP)** e do **Laboratório de Computação Aplicada**, que sempre me ajudaram com dúvidas, orientações e apoio para o desenvolvimento deste trabalho.

Ao **Professor Drº Antônio Pereira Junior**, pela orientação assídua na pesquisa e escrita deste trabalho. Ao **Professor Drº Bruno Duarte Gomes** por me incentivar a seguir passos firmes e confiar no meu trabalho. Ao **Drº Sérgio Ivan Viademonte** pela oportunidade de enriquecimento intelectual e profissional na empresa Vale SA. A **Professora Drª Valquíria Gusmão Macedo** que sempre me acolheu e ajudou tanto desde a graduação.

Agradeço à **Universidade Federal do Pará (UFPA)**, lugar que tanto amo e tenho orgulho de fazer parte, que me proporcionou ótimas experiências e me levou a lugares incríveis. Viva à universidade pública e à ciência brasileira!

Por fim, agradeço ao **Instituto Tecnológico Vale (ITV)**, por me ajudar financeiramente durante meu mestrado e ao Programa de Pós-Graduação em Engenharia Elétrica (PPGEE/UFPA).

*“A educação sozinha não pode mudar o mundo.
Porém ela é a melhor arma para continuarmos
lutando pela igualdade social”
(Paulo Freire, 1997).*

Resumo

Neste trabalho desenvolvemos um protocolo de análise de um treinamento cognitivo (TC) para melhoria de performance de desempenho em operadores de escavadeira da empresa Vale S.A. Esta pesquisa fez parte do Projeto de Inovação *POAD* (Programa de Operadores de Alto Desempenho) do Instituto Tecnológico Vale (ITV). O protocolo de TC foi baseado em *Neurofeedback* (NFB), com a finalidade de desenvolver habilidades de auto regulação das frequências cerebrais de indivíduos, com base nas análises de eletroencefalograma (EEG). Nesta pesquisa, utilizamos a Análise Espectral de Holo-Hilbert (HHSa) para estudar a modulação em amplitude (AM) e frequência (FM) dos ritmos que compõem as frequências cerebrais. A HHSa foi baseada na decomposição em modo empírico (EMD) de duas camadas. Primeiro houve uma decomposição do sinal EEG em uma série de funções de modo intrínseco em frequência modulada (IMFs) e então se decompôs cada IMF modulado em frequência em um conjunto de IMFs modulados em amplitude. Dessa forma, este trabalho investiga a eficácia de um TC com base nas variações de frequência e amplitude moduladas nos dados de EEG obtidos por NFB. Os resultados demonstram eficácia para o TC e validam a eficácia da HHSa em extrair características informativas dos sinais.

Palavras-chave: Análise Espectral Holo-Hilbert. EEG. *Neurofeedback*. Treinamento Cognitivo.

Abstract

In this work we developed a protocol for the analysis of a cognitive training (TC), in order to raise the performance in bulldozer operators of Vale S.A. This research took part of the POAD (High performance operators' program) Innovation Project of the Vale Technological Institute (ITV). The protocols of the TC were based in Neurofeedback (NFB), in order to develop the ability to self-regulate cerebral frequencies, based on electroencephalogram (EEG) analysis. In this research, the Holo-Hilbert Spectral Analysis (HHSa) for the study of amplitude modulation (AM) band frequency (FM) of the rhythms that compose the cerebral frequencies. The HHSa was based on empirical mode decomposition (EMD) in two layers. First the EEG signal has been decomposed in a series of intrinsic mode function in modulated frequency (IMFs) and then every IMF modulated in frequency have been decomposed in a set of IMFs modulated in amplitude. thus, the present work explores the efficiency of an TC based on modulated frequency and amplitude variations in EEG data obtained via NFB. The results show statistical relevance for the group who went through the TC showing the effects of the application of TC. Moreover, validate the efficacy of HHSa in the extraction of informative characteristics from the signals.

Keywords: Holo-Hilbert Spectral Analysis. EEG. Neurofeedback. Cognitive Training.

Lista de ilustrações

Figura 1 – Exemplo de frequências típicas do EEG.	23
Figura 2 – Sistema internacional 10-20 BrainMaster 24D	29
Figura 3 – Simulador de escavadeira.	29
Figura 4 – Setup experimental.	30
Figura 5 – Primeira EMD	31
Figura 6 – Envelopamento do Sinal	32
Figura 7 – Segunda EMD	32
Figura 8 – Exemplo do Mapa Espectral gerado pela HHSA	33
Figura 9 – Algoritmo de Processamento da HHSA	34
Figura 10 – Validação do método	35
Figura 11 – Leitura do mapa espectral.	36
Figura 12 – Componentes de um <i>box plot</i>	37
Figura 13 – Mapas espectrais sujeito treinado antes e após o treinamento	38
Figura 14 – Mapas espectrais destacados para o sujeito treinado antes e após o treinamento	39
Figura 15 – Mapas espectrais sujeito 1 GC antes e após o treinamento	39
Figura 16 – Mapas espectrais da média dos sinais para GT	40
Figura 17 – Mapas espectrais da média dos sinais para GC	40
Figura 18 – Comparação entre os valores de P_{Total} obtidos em $Tetha$ para Grupo Controle e Treinado. Resultados para $***p \leq 0,05$	44
Figura 19 – Comparação entre os valores de P_{Total} obtidos em SMR para Grupo Controle e Treinado. Considerando que $**p \leq 0,001$	45
Figura 20 – Comparação entre os valores de P_{Total} obtidos em $HiBeta$ para Grupo Controle e Treinado. Resultados para $***p \leq 0,05$	46

Lista de tabelas

Tabela 1 – Faixas de frequência do EEG e suas características	22
Tabela 2 – Valores de ω e Ω para Theta no grupo controle	41
Tabela 3 – Valores de ω e Ω para Theta no grupo treinado	41
Tabela 4 – Valores de ω e Ω para SMR no grupo controle	42
Tabela 5 – Valores de ω e Ω para SMR no grupo treinado	42
Tabela 6 – Valores de ω e Ω para HiBeta no grupo controle	43
Tabela 7 – Valores de ω e Ω para HiBeta no grupo treinado	43

Lista de abreviaturas e siglas

AAR	<i>Adaptive Auto-Regressive</i>
AM	Amplitude Modulada
EEG	Eletroencefalograma
ECG	Eletrocardiograma
NFB	<i>Neurofeedback</i>
EMD	<i>Empirical Mode Decomposition</i>
ERD	<i>Event-Related Desynchronization</i>
ERS	<i>Event-Related Synchronization</i>
GC	Grupo Controle
GT	Grupo Treinado
HHS	<i>Holo-Hilbert Spectrum</i>
HHSA	<i>Holo-Hilbert Spectrum Analysis</i>
HHT	<i>Holo-Hilbert Transform</i>
ICA	<i>Independent Component Analysis</i>
ITV	Instituto Tecnológico Vale
IMF	<i>Intrinsic Mode Function</i>
MATLAB	<i>MATrix LABoratory</i>
PDF	Função Densidade de Probabilidade
POAD	Projeto de Operadores de Alto Desempenho
SMR	<i>Sensorio-Motor Rhythm</i>
STFT	<i>Short-Time Fourier Transform</i>
TSE	<i>Temporal Spectral Evolution</i>
TC	Treinamento Cognitivo
VFC	Variabilidade de Frequência Cardíaca

Lista de símbolos

γ	Letra grega <i>gama</i>
Ω	Letra grega <i>ômega</i>
β	Letra grega <i>beta</i>
Hz	Hertz
α	Letra grega <i>alpha</i>
δ	Letra grega <i>delta</i>
θ	Letra grega <i>theta</i>
μ	Letra grega <i>Miu</i>
p	Significância do método estatístico
Σ_a^b	Função somatório
$ $	Operação do Módulo
Re	Parte real
N	Númeração das camadas na primeira decomposição
L	Camada de decomposição
I_L	IMFs da camada decomposta
ω	Letra grega <i>ômega</i>
a_L	Amplitude instantânea
\cos	Função cosseno
θ_j	Ângulo a ser determindo na função
e	Função exponencial natural
\int	Sinal de integral
ω_L	Frequência instantânea
τ	Reposta ao degrau
$d\tau$	Derivado em relação a <i>tau</i>

$\hat{a}_L(t)$	Representação da Função de envelopamento
K	Númeração das camadas na segunda decomposição
P	Potência calculada
μ	Microvolts
t	Tempo
sec	Segundos

Sumário

1	CONSIDERAÇÕES INICIAIS	16
1.1	Introdução	16
1.2	Justificativa	17
1.3	Objetivos do Trabalho	18
1.3.1	Objetivo Geral	18
1.3.2	Objetivos Específicos	18
1.4	Estrutura da Dissertação	18
2	FUNDAMENTAÇÃO TEÓRICA	20
2.1	Análise Espectral de Holo-Hilbert	20
2.2	Fundamentos de EEG	21
2.2.1	Ritmos cerebrais	22
2.3	Propriedades Estocásticas e Determinísticas do Sinal de EEG	23
2.3.1	Abordagem estocástica do sinal de EEG	24
2.4	Treinamento Cognitivo	25
2.4.1	Neurofeedback	25
2.4.2	Sistema Internacional 10/20	26
3	MÉTODOS	27
3.1	Iniciativa	27
3.2	Participantes	27
3.2.1	Grupo Controle	27
3.2.2	Grupo Experimental	27
3.3	Aquisição de sinais de EEG	28
3.3.1	Setup Experimental	29
3.4	Algoritmo Implementado para HHSA	31
3.4.1	Validação	35
3.4.2	Leitura dos mapas	36
3.5	Análise Estatística	36
4	RESULTADOS	38
4.1	Análise espectral de Holo-Hilbert	38
4.1.1	Valores de amplitude e frequência	41
4.2	Análise de P_{Total}	44
5	DISCUSSÃO	47

5.1	Análise espectral de Holo-Hilbert	47
5.2	Treinamento Cognitivo	49
6	CONCLUSÃO	51
6.1	Trabalhos Futuros	51
	REFERÊNCIAS	52
	APÊNDICES	57
	APÊNDICE A – PARECER DO COMITÊ DE ÉTICA	58

1 Considerações Iniciais

1.1 Introdução

A cognição é o conjunto de habilidades ou processos mentais que fornecem meios a um indivíduo de entender o mundo ao seu redor e tomar decisões sobre ele. O treinamento cognitivo tornou-se uma das intervenções mais proeminentes nos estudos para aperfeiçoamento de funções cognitivas. Atualmente duas abordagens principais para o treinamento cognitivo têm sido investigadas: formação baseada em estratégia e formação baseada em processos. Metas de treinamento baseadas em estratégia realizam o uso de estratégias de melhoria de desempenho (por exemplo, mnemônicos) que é relacionada a déficits cognitivos (BREHMER et al., 2014; WILLIS; BELLEVILLE, 2016). Já o treinamento baseado em processos visa aperfeiçoar processos cognitivos por meio de repetição e prática em tarefas direcionadas a domínios cognitivos específicos (CAMERON et al., 2015). A essência do treinamento baseado em processos está na premissa de que a prática constante em uma tarefa melhora o desempenho na mesma e em tarefas semelhantes (KARBACH; VERHAEGHEN, 2014).

Dessa forma, ferramentas como *Neurofeedback* (NFB) podem ser eficazes em protocolos de TC. O NFB é uma ferramenta terapêutica que fornece informações com a finalidade de permitir aos indivíduos desenvolver a capacidade de autorregulação fisiológica. Proporciona o retorno imediato da informação baseado em diferentes processos fisiológicos (NESTORIUC et al., 2008). É um sistema baseado no paradigma de condicionamento operante, em que o processo de aprendizagem ou comportamento é modificado por reforço ou punição. Os diferentes padrões de EEG correlacionados, por exemplo, aos estados de concentração focada ou o comportamento de tolerância ao estresse, podem ser identificados, treinados (reforçados ou inibidos) e ativados voluntariamente (THOMPSON et al., 2007).

O principal objetivo das intervenções com neurofeedback, é o de condicionar a energia do seu ritmo sensório-motor (SMR). O ritmo SMR está funcionalmente ligado ao córtex motor primário e sensorial, localizado centralmente no córtex cerebral. Este ritmo ocorre em uma faixa de frequência específica [12–15] Hz, se manifesta e suprime como um padrão estreito e repentino. Quanto mais tempo esses picos se mantiverem, melhor a resposta ao treinamento (TIMMERS, 2014).

O estudo do sinal obtido por pelo treinamento cognitivo é de extrema importância para análise e interpretação de resultados. Nesta pesquisa, utilizamos a Análise Espectral de Holo-Hilbert (HHS), que se baseia no método de decomposição de modo empírico para cálculos de frequência e amplitude moduladas. Atualmente esse método vem sendo utilizado em diversos trabalhos de processamentos de sinais biomédicos. Moradi et al. (2022) usa o método HHS

para examinar a banda gama do EEG, aplicando duas camadas de EMD aos componentes FM e AM, removendo componentes com potência muito baixa com base no espectro de frequência de potência instantânea e, posteriormente, reconstruindo o sinal de banda gama sem ruído dos componentes restantes (MORADI et al., 2022).

Lee et al. (2022) utilizaram o método HHSA para analisar a variabilidade de frequência cardíaca (VFC) em sinais de eletrocardiograma (ECG) e a distribuição de probabilidade FM-AM em todo o sinal medido. A partir disso foi acumulada e exibida em um espectro Holo-Hilbert (HHS). Os autores observaram que a banda de frequência muito alta foi modulada por uma frequência FM próxima de zero e a frequência AM de 05 Hz no HHS calculado. Segundo Te-Min Lee (2022) o HHSA oferece uma nova perspectiva para analisar a VFC que pode fornecer informações perspicazes em estudos futuros (LEE et al., 2022).

1.2 Justificativa

Um dos grandes desafios do treinamento cognitivo, é identificar padrões ou biomarcadores que possibilitem a quantificação de estados mentais, como por exemplo, atenção, estados fadiga mental, estados produtivos relacionados a uma determinada tarefa, etc. A atividade cerebral medida em sinais EEG são séries temporais estocásticas que podem ser decompostas em diferentes componentes de frequência, também conhecidas como ritmos cerebrais (NIEDERMEYER; ERNST, 2005). Historicamente, essas componentes são divididas em cinco, *Delta*, *Alpha*, *Theta*, *Beta* e *Gama*. Essas frequências e suas subdivisões têm sido relacionadas a diversos estados comportamentais e cognitivos (PFURTSCHELLER; NEUPER, 2001; SANNELLI et al., 2019).

No caso da aprendizagem, determinar indicadores EEG ou biomarcadores que a relacione com o desempenho em uma atividade laboral é desafiador, devido à grande variabilidade desses sinais e a dinâmica cerebral de cada indivíduo (SEUNG, 2012; SPORNS, 2012). Por definição, biomarcadores são características quantificáveis (frequência, amplitude, potência, etc.) de processos biológicos que podem ou não estar correlacionados com a experiência do indivíduo (STRIMBU; TAVEL, 2010).

As ondas elétricas registradas com EEG são frequentemente tratados por abordagens lineares com bases predefinidas, enquanto que as oscilações captadas por EEG, são complexas e compostas por dinâmicas não lineares. Embora a análise espectral Wavelet e Hilbert possam resolver os sinais não estacionários adicionando variação temporal para determinar de forma adaptativa a função de fase e, assim, obter a frequência instantânea (FLANDRIN, 1998; HUANG et al., 2009), as modulações de amplitude são geralmente negligenciadas (HUANG et al., 2016). Por exemplo, a análise espectral de Fourier assume que a amplitude é constante e, portanto, a informação da variação nas modulações de amplitude é inexplorada, o que significa que os métodos convencionais de decomposição de dados são insuficientes para analisar as

informações não lineares na atividade neural (BREAKSPEAR, 2017; BUZSÁKI; MIZUSEKI, 2014; NGUYEN et al., 2019; CLARKE; LONGTIN; MALER, 2015).

Para investigar a modulação de amplitude em oscilações neurais, Huang et al. (2016) utilizam o método de análise espectral de Holo-Hilbert para fornecer representações informativas completas que incluem frequência portadora (FM), que é a frequência na análise de frequência convencional e medidas de frequência de modulação de amplitude (AM). O HHSA foi aplicado na análise de sinais de EEG na percepção visual (JUAN et al., 2021; NGUYEN et al., 2019) e memória de trabalho visual (LIANG et al., 2021).

1.3 Objetivos do Trabalho

1.3.1 Objetivo Geral

Extrair informações de frequência e amplitude moduladas de dados de EEG obtidos nas sessões de treinamento cognitivo a partir da Análise Espectral de Holo-Hilbert (HHSA).

1.3.2 Objetivos Específicos

- Implementar o algoritmo de processamento para a HHSA.
- Investigar variações de amplitude e frequência moduladas a partir dos mapas espectrais.
- Caracterizar informações de energia nos ritmos *Theta*, *SMR* e *HiBeta*.
- Analisar a eficácia de um treinamento cognitivo com base nas informações obtidas pela HHSA.

1.4 Estrutura da Dissertação

Este trabalho está estruturado em 6 capítulos, que abordam os estudos teórico e experimental sobre o tema.

Este capítulo tem o intuito de introduzir o assunto, definir os objetivos do trabalho e justificar a sua importância.

No segundo capítulo é feito o referencial teórico com um levantamento bibliográfico a respeito dos temas que servem de base para as ideias propostas neste trabalho.

No terceiro capítulo são apresentados os materiais utilizados, a descrição do banco de dados utilizado, a montagem do setup experimental e o método empregado para a aquisição e processamento de dados.

No quarto capítulo, é realizada a análise dos dados resultantes após a aplicação dos procedimentos.

No quinto capítulo, é feita uma breve discussão com base nos resultados exibidos no capítulo anterior.

E por fim, no sexto capítulo a conclusão e sugestão para propostas futuras deste trabalho são apresentadas.

2 Fundamentação Teórica

Neste capítulo, aborda-se os aspectos teóricos necessários para o desenvolvimento deste trabalho. Inicialmente, uma descrição sobre a Análise Espectral de Holo-Hilbert é apresentada. Algumas definições básicas sobre os fundamentos de EEG e os ritmos cerebrais também ser abordado e, por fim, definições a respeito de *Neurofeedback* também será explanado.

2.1 Análise Espectral de Holo-Hilbert

A Análise espectral de Holo-Hilbert (HHSa) é uma representação tempo-frequência relativamente recente com base na Decomposição de Modo Empírico (EMD) e na transformada de Hilbert, uma ferramenta padrão para calcular a amplitude e frequência instantânea de dados. Comparado com a transformada de Fourier janelada e transformada de Wavelet, a HHSa resulta em espectros mais nítidos e assim sendo mais sensível a variações de amplitude e frequência instantâneas (HUANG et al., 2016).

A HHSa foi proposta como complemento aos métodos tradicionais de análise espectral e fornece informações completas sobre sinais não lineares e não estacionários. A HHSa utiliza uma decomposição de modo empírico alinhado a abordagem da transformada de Hilbert-Huang (HHT) para identificar modulações de amplitude e frequência intrínsecas frequentemente presentes em sistemas não lineares em relação as análises tradicionais, que geralmente entregam resultados por meio de transformações integrais convolucionais baseadas em expansões aditivas e bases predeterminadas, principalmente sob premissas lineares e estacionárias (HUANG et al., 2016).

Assim, para processos não estacionários, o melhor que se podia fazer historicamente era usar as representações tempo-frequência, nas quais a variação da amplitude (ou densidade de energia) ainda é representada em termos de tempo. Para processos não lineares, os dados podem ter modulações de amplitude e frequência geradas por dois mecanismos diferentes: processos lineares aditivos ou não lineares multiplicativos. Como todos os métodos de análise espectral existentes são baseados em expansões aditivas, a priori ou adaptativos, nenhum deles poderia representar os processos multiplicativos. Embora a abordagem de análise espectral adaptativa anterior (HHT) pudesse acomodar a não linearidade intra-onda de maneira bastante notável, mecanismos multiplicativos não-lineares entre ondas que incluam acoplamento em escala cruzada e modulações de bloqueio de fase ainda foram deixados sem tratamento específico. Para resolver o problema de processos multiplicativos, dimensões adicionais no resultado do espectro tornam-se necessárias para analisar as variações em modulações de amplitude e frequência simultaneamente. A HHSa acomoda todos os processos: aditivo e multiplicativo, estacionário e não estacionário, interações lineares e não lineares. o Holo prefixo em HHSa denota uma representação dimensional múltipla com capacidades aditivas e multiplicativas (HUANG et al.,

2016; HUANG et al., 1998; WU; HUANG, 2010; HOU; SHI; TAVALLALI, 2013).

A HHSA é implementada nas seguintes etapas (HSU et al., 2018):

1. Decompor o sinal de série temporal $X(t)$ em IMF_{FM_s} usando decomposição de modo empírico, denotado pela equação 3.1:

$$X(t) = \sum_{L=1}^N I_L(t) = \sum_{L=1}^N a_L(t) \cos \theta_j(t) = Re \left\{ \sum_{L=1}^N a_L(t) \cdot e^{i \int_t \omega_L(\tau) d\tau} \right\} \quad (2.1)$$

Onde $Re \{ \}$ é o operador para extrair valor real sinal, $I_L(t)$ é o L^{th} IMF_{FM} , e $a_L(t)$ e $\omega_L(t)$ são a amplitude e a frequência instantânea de L^{th} IMF_{FM} no tempo t , respectivamente, após a aplicação do EMD de primeira camada.

2. Extrair o valor absoluto de cada IMF_{FM} e construindo a função envelope, denotada por $\hat{a}_L(t)$ para todos os extremos superiores.
3. Executar a segunda camada de EMD para decompor $\hat{a}_L(t)$ em IMF_{AM_s} , expresso pela equação 3.2:

$$\hat{a}_L(t) = Re \sum_{K=1}^M a_{L,K}(t) e^{i \int_t \Omega_{L,K}(\tau) dt} \quad (2.2)$$

Onde $a_{L,K}(t)$ e $\Omega_{L,K}(t)$ são as amplitudes e frequências instantâneas do K^{th} IMF_{AM} decomposto do L^{th} IMF_{FM} , respectivamente, no tempo t .

4. Integrar a potência $|a_{L,K}(t)|^2$ com as frequências instantâneas $\omega_L(t)$ e $\Omega_{L,K}(t)$ ao longo do tempo todos os pontos de todas as IMF_{FM_s} e IMF_{AM_s} para obter o mapa tridimensional do espectro de Holo-Hilbert, ou seja $(\omega, \Omega, P(\omega, \Omega))$.

$$P_{total} = \int \int P_s(\omega, \Omega) d\omega d\Omega \quad (2.3)$$

2.2 Fundamentos de EEG

Eletroencefalografia (EEG) é um método de monitoramento eletrofisiológico que é utilizado para registrar a atividade elétrica do cérebro. Trata-se de um método não-invasivo, com eletrodos posicionados no couro cabeludo. O EEG mede as variações de tensão elétrica resultantes das correntes iônicas no meio extracelular dos neurônios. (TANZER et al., 2006).

Quando as células cerebrais (neurônios) são ativadas, os fluxos de corrente local são produzidos. O EEG mede principalmente as correntes que fluem durante as excitações sinápticas dos dendritos de neurônios piramidais no córtex cerebral. As diferenças de potenciais elétricos

são causadas por potenciais graduados pós-sinápticos somados de células piramidais que criam dipolos elétricos entre o soma (corpo do neurônio) e os dendritos apicais (ramos neurais). Apenas grandes populações de neurônios ativos podem gerar atividade elétrica registrável na superfície da cabeça. Sinais elétricos detectados pelos eletrodos do couro cabeludo são amplificados e, em seguida, exibidos em papel ou armazenados na memória do computador (TYNER; KNOTT; MAYER, 1989). Devido à capacidade de refletir a atividade elétrica normal e anormal do cérebro, o EEG é considerado uma ferramenta muito poderosa no campo da neurologia e da neurofisiologia clínica (TEPLAN et al., 2002).

2.2.1 Ritmos cerebrais

As faixas de frequência reveladas no sinal de EEG estão associadas com funções mentais distintas (MARZBANI; MARATEB; MANSOURIAN, 2016): ondas θ são mais evidentes em crianças e, em adultos, estão associadas com estados meditativos e sono (exceto sono profundo). As ondas α estão associadas a um estado de relaxamento, tranquilidade e vigília, estado de autoconsciência. O ritmo β é associado a estados de atividade mental, intelectual e concentração sustentada, e é dividido em dois subritmos: *LowBeta* (12 – 20Hz) e *HighBeta* (20 – 30Hz) (LÓPEZ-AZCÁRATE et al., 2010) (PRIORI et al., 2004). A tabela 1 resume algumas frequências características de sinais de EEG e a Figura 1 ilustra as características dessas ondas.


Tabela 1 – Faixas de frequência do EEG e suas características

Onda cerebral	Faixa de frequência (Hz)	Características gerais
δ	0,5-4	sono, reparo, resolução de problemas, inconsciência, inconsciência profunda
θ	4-8	Criatividade, <i>insight</i> , estados profundos, inconsciência, estado meditativo ótimo, depressão, ansiedade, distração
α	8-12	prontidão e tranquilidade, meditação, profundamente relaxado
β	12-30	<i>LowBeta</i> (12 – 20Hz): Atividade intelectual, pensando, focando <i>HighBeta</i> (20 – 30Hz): Concentração sustentada, alerta, excitação
γ	30-100	aprendizagem, processamento cognitivo, tarefas de resolução de problemas, agudez mental

Fonte: Marzbani, Marateb e Mansourian (2016).

O ritmo MU (μ) ou sensoriomotor (SMR) ocorre na faixa de frequência de 12 – 15Hz, são detectados principalmente no córtex motor e se desencadeia quando há um movimento real ou há uma intenção de se mover (MUNIAN; SIVALINGAM; JAYARAMAN, 2014). A Figura 1 ilustra as características dessas ondas.

Figura 1 – Exemplo de frequências típicas do EEG.



Fonte: Autor.

2.3 Propriedades Estocásticas e Determinísticas do Sinal de EEG

A definição do EEG como um sinal estocástico ou determinístico é uma questão fundamental a ser discutida. O sinal de EEG é normalmente corrompido por ruídos aleatórios e artefatos, introduzidos por diversas fontes intrínsecas (atividade muscular, movimentos com olhos, etc.) e extrínsecas (rede elétrica, etc.). Neste sentido, não é possível prever amplitude, duração e morfologia deste tipo de sinal, o que torna razoável considerar o sinal de EEG como um sinal estocástico (SÖRNMO; LAGUNA, 2005).

Outra abordagem é a determinística. A abordagem determinística do sinal de EEG é baseada em modelos não lineares descritos por um conjunto de equações diferenciais, nas quais a ativação das bombas de potássio e sódio, a inibição das bombas de sódio e o potencial da membrana são variáveis destas equações. Estes modelos são de alta complexidade e partem do princípio que a saída de um sistema não linear caracterizado por um processo determinístico exibe comportamento caótico que representa características similares ao um processo estocástico

(FELL et al., 2000).

Basicamente, a principal diferença entre processos estocásticos e determinísticos reside no fato de que sistemas determinísticos sempre evoluem de uma forma fixa, definido um instante inicial. Um sistema determinístico pode ser testado aplicando-se uma entrada conhecida a este sistema, e comparando os instantes de tempo adjacentes para ver a evolução temporal do sistema. O erro de um sistema determinístico mantém-se o mesmo ou cresce exponencialmente (sistemas caóticos). O processo estocástico, por outro lado, possui erro aleatório e este é medido comparando a evolução temporal do sinal de EEG (SÖRNMO; LAGUNA, 2005).

2.3.1 Abordagem estocástica do sinal de EEG

Um sinal estocástico parte da definição de variável aleatória. Uma variável aleatória é definida como o resultado de um experimento estatístico completamente caracterizado por um espaço amostral, evento e função de densidade de probabilidade (CANDY, 1988). Um processo estocástico é definido como uma função bidimensional do tempo e de um conjunto de possíveis valores de uma variável aleatória - amostras do espaço amostral (CANDY, 1988).

Ao definir o EEG como um processo estocástico, faz-se necessário a sua caracterização quanto à função densidade de probabilidade (PDF). Em acordo com uma abordagem não paramétrica, a densidade de probabilidade pode ser definida calculando-se o histograma dos dados amostrados do sinal de EEG e realizando hipóteses baseados nos histogramas (SANEI; CHAMBERS, 2013).

Tomando como base a premissa do Teorema Central do Limite, que afirma que a média das diversas componentes aleatórias independentes (sinais individuais de cada neurônio) tende a uma PDF Gaussiana à medida que o número de amostras aumenta, é plausível caracterizar os sinais de EEG como uma PDF Gaussiana. Uma vez que o sinal de EEG registrado no escalpo é formado pela soma de sinais (atividades neuronais) de uma imensa quantidade de neurônios individuais com atividades aleatórias (SÖRNMO; LAGUNA, 2005).

Por meio de investigações procurando determinar o quão bem a PDF gaussiana descreve os sinais de EEG realizadas sob várias condições experimentais, conclui-se que, em geral, para intervalos curtos de tempo, os sinais de EEG são descritos de maneira fiel por um PDF Gaussiana. À medida que os intervalos de tempo dos sinais de EEG aumentam a descrição do sinal de EEG pela PDF Gaussiana passa a ser menos fiel (MCEWEN; ANDERSON, 1975).

Um sinal estocástico, descrito por uma distribuição de probabilidade Gaussiana, é completamente caracterizado por seu valor médio e pela função de correlação (autocorrelação) (MCEWEN; ANDERSON, 1975). A análise espectral é uma das técnicas mais utilizadas para o processamento de sinais de EEG, uma vez que um sinal aleatório pode ser representado por sua covariância e sua transformada pelo seu espectro de potência. Segue-se então que a análise espectral define o processo estocástico descrito por uma PDF Gaussiana de maneira eficaz, e,

portanto é uma técnica apropriada para a extração de informações de sinais de EEG (CANDY, 1988).

2.4 Treinamento Cognitivo

O treinamento cognitivo é o conjunto de técnicas que contribuem para estimular as funções cerebrais e a capacidade mental. Tem o objetivo de aprimorar as habilidades cognitivas gerais, como atenção, funções executivas, memória, percepção, praxia, linguagem, entre outras (GE et al., 2018).

O interesse científico em intervenções cognitivas destinadas a manter ou melhorar as funções cognitivas no cérebro tem aumentado rapidamente. Geralmente, duas categorias básicas de intervenções de treinamento cognitivo podem ser distinguidas: o treinamento baseado em estratégia, com uso de vários domínios, geralmente são mais complexas e envolvem vários processos cognitivos, produzindo efeitos de transferência amplos, relacionados a déficits cognitivos, envelhecimento e neuroplasticidade (PARK et al., 2014; LÖVDÉN et al., 2012). Já os protocolos baseados em processos, que visam aperfeiçoar capacidades de processamento mais gerais, como velocidade de processamento ou funções executivas (LI et al., 2004). São um conjunto de processos de controle que suportam a adaptação a ambientes em mudança e demandas de tarefas. Eles incluem memória de trabalho, inibição e flexibilidade cognitiva. Algumas intervenções baseadas em processos, principalmente com foco em funções executivas, resultaram em transferência promissora de ganho de treinamento para tarefas semelhantes (BREHMER; WESTERBERG; BÄCKMAN, 2012; ZINKE et al., 2014).

2.4.1 Neurofeedback

Um dos principais instrumentos utilizados em protocolos de TC é o *Neurofeedback* (NFB) (PARSONS; FAUBERT, 2021; RAJABI; PAKIZE; MORADI, 2020; HU; XIE; SUN, 2018), que é uma ferramenta terapêutica que permite aos indivíduos, desenvolver a capacidade de autorregulação de ritmos cerebrais através de EEG. É um sistema baseado no paradigma de condicionamento operante no qual um comportamento pode ser modificado através de reforço ou punição. Dessa forma, parâmetros do registro de EEG, quando identificados, podem ser treinados e reforçados ou inibidos induzindo uma ativação voluntária (THOMPSON E THOMPSON, 2003).

O sinal da atividade neural é captado por eletrodos, através do EEG e remetido ao computador na forma de onda. No computador, o sinal bruto é filtrado e processado. (THOMPSON E THOMPSON, 2003). Aprender a mudar uma imagem ou som do computador reflete a autorregulação do ritmo treinado e dos estados mentais subjacentes. Na medida em que os padrões de EEG refletem mudanças nas relações entre os sistemas neurais, fisiológicos, etc. o indivíduo estaria realmente aprendendo a autorregular esse complexo sistema neural e desenvol-

ver a capacidade de acessar de forma voluntária e fora do ambiente de treinamento os ritmos treinados (COLLURRA, 2014).

2.4.2 Sistema Internacional 10/20

As informações sobre as especializações de cada área do cérebro, obtidas em pesquisas de intervenções cirúrgicas, permitiram correlacionar as áreas com funções e sintomas específicos, destacando a importância desse conhecimento, tanto na avaliação como no treinamento em NFB (ARDILA; BERNAL; ROSSELLI, 2016).

O sistema internacional 10/20 atribui letras e números para identificar os pontos ou sítios no escalpo. É um sistema de coordenadas onde os números ímpares representam os pontos no hemisfério esquerdo e os pares no direito, enquanto as letras se referem aos lobos ou regiões específicas, sendo F (forntal), Fp (polo frontal), T (temporal), O (occipital), P (parietal), C (central ou cortical) e Z a linha central que separa os dois hemisférios (KULKARNI et al., 2020)

3 Métodos

Esse capítulo tem por objetivo apresentar e descrever os materiais e métodos implementados no desenvolvimento deste trabalho.

3.1 Iniciativa

O projeto está inserido no Programa de Operadores de Alto Desempenho da Vale (POAD) vinculado ao Instituto Tecnológico Vale (ITV). O projeto visa desenvolver atividades para melhoria de performance de desempenho dos operadores da empresa *Vale S.A.*, assim como protocolos de treinamentos para novos operadores. Dessa forma, esse trabalho foi desenvolvido para fins de análise, caracterização e classificação de dados coletados. Os procedimentos foram aprovados pelo Comitê de Ética em Pesquisa com Seres Humanos do Instituto de Ciências da Saúde da Universidade Federal do Pará (CAAE: 11015918.4.0000.0018).

3.2 Participantes

Este estudo teve a participação de um conjunto de 16 operadores de escavadeira do Complexo S11D Eliézer Batista, localizado na Serra Sul da grande região de Carajás. Os sujeitos possuíam idades entre 26 e 53 anos, nenhum relatou possuir doenças crônicas ou ser usuário de medicamentos controlados. O conjunto de operadores foi dividido em dois grupos de 8 sujeitos cada, grupo treinado e grupo controle, respectivamente.

3.2.1 Grupo Controle

A metodologia e coleta de dados do grupo controle foi implementada da seguinte maneira:

- **Semana 1:** Registro da atividade EEG em repouso e coleta de dados em simulador de operação, em Carajás.
- **Semana 2:** Sem atividades relacionadas ao projeto.
- **Semana 3:** Registro da atividade EEG em repouso e coleta de dados em simulador de operação, em Carajás.

3.2.2 Grupo Experimental

A fase de treinamento da equipe de operadores de escavadeira foi dividida em duas etapas (etapa Carajás e etapa Belém). Por questões logísticas, os operadores foram divididos em

dois grupos, turmas 1 e 2. Assim, o cronograma foi executado em cinco semanas intercalando três etapas Carajás (primeira, terceira e quinta semanas) com duas etapas Belém (segunda e quarta semanas).

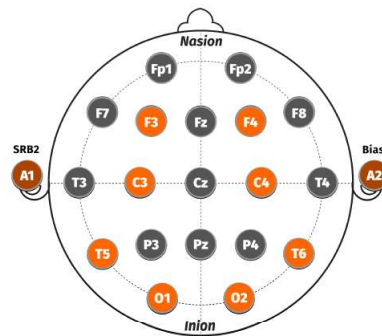
Durante as etapas Carajás, os operadores desenvolveram suas operações em simulador. Na etapa Belém, os operadores estiveram dedicados ao protocolo de treinamento cognitivo explicado adiante. A metodologia do treinamento foi implementada da seguinte forma:

- **Semana 1:** Registro da atividade EEG em repouso e coleta de dados em simulador de operação das turmas 1 e 2, em Carajás.
- **Semana 2:** Treinamento cognitivo da turma 1, em Belém:
 - Dia 1
 - * 3 (três) minutos de registro de EEG em repouso
 - * Treinamento Cognitivo
 - * 3 (três) minutos de repouso
 - Dias 2 e 3
 - * 3 (três) minutos de registro EEG em repouso
 - * Treinamento Cognitivo
 - * 3 (três) minutos de repouso
 - Dias 4
 - * 3 (três) minutos de registro EEG em repouso
 - * Treinamento Cognitivo
 - * 3 (três) minutos de repouso
- **Semana 3:** Registro da atividade EEG em repouso e coleta de dados em simulador de operação, em Carajás, da turma 1.
- **Semana 4:** Treinamento cognitivo da turma 2, em Belém, como feito na semana 2.
- **Semana 5:** Registro da atividade EEG em repouso e coleta de dados em simulador de operação, em Carajás, da turma 2.

3.3 Aquisição de sinais de EEG

Os sinais EEG foram registrados com um sistema de 21 eletrodos (*neuro – headset* BrainMaster, Germany). Os dados são enviados do capacete ao computador com uma taxa de amostragem de 300Hz através de uma conexão sem fio bluetooth. Os 21 eletrodos são posicionados de acordo com o sistema 10-20 (ODOM et al., 2010), ilustrado na Figura 2.

Figura 2 – Sistema internacional 10-20 BrainMaster 24D




Fonte: BrainMaster (2018).

3.3.1 Setup Experimental

O protocolo consiste, em um primeiro momento manter o olhar fixo na tela por 3 minutos. Na sequência, o operador é submetido a um período de 15 minutos de familiarização com o ambiente de simulação de escavadeira. Em seguida, são registrados 60 minutos de simulação sem interferências externas. Imediatamente após a sessão são capturados mais 3 minutos de sinais de EEG em repouso. Durante os períodos de registro orienta-se que sejam evitadas deglutições, piscadas excessivas e movimentos voluntários. Também, durante do experimento de escavação foi solicitado que movimentos abruptos fossem evitados. A Figura 3 ilustra esse protocolo.

Figura 3 – Simulador de escavadeira.




Fonte: Ana Carolina (2021).

Na segunda etapa, é aplicado o treinamento cognitivo (TC) realizado através do software BrainAvatar, que acompanha o sistema Brain Master (BrainMaster Technologies, OH). O TC foi composto de um jogo, com NFB em que o operador tinha que manter um objeto, neste caso, uma nave, no limiar (linha central), para que assim fosse emitido um som que representava que o

mesmo estava satisfazendo as condições do treinamento, que eram predefinidas de acordo com o protocolo escolhido no software. Para este trabalho, os valores predefinidos foram baseados na literatura (WEBER et al., 2011): aumento da amplitude no SMR (12 – 15Hz) e redução da amplitude das ondas *Theta* (4 – 7Hz) e *HiBeta* (20 – 30Hz). O limiar é automático, o que significa que a recompensa e inibição são definidas automaticamente pelo programa. A pontuação ocorre quando o operador atinge a marca de 500 milissegundos em que os níveis das três bandas citadas apresentem o comportamento desejado. Os sujeitos realizaram duas sessões de treinamento cognitivo por dia, cada uma de 40 minutos, uma pela manhã, e outra pela tarde, espaçadas de aproximadamente 4 horas. Totalizando 4 sessões para cada operador. Os dados utilizados para este estudo são registros de EEG coletados após a primeira e a última sessão de treinamento, a Figura 4 ilustra este protocolo.

Figura 4 – Setup experimental.



Fonte: Autora (2022).

3.4 Algoritmo Implementado para HHSA

O projeto foi desenvolvido no ambiente de programação MATLAB ou *MATrix LABORatory* (MathWorks Inc, EUA) trata-se de um software interativo de alta performance voltado para o cálculo numérico. O MATLAB integra análise numérica, cálculo com matrizes, processamento de sinais e construção de gráficos em ambiente intuitivo para uso, onde problemas e soluções são expressos e escritos matematicamente, ao contrário da programação tradicional.


A HHSA foi implementada em cinco etapas de processamento, listadas a seguir:

1. Entrada do sinal EEG de 3min
2. Decompor o sinal de série temporal $X(t)$ em IMF_{FM_s} usando decomposição de modo empírico (Figura 5), denotado pela equação 3.1:

$$X(t) = \sum_{L=1}^N I_L(t) = \sum_{L=1}^N a_L(t) \cos \theta_j(t) = Re \left\{ \sum_{L=1}^N a_L(t) \cdot e^{i \int_t \omega_L(\tau) d\tau} \right\} \quad (3.1)$$

Onde $Re \{ \}$ é o operador para extrair valor real sinal, $I_L(t)$ é o L^{th} IMF_{FM} , e $a_L(t)$ e $\omega_L(t)$ são a amplitude e a frequência instantânea de L^{th} IMF_{FM} no tempo t , respectivamente, após a aplicação do EMD de primeira camada.

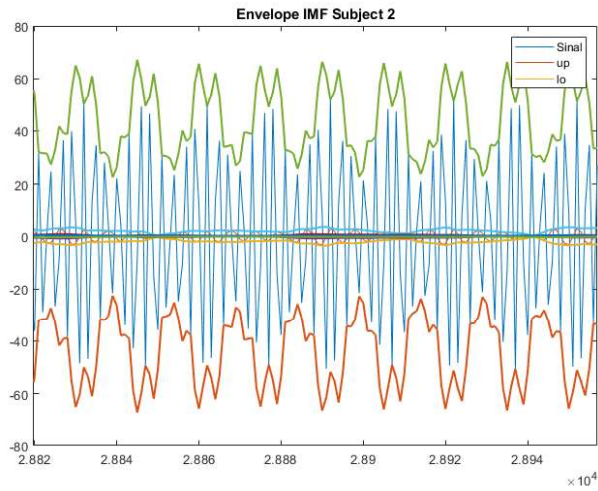
Figura 5 – Primeira EMD



Fonte: Autora (2022).

3. Extrair o valor absoluto de cada IMF_{FM} e construindo a função envelope, denotada por $\hat{a}_L(t)$ para todos os extremos superiores (Figura 6).
4. Executar a segunda camada de EMD, figura 7, para decompor $\hat{a}_L(t)$ em IMF_{AM_s} , expresso pela equação 3.2:

Figura 6 – Envelopamento do Sinal

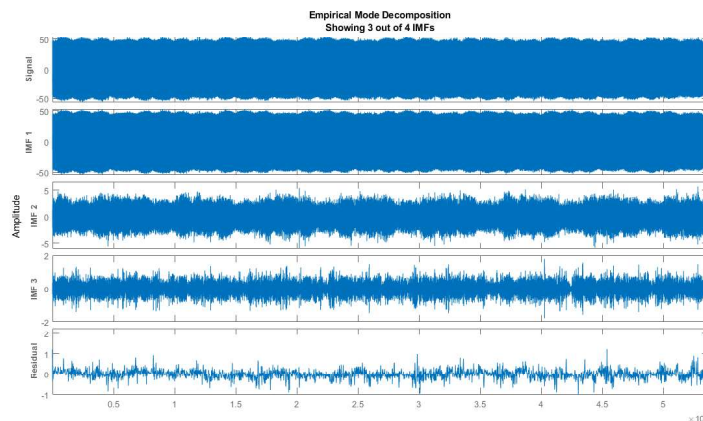


Fonte: Autora (2022).

$$\hat{a}_L(t) = Re \sum_{K=1}^M a_{L,K}(t) e^{i \int_t \Omega_{L,K}(\tau) dt} \quad (3.2)$$

Onde $a_{L,K}(t)$ e $\Omega_{L,K}(t)$ são as amplitudes e frequências instantâneas do K^{th} IMF_{AM} decomposto do L^{th} IMF_{FM} , respectivamente, no tempo t .

Figura 7 – Segunda EMD

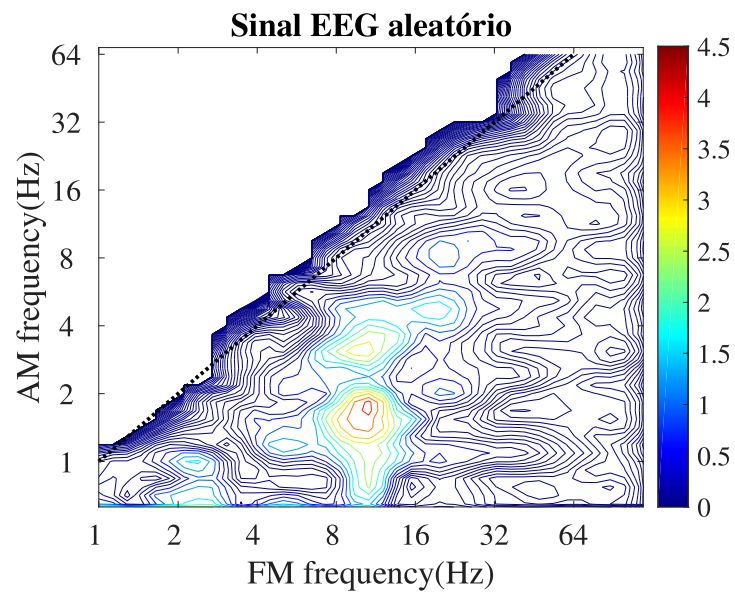


Fonte: Autora (2022).

- Integrar $|a_{L,K}(t)|^2$ com as frequências instantâneas $\omega_L(t)$ e $\Omega_{L,K}(t)$ ao longo do tempo todos os pontos de todas as IMF_{FM_s} e IMF_{AM_s} para estimação da potência e obter o mapa tridimensional do espectro de Holo-Hilbert (Figura 8, ou seja $(\omega, \Omega, P(\omega, \Omega))$).

$$P_{total} = \int \int P_s(\omega, \Omega) d\omega d\Omega \quad (3.3)$$

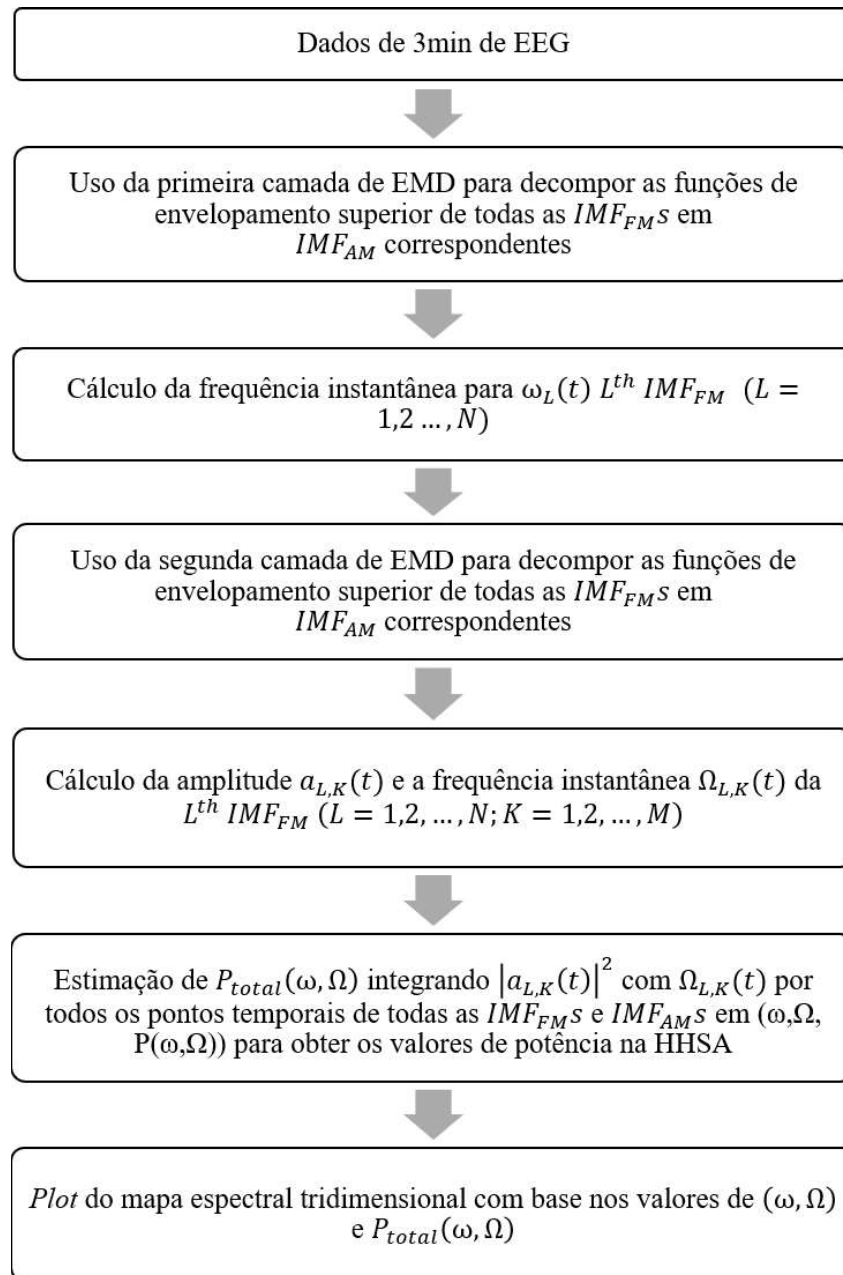
Figura 8 – Exemplo do Mapa Espectral gerado pela HHSA



Fonte: Autora (2022).

Em suma, todas as etapas de processamento são apresentadas no fluxograma ilustrado na figura 9.

Figura 9 – Algoritmo de Processamento da HHSa

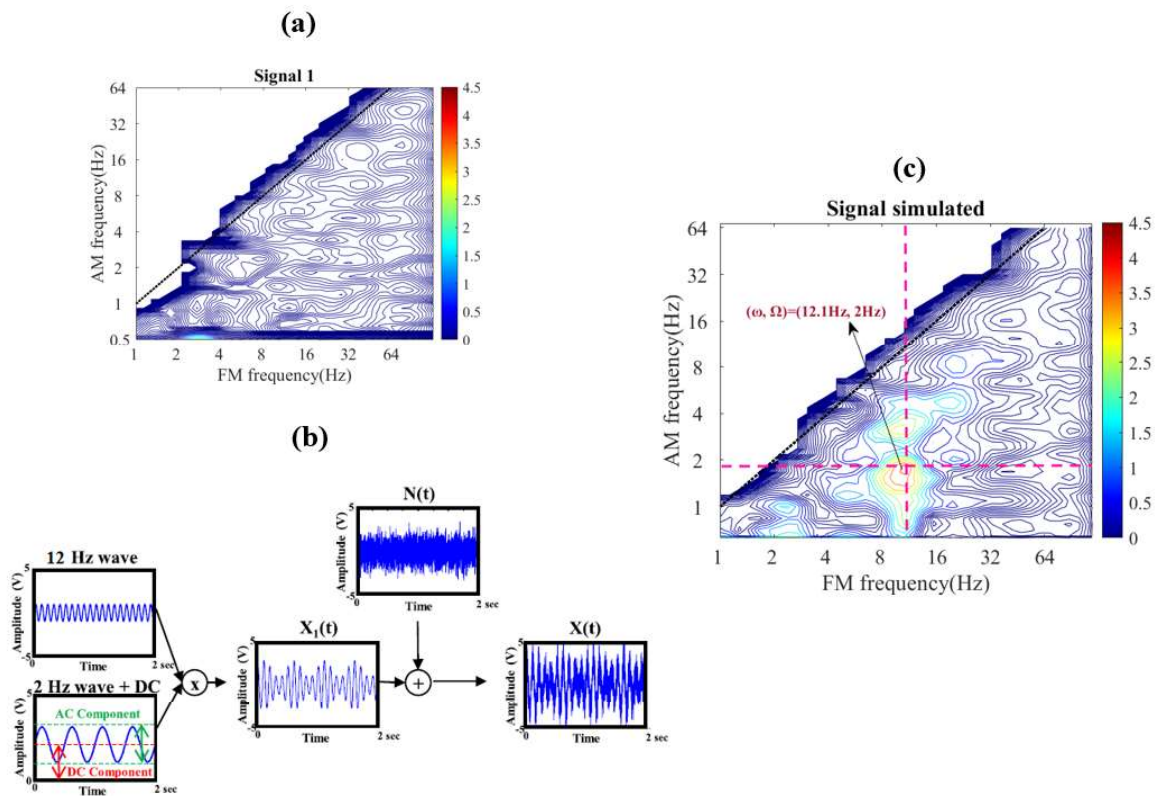


Fonte: Autora (2022).

3.4.1 Validação

Para fins de validação do método proposto, foi feita uma simulação com um sinal aleatório sem nenhuma informação significativa para análise (a). Como mostra a figura 10, é adicionada uma informação não linear: uma onda em frequência (FM) em 12Hz, e um sinal de amplitude (AM) em 2Hz. Em seguida, é aplicado o processo multiplicativo somado a um ruído (b). Dessa forma, o sinal resultante X_t será uma série temporal não-linear com informações predefinidas para análise. Portanto, é possível observar em (c) que, o algoritmo proposto neste trabalho está expressando corretamente as informações aplicadas.

Figura 10 – Validação do método

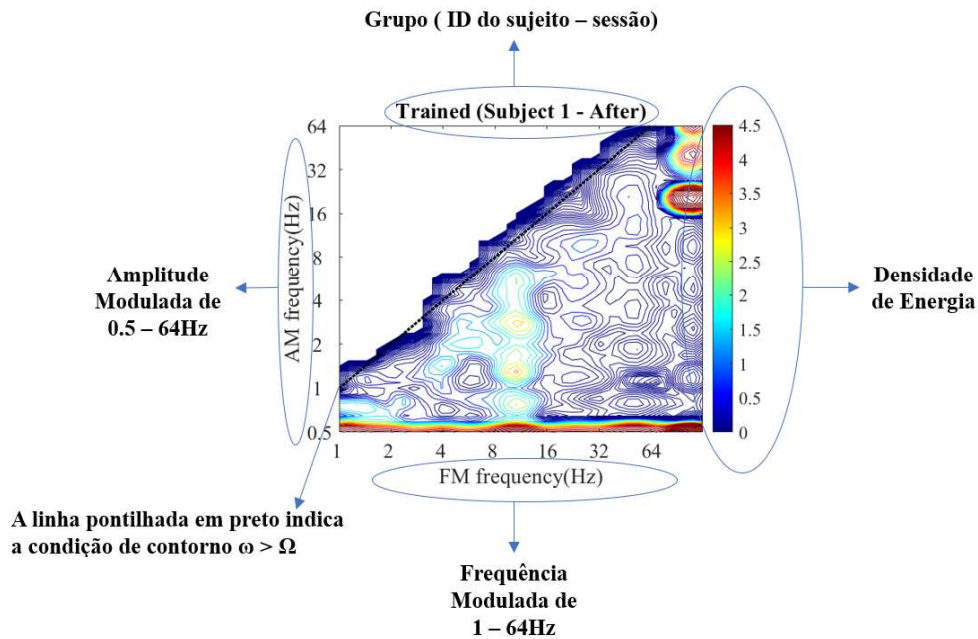


Fonte: Autora (2022).

3.4.2 Leitura dos mapas

Para interpretação correta dos resultados é importante entender as informações expressas nos mapas, dessa forma a Figura 11 ilustra a leitura correta da imagem.

Figura 11 – Leitura do mapa espectral.



Fonte: Autora (2022).

3.5 Análise Estatística

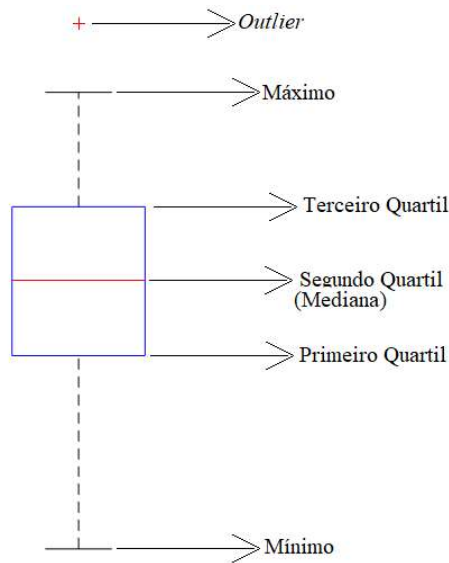
O teste de não paramétrico pareado de *Wilcoxon* foi aplicado para verificar a diferença estatística nos dados obtidos para os sujeitos do grupo treinado e controle. Para essa análise foi utilizado os valores de P_{total} obtidos pela equação 3.3, através do software STATISTICA v.14.0.

Desenvolvido por F. Wilcoxon em 1945, o teste de *Wilcoxon* pareado baseia-se nos postos das diferenças intrapares. Este teste não-paramétrico, usado para comparar amostras relacionadas, é uma alternativa para o teste *t-Student* quando as amostras não seguem distribuição normal. Portanto, o teste de *Wilcoxon* é usado para testar se as medianas das amostras são iguais nos casos em que a suposição de normalidade não é satisfeita ou quando não for possível checar essa suposição (WILCOXON, 1992).

O teste é realizado da seguinte forma, considerando que X_i representa os escores de uma dada amostra 1 e Y_i os escores de uma dada amostra 2. Primeiramente são calculadas as diferenças de cada par de escores, ou seja, $d_i = X_i - Y_i$. Após o cálculo das diferenças atribuem-se postos às diferenças dos escores em valor absoluto, $|d_i|$.

Neste trabalho, os resultados de P_{total} e da análise estatística serão complementados através dos *box plots*, que auxiliam na visualização dos resultados e comparação de grupos de dados. Os *box plots* identificam a distribuição dos dados, detalhando os valores discrepantes (*outliers*), máximo e mínimo, sendo estes calculados sem a inclusão dos *outliers*, primeiro, segundo e terceiro quartil, sendo o segundo quartil a mediana da distribuição dos dados (WILLIAMSON; PARKER; KENDRICK, 1989), conforme ilustrado na figura 12. Os *outliers* são identificados através de símbolos diferenciais, podendo ser um círculo ou uma cruz, por exemplo.

Figura 12 – Componentes de um *box plot*.



Fonte: Autora (2022).

4 Resultados

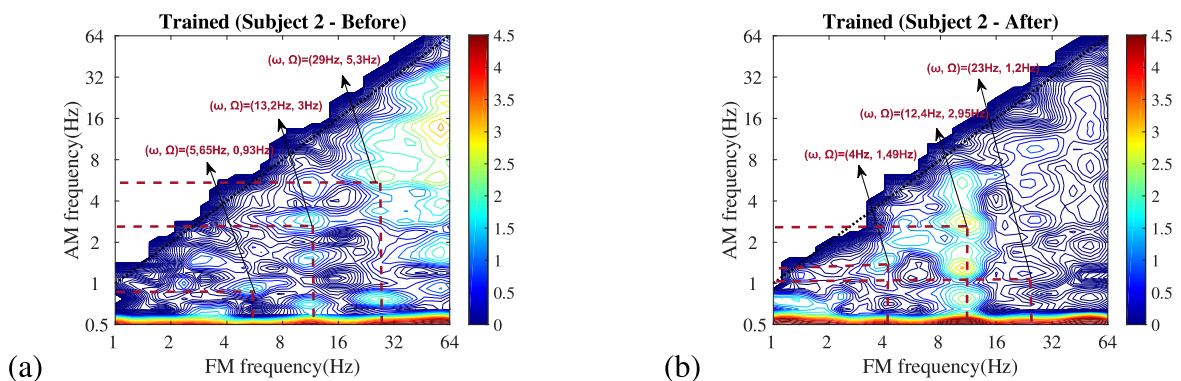
Neste capítulo serão apresentados os resultados obtidos a partir da metodologia descrita no capítulo anterior.

4.1 Análise espectral de Holo-Hilbert

Os sinais foram analisados em duas condições, antes e depois do treinamento. Para fins de demonstração dos resultados da HHSA, um sujeito do grupo treinado (GT) e um do grupo controle (GC) foram selecionados. Os demais mapas espectrais são encontrados em anexo no final deste documento.

São apresentados a seguir os resultados do grupo treinado antes e depois do treinamento. A Figura 13, ilustra o processamento resultante do algoritmo da HHSA proposto para o sujeito 2. Os pontos de interesse são marcados por retângulos tracejados em vermelho escuro, destacando as regiões de frequências das bandas estabelecidas. Os valores de P_{total} antes do treinamento são: $1.63197 \mu V^2$, $1.7399 \mu V^2$ e $2.3058 \mu V^2$ e as frequências máximas são: (5.65 Hz, 0.93 Hz), (13.2 Hz, 3 Hz) e (29 Hz, 5.3 Hz), respectivamente. Já os valores obtidos após o treinamento (Figura 13b) são: $1.32974 \mu V^2$ para *Theta*, $4.29873 \mu V^2$ para *SMR* e $0.464488 \mu V^2$ para *HiBeta*. As frequências máximas são: (4 Hz, 1.49 Hz), (12.4 Hz, 2.95 Hz) e (23 Hz, 1.2 Hz).

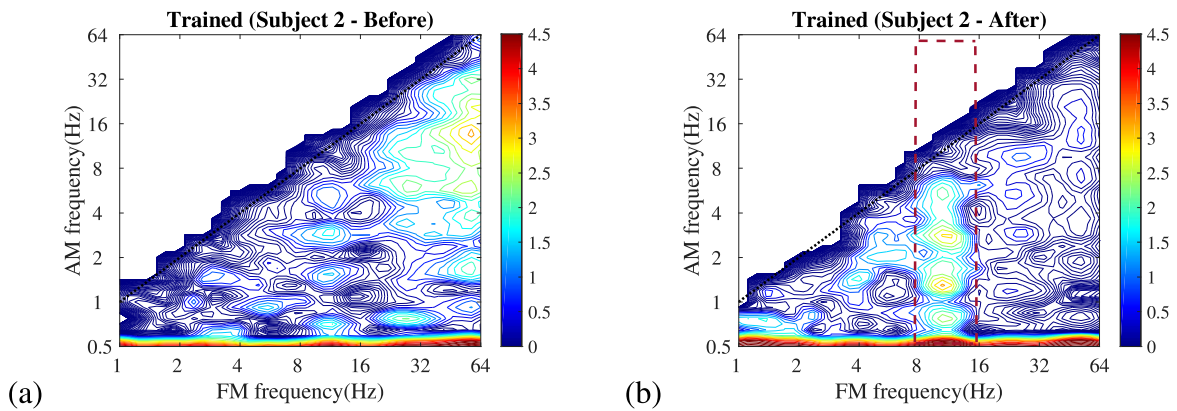
Figura 13 – Mapas espectrais sujeito treinado antes e após o treinamento



Fonte: Autora (2022).

Na Figura 14 foram destacadas algumas mudanças no mapa anterior.

Figura 14 – Mapas espectrais destacados para o sujeito treinado antes e após o treinamento

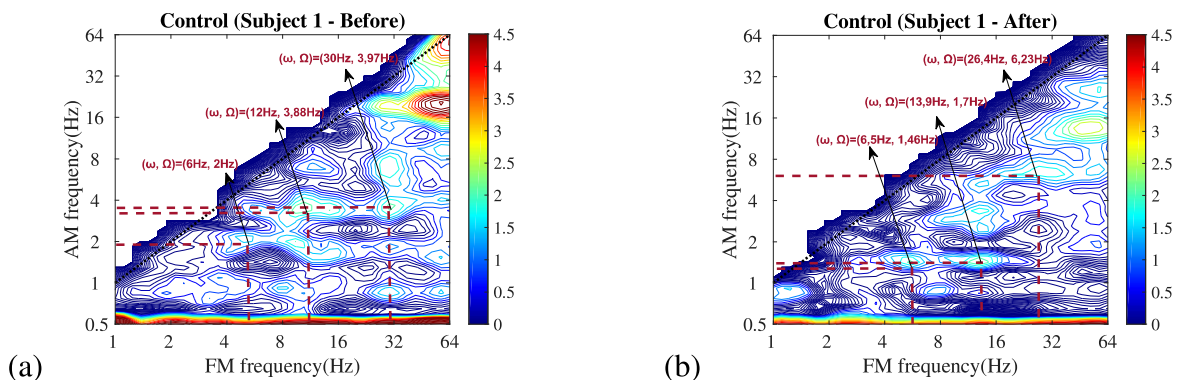


Fonte: Autora (2022).

É possível indentificar a diferença após o treinamento, dentro do retângulo tracejado em vermelho as variações de densidade de energia nas bandas de frequências estimuladas no treinamento cognitivo. O mapa após o treinamento (b) quando comparado a sessão antes (a) apresenta um pico de estímulo no SMR (12-15Hz), enquanto que nas demais frequências (*Theta* e *HiBeta*) não apresentam densidade de energia relativamente elevada, conforme o almejado pelo treinamento.

Para devidas comparações, é apresentado o mapa de espectro referente aos sujeitos do grupo controle, a Figura 15 ilustra os valores obtidos para o sujeito 1. Os valores da P_{total} para *Theta*, SMR e *HiBeta* na primeira sessão foram: $0.822177 \mu V^2$, $1.4786 \mu V^2$ e $1,77825 \mu V^2$, respectivamente. As frequências máximas são: (6 Hz, 2 Hz), (12 Hz, 3.88 Hz) e (30 Hz, 3.97 Hz), respectivamente. Para segunda sessão os valores de P_{total} são: $2.11912 \mu V^2$ para *Theta*, $1.35327 \mu V^2$ para SMR e $1.85059 \mu V^2$ para *HiBeta* e as frequências máximas foram: (6.5 Hz, 1.46 Hz), (13.9 Hz, 1.7 Hz) e (26.4 Hz, 6.23 Hz), respectivamente.

Figura 15 – Mapas espectrais sujeito 1 GC antes e após o treinamento

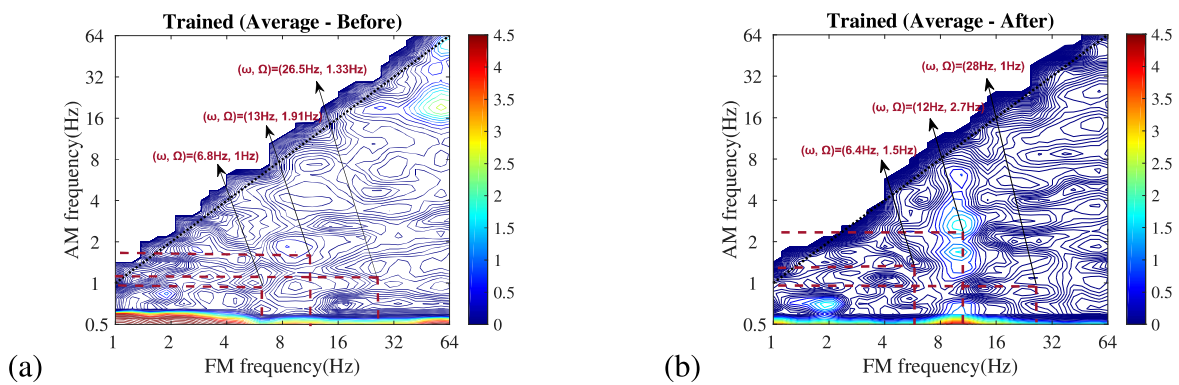


Fonte: Autora (2022).

Para visualização do comportamento médio através dos mapas espectrais foi feito o processamento do sinal médio, obtido através da média dos sinais de cada grupo. A Figura 16 mostra o mapa obtido para o grupo treinado antes e após o treinamento. Os valores de P_{total} antes do treinamento são: $0.8697 \mu V^2$, $0.22 \mu V^2$ e $0.087 \mu V^2$ e as frequências máximas são: (6.8 Hz, 1 Hz), (13 Hz, 1.91 Hz) e (26 Hz, 1.33 Hz), respectivamente. Já os valores obtidos após o treinamento (Figura 16b) são: $0.8017 \mu V^2$, $0.8045 \mu V^2$ e $0.40 \mu V^2$. As frequências máximas são: (6.4 Hz, 1.5 Hz), (12 Hz, 2.7 Hz) e (28 Hz, 1 Hz).

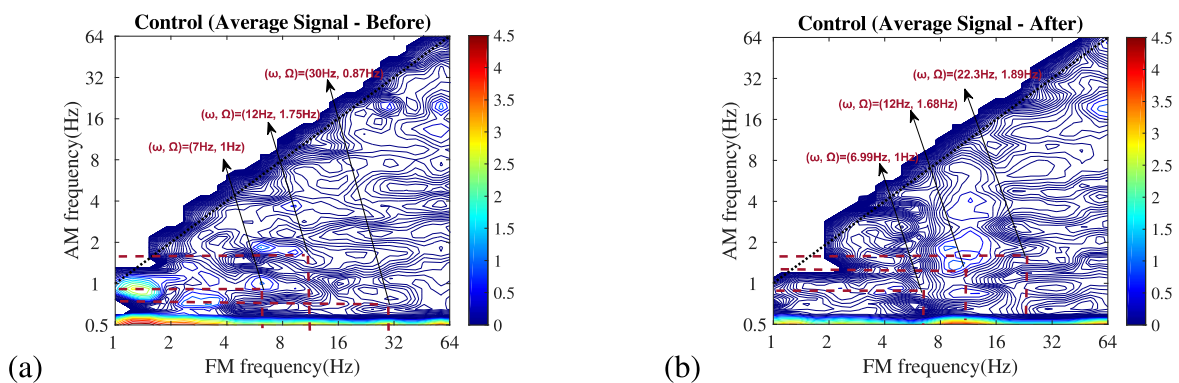
A Figura 17 mostra o mapa obtido para o grupo controle antes e após o período de treinamento. Os valores de P_{total} antes do treinamento são: $0.822 \mu V^2$, $1.47 \mu V^2$ e $0.69 \mu V^2$ e as frequências máximas são: (7 Hz, 1 Hz), (12 Hz, 1.75 Hz) e (30 Hz, 0.87 Hz), respectivamente. Já os valores obtidos após (Figura 17b) são: $0.44 \mu V^2$, $2.3 \mu V^2$ e $0.38 \mu V^2$. As frequências máximas são: (6.99 Hz, 1 Hz), (12 Hz, 1.68 Hz) e (22 Hz, 1.89 Hz).

Figura 16 – Mapas espectrais da média dos sinais para GT



Fonte: Autora (2022).

Figura 17 – Mapas espectrais da média dos sinais para GC



Fonte: Autora (2022).

É possível observar na Figura 16b que o comportamento médio do grupo treinado no pós treinamento, apresenta picos de densidade de energia nos intervalos de frequência do SMR,

enquanto que as demais frequências apresentam-se desestimuladas. Já no grupo controle, Figura 17, diferenças leves ou neutras visualmente.

4.1.1 Valores de amplitude e frequência

As Tabelas 2 e 3 mostram os valores de amplitude e frequência da banda *Theta* para o grupo controle e treinado respectivamente, antes e após o período de treinamento.

Tabela 2 – Valores de ω e Ω para Theta no grupo controle

Nome do Sujeito	Grupo Controle			
	Antes		Depois	
	ω	Ω	ω	Ω
Sujeito 1	6	2	6,5	1,46
Sujeito 2	7	0,82	6,66	1,54
Sujeito 3	6,11	1,54	6,8	1,4
Sujeito 4	4,4	1,44	6	1,4
Sujeito 5	5,79	0,89	7	0,75
Sujeito 6	5	1,98	4,3	2
Sujeito 7	4,1	1,333	5	1,49
Sujeito 8	6	1,55	4,2	1,9

Fonte: Autora (2022).

Tabela 3 – Valores de ω e Ω para Theta no grupo treinado

Nome do Sujeito	Grupo Treinado			
	Antes		Depois	
	ω	Ω	ω	Ω
Sujeito 9	6	1,55	4	1,5
Sujeito 10	5,65	0,93	4	1,49
Sujeito 11	6,7	1,61	5	1,91
Sujeito 12	4,2	1,49	4,391	1,86
Sujeito 13	4,35	0,89	5,3	1,71
Sujeito 14	6,40	1,6	5	1,75
Sujeito 15	4	0,80	4	0,50
Sujeito 16	6,31	2	6	1,62

Fonte: Autora (2022).

Na Tabela 4 mostra os valores de amplitude e frequência de SMR para o grupo controle e a Tabela 5 para o grupo treinado.

Tabela 4 – Valores de ω e Ω para SMR no grupo controle

Grupo Controle				
Nome do Sujeito	Antes		Depois	
	ω	Ω	ω	Ω
Sujeito 1	12	3,88	13,9	1,7
Sujeito 2	12,8	1,69	12,99	2,29
Sujeito 3	14,6	1,64	14	1,56
Sujeito 4	12	2,89	12	2,91
Sujeito 5	13	3,1	12	1,94
Sujeito 6	15	0,89	12	1,90
Sujeito 7	15	0,655	14,5	3,3
Sujeito 8	14	3,90	13	1,98

Fonte: Autora (2022).

Tabela 5 – Valores de ω e Ω para SMR no grupo treinado

Grupo Treinado				
Nome do Sujeito	Antes		Depois	
	ω	Ω	ω	Ω
Sujeito 9	14,56	3	12,2	2
Sujeito 10	13,2	3	12,4	2,5
Sujeito 11	14,4	2,9	14	3,10
Sujeito 12	13,45	3	12,4	3,69
Sujeito 13	13,99	1,365	13,1	0,65
Sujeito 14	15	3,2	12,1	1,61
Sujeito 15	12	0,79	12,12	1,89
Sujeito 16	13,5	1,5	15	1,89

Fonte: Autora (2022).

Por fim, na Tabela 6 são apresentados os valores de amplitude e frequência encontrados para *HiBeta* para o grupo controle e treinado, Tabela 7.

Tabela 6 – Valores de ω e Ω para *HiBeta* no grupo controle

Nome do Sujeito	Grupo controle			
	Antes		Depois	
	ω	Ω	ω	Ω
Sujeito 1	30	3,97	26,4	6,23
Sujeito 2	25,3	3,2	29	1,38
Sujeito 3	30	6,9	24,5	2,91
Sujeito 4	30	3	26,9	5,99
Sujeito 5	29,1	7	27	7,2
Sujeito 6	28	3,90	20	1,70
Sujeito 7	20	5,6	27	7
Sujeito 8	20	3	27,2	1,92

Fonte: Autora (2022).

Tabela 7 – Valores de ω e Ω para *HiBeta* no grupo treinado

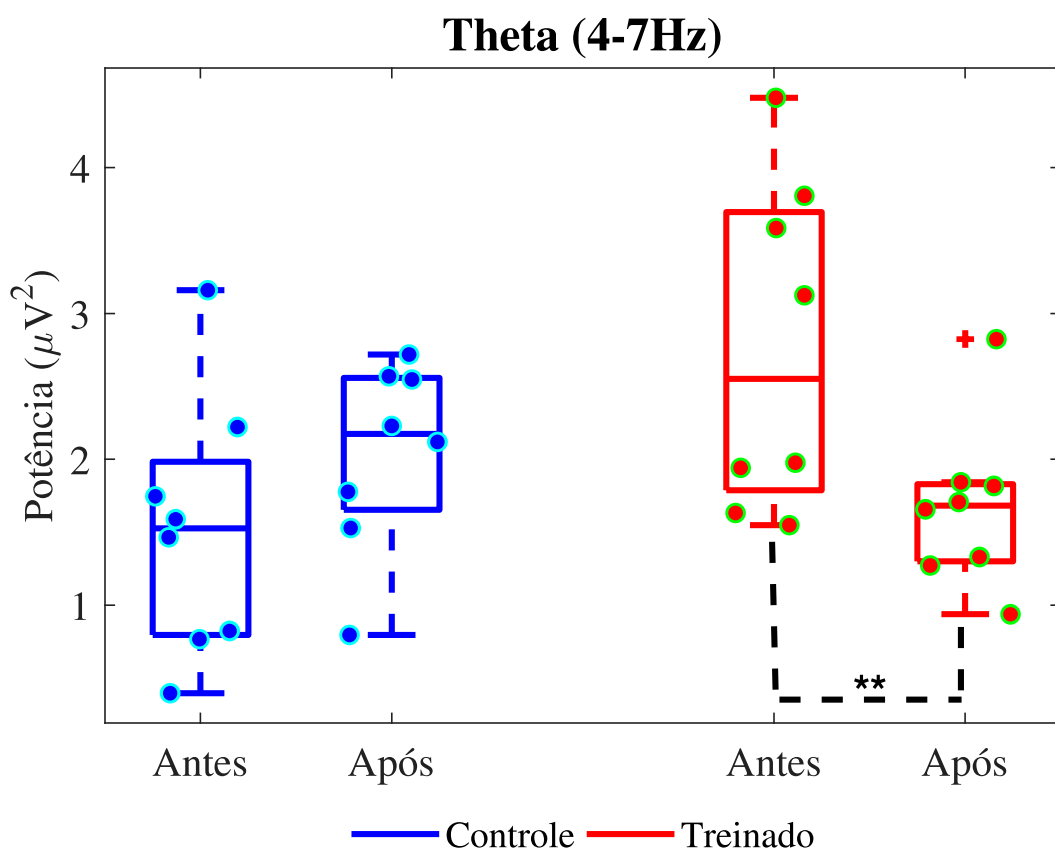
Nome do Sujeito	Grupo treinado			
	Antes		Depois	
	ω	Ω	ω	Ω
Sujeito 9	29,6	6,49	28	0,69
Sujeito 10	29	5,3	23	1,2
Sujeito 11	29,33	6	30	6,9
Sujeito 12	29,5	1,38	25,74	2,48
Sujeito 13	26,1	3,22	29,1	6,99
Sujeito 14	27,2	3,1	25,20	3,4
Sujeito 15	20,1	6,88	29,9	0,5
Sujeito 16	23,45	1,79	30	1,95

Fonte: Autora (2022).

4.2 Análise de P_{Total}

Realizou-se o teste de *Wilcoxon* para investigar a diferença entre os grupos. Para esta análise foram utilizados os valores P_{total} obtidos após a primeira e a última sessão. No ritmo *Theta* houve significância apenas para o grupo treinado, ilustrado na Figura 18. O grupo treinado apresentou uma diminuição no valor da mediana de P_{Total} , e variabilidade menor após o treinamento, já o grupo controle demonstra aumento no valor da mediana.

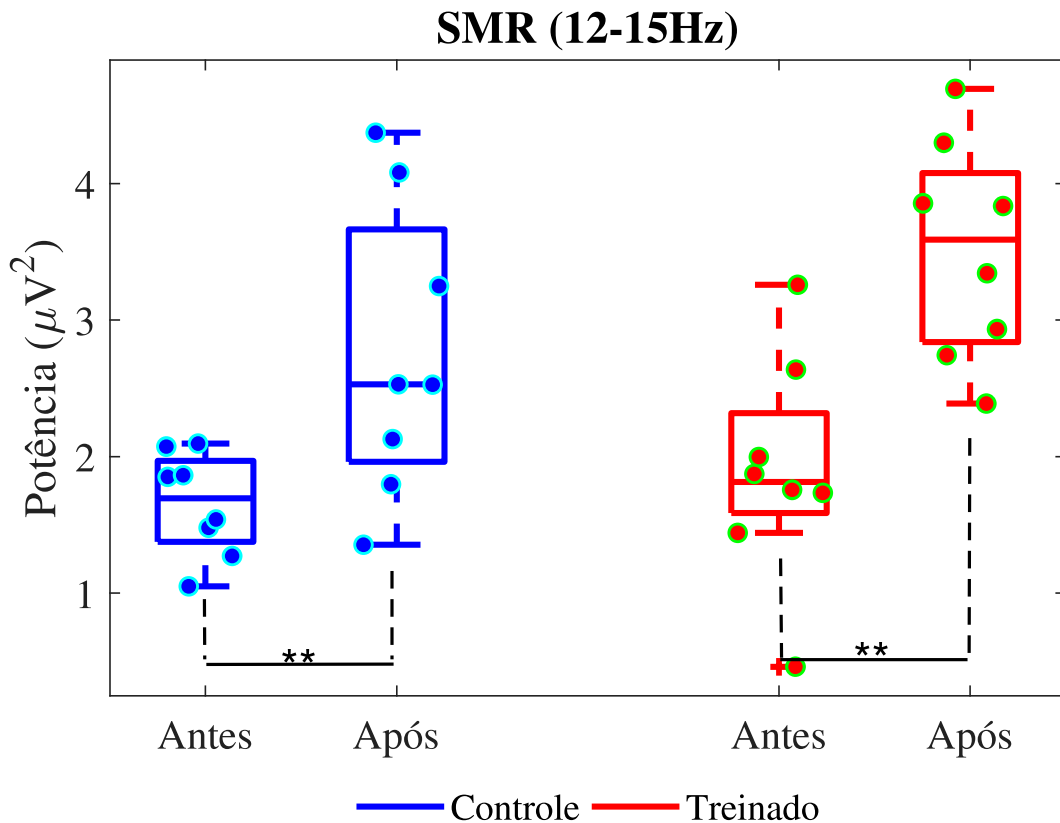
Figura 18 – Comparação entre os valores de P_{Total} obtidos em *Tetha* para Grupo Controle e Treinado. Resultados para $***p \leq 0,05$.



Fonte: Autora (2022).

O resultado para os valores do SMR são ilustrado na Figura 19, tanto o grupo treinado quando o grupo controle apresentaram significância estatística porém, o grupo treinado apresentou menor variabilidade após o treinamento, e mediana acima de $3 \mu V^2$, o grupo controle demonstra maior variabilidade e mantém os valores de potência abaixo de $3 \mu V^2$.

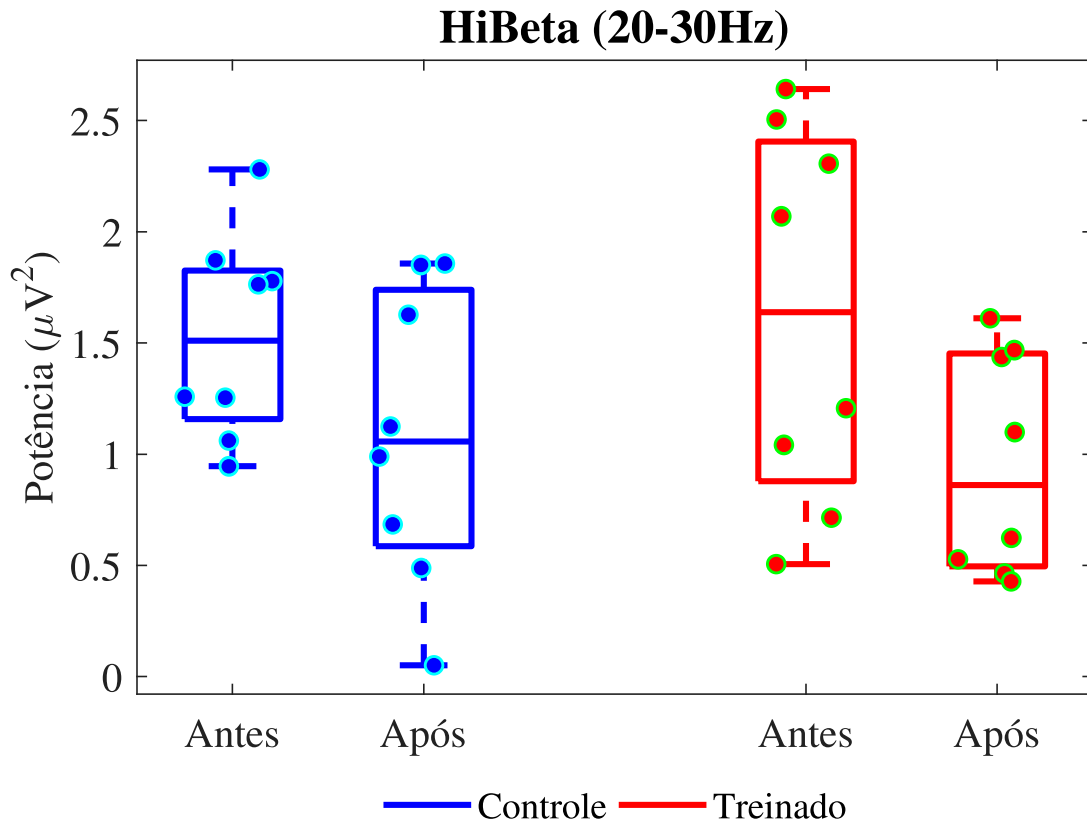
Figura 19 – Comparação entre os valores de P_{Total} obtidos em SMR para Grupo Controle e Treinado. Considerando que $**p \leq 0,001$.



Fonte: Autora (2022).

Por fim, para *HiBeta* houve uma diminuição nos valores de P_{Total} para ambos os grupos, mas não foram encontradas diferenças significativas nas análises estatísticas.

Figura 20 – Comparação entre os valores de P_{Total} obtidos em *HiBeta* para Grupo Controle e Treinado. Resultados para $***p \leq 0,05$.



Fonte: Autora (2022).

5 Discussão

Na presente pesquisa investigamos os efeitos de um treinamento cognitivo sob os ritmos *Theta*, SMR e *HiBeta* utilizando a Análise Espectral de Holo-Hilbert. Assim, este capítulo tem por objetivo discutir os resultados apresentados no capítulo anterior, tendo como base os trabalhos correlatos da literatura.

5.1 Análise espectral de Holo-Hilbert

Uma grande vantagem encontrada na utilização da HHSA, também relatado no trabalho de Huang et al. (2016), foi a possibilidade de extrair informações de forma adaptativa com base na natureza intrínseca do sinal bruto, através da decomposição de modo empírico (HUANG et al., 2016). Além disso, segundo Cole et al. (2017) o fato de o conteúdo de energia não ser restringido pela seleção de largura de banda ocorre para os métodos de acoplamento fase amplitude (PAC), indica que esta abordagem foi adequada para analisar as propriedades espectrais de oscilações não lineares (COLE et al., 2017).

Como observado na Figura 13, os resultados do sujeito treinado no pós treinamento apresentam um aumento nos componentes de amplitude no SMR (12-15Hz), apresentando modulação em amplitude na mesma faixa de amplitude de *Theta*. O trabalho de Juan et al. (2021) investigou este fenômeno e a natureza dinâmica da modulação de amplitude neural utilizando a HHSA, e verificou que a interação de frequência cruzada e o acoplamento entre as frequências de ritmos cerebrais pode ser observada usando HHSA confirmando assinaturas fisiológicas dinâmicas de sincronização neural relacionadas a ritmos em EEG (JUAN et al., 2021).

Ainda para os resultados do grupo treinado (Figura 14), na faixa de frequência do SMR, é possível observar um aumento nas modulações de amplitude. Essa diminuição também foi identificada nos demais sujeitos do grupo treinado, como indicado na tabela 5. Resultados semelhantes foram encontrados no trabalho de Hyafil (2015) que propõe que essas formas específicas de acoplamento são uma assinatura fisiológica de funções cognitivas. Segundo Hyafil (2015) a HHSA tem a capacidade revelar padrões nas variações de modulação em amplitude que ocorrem em sinais de EEG (HYAFIL, 2015).

Similarmente, no trabalho de Hsu et al. (2018), os mapas espectrais gerados pela HHSA foram utilizados não somente para o estudo e interpretação de informações visuais, como também para identificar valores de frequência e amplitude instantânea. Nossos resultados mostram que os mapas gerados apresentaram uma alta resolução temporal de interação de frequência cruzada, revelando possíveis padrões de comportamento do sinal nos dados do treinamento cognitivo. Nas figuras 13 e 14 é possível observar os picos de densidade de energia, que trazem informações de

variações de potência das oscilações neuronais e indicam que houve uma variação de energia nas bandas para o sujeito apresentado aos estímulos no treinamento cognitivo, confirmando que a HHSA pode ser uma ferramenta eficaz para o estudo e identificação variação de atividades neuronais (HSU et al., 2018).

O trabalho de Tiwari, Chakraborty e Koppurapu (2022), na tentativa de classificar dados de EEG a partir da HHSA, utilizou os valores de frequência e amplitude obtidos pelas decomposições semelhantes mostrados nas Tabelas 3, 2, 5, 4, 7, 6 e obtiveram uma acurácia de 67,33%. Na presente pesquisa, o método desenvolvido fornece não apenas os valores de amplitude e frequência (Ω , ω), como também todos os valores de potência (P_{Total}) estimadas para cada banda de frequência envolvida, para todos os sujeitos de grupo treinado e controle, sendo possível ainda extrair os valores de energia instantânea de cada IMF_{AM} e IMF_{FM} na primeira e segunda decomposição respectivamente, proporcionando uma potencial banco de dados para a implementação em um classificador (TIWARI; CHAKRABORTY; KOPPARAPU, 2022).

As informações não lineares obtidas pelos mapas do grupo controle, tanto visuais (Figuras 15) quando numéricas (Tabelas 2, 4 e 6) indicam, como o esperado, que não houve variações significantes de amplitude, frequência e energia instantânea.

Esses achados não apenas validam a eficácia do HHSA em revelar as características naturais dos sinais, mas também corroboram para melhor entendimento sobre outras aplicações de processamento e análise de dados eletrofisiológicos com o objetivo de entender o papel funcional das oscilações neuronais em diferentes aspectos e funções cognitivas.

5.2 Treinamento Cognitivo

Este trabalho testa a hipótese de que a utilização de um treinamento cognitivo pode aperfeiçoar funções cognitivas, levando em consideração o estudo de variações em bandas de frequências.

No grupo treinado, para os ritmos *Theta* e *Hibeta*, foi identificado uma diminuição nos valores de P_{Total} , como é possível verificar nas Figuras 18 e 20, respectivamente. O teste estatístico de *Wilcoxon* revelou que a potência total é significativamente maior em *Theta*. O trabalho de Leins et al. (2007) mostra que a redução em potência nesses ritmos está relacionada diretamente funções cognitivas de memória e atenção. O mesmo também foi encontrado no trabalho de Putman et al. (2014), onde a relação entre esses ritmos, para registros em estado de repouso, é relacionada ao estado atencional e mostra que a razão entre estas fornece uma medida adequada para estudar diferenças individuais no controle atencional e, como tal, pode ser um biomarcador útil no estudo de funções cognitivas por treinamentos cognitivos, corroborando a hipótese apresentada nesta pesquisa (LEINS et al., 2007; PUTMAN et al., 2014).

O ritmo SMR medido para o grupo treinado (Figura 19), o resultado estatístico apresentou mudanças significantes no pós treinamento. O trabalho de Marlats et al. (2020) investigou a potência no SMR, durante o estado de repouso, antes e após um treinamento cognitivo e mostrou um aumento significativamente maior no pós treinamento e, adicionalmente descreveram melhoras em atenção sustentada em um acompanhamento de 1 mês (MARLATS et al., 2020). No trabalho de Kouzak et al. (2018) um estudo randomizado controlado por placebo aplicado em 17 sujeitos, mostrou que o grupo experimental expressou ativação significativa no SMR e apresentou melhora no desempenho da memória de trabalho após o treinamento (KOUZAK et al., 2018). Resultados semelhantes também foram encontrados no trabalho de Rajabi, Pakize e Moradi (2020), onde foi examinado o efeito da NFB e do treinamento cognitivo a partir de um estudo duplo-cego. A pesquisa foi realizada em um grupo de 32 sujeitos com idades entre 10 e 20 anos e as análises pós treinamento revelaram um aumento da atividade sensoriomotora nos participantes treinados e melhora na escala de avaliação cognitiva utilizada (RAJABI; PAKIZE; MORADI, 2020).

Nos dados apresentados para o grupo controle, Figuras 18 e 20 podemos observar que não houve mudanças significativas nas variações das bandas *Theta* e *HiBeta*, para o SMR nota-se uma pequena mudança no pós período de treinamento, porém menor que apresentada para o grupo experimental (Figura 19 e Figura 17).

Como tal, a maioria dos estudos de treinamento cognitivo relataram melhorias significativas relacionadas ao treinamento em tarefas treinadas como por exemplo, tempo de reação mais rápido e precisão, ou seja, participantes treinados demonstraram melhor desempenho em tarefas treinadas no pós-teste do que no pré-teste em comparação com os participantes de um grupo controle e ganhos de desempenho em tarefas cognitivas treinadas sugerem a transferência para

outras tarefas cognitivas (HEINZEL et al., 2018; ROSE et al., 2015; SANDBERG et al., 2014). Além disso, estes estudos relatam que os resultados obtidos pelo treinamento também variam em função das diferenças individuais em fatores como idade, capacidade inicial, motivação, entendimento correto da tarefa e predisposição genética (KÖNEN; STROBACH; KARBACH, 2021).

6 Conclusão

Este trabalho descreve os efeitos do TC com NFB de operados de alto desempenho, utilizando a HHSa. Avaliamos os efeitos sob os ritmos *Theta*, *SMR* e *HiBeta* para verificar diferenças comportamentais entre antes e depois da aplicação do treinamento a partir do resultados obtidos pela HHSa.

O objetivo de observar uma variação de desempenho nas bandas de frequências oscilatórias através do método de extração usando a HHSa foi contemplado pelo protocolo proposto para esse procedimento experimental, mostrando-se eficaz nesse processo. Os resultados presentes nessa pesquisa demonstram a eficácia da HHSa na análise das atividades oscilatórias de EEG e fornecem elementos para considerar esta abordagem uma potencial ferramenta no estudo do sinal, contribuindo também para uma melhor compreensão a respeito deste método.

Com relação ao TC, as análises dos dados de EEG de operadores treinados foram acompanhadas de comparações e discussões com os dados de operadores não-treinados (grupo controle), procurando-se mitigar assim o efeito do treinamento. As maiores mudanças foram encontradas para o grupo treinado, em nível significativo, quando comparado às diferenças encontradas para o grupo controle. Observamos que tais diferenças conversam diretamente treinamento cognitivo. Dentre as análises executadas, algumas diferenças práticas sutis foram percebidas para o grupo controle, observou-se diferenças levemente positivas ou neutras. Essas diferenças podem ser fruto de variações estatísticas normais ou influência de variáveis ambientais. Dessa forma, conclui-se que os resultados indicam a efetividade do treinamento.

6.1 Trabalhos Futuros

Como trabalhos futuros, é pretendido aumentar a base de dados para implementação em um classificador, a partir das características obtidas pela HHSa. Também pretende-se realizar o estudo do sinal obtido durante a sessão de 60min no simulador e adicionar mais métodos estatísticas nos dados. Para o TC, considerando os resultados obtidos, está se propondo a ampliação do número de indivíduos, assim como a extensão da duração de tempo do treinamento, a quantidade de sessões e intervalo de tempo entre essas. Seria interessante também o protocolo ser executado em condições mais uniformes para que se possa aumentar o nível de assertividade nas comparações, por exemplo: mesmo local de aplicação e grupo controle passando por uma simulação do treinamento.

Referências

- ARDILA, A.; BERNAL, B.; ROSSELLI, M. How localized are language brain areas? a review of brodmann areas involvement in oral language. *Archives of Clinical Neuropsychology*, Oxford University Press, v. 31, n. 1, p. 112–122, 2016. Citado na página 26.
- BREAKSPEAR, M. Dynamic models of large-scale brain activity. *Nature neuroscience*, Nature Publishing Group, v. 20, n. 3, p. 340–352, 2017. Citado na página 18.
- BREHMER, Y. et al. Plasticity of brain and cognition in older adults. *Psychological research*, Springer, v. 78, n. 6, p. 790–802, 2014. Citado na página 16.
- BREHMER, Y.; WESTERBERG, H.; BÄCKMAN, L. Working-memory training in younger and older adults: training gains, transfer, and maintenance. *Frontiers in human neuroscience*, Frontiers, v. 6, p. 63, 2012. Citado na página 25.
- BUZSÁKI, G.; MIZUSEKI, K. The log-dynamic brain: how skewed distributions affect network operations. *Nature Reviews Neuroscience*, Nature Publishing Group, v. 15, n. 4, p. 264–278, 2014. Citado na página 18.
- CAMERON, J. et al. Prospective memory training to improve heart failure self-care (prometheus): study protocol for a randomised controlled trial. *Trials*, BioMed Central, v. 16, n. 1, p. 1–14, 2015. Citado na página 16.
- CANDY, C. J. *Signal Processing: The Model-based Approach*. [S.l.]: Series in Electrical Engineering, 1988. Citado 2 vezes nas páginas 24 e 25.
- CLARKE, S. E.; LONGTIN, A.; MALER, L. Contrast coding in the electrosensory system: parallels with visual computation. *Nature Reviews Neuroscience*, Nature Publishing Group, v. 16, n. 12, p. 733–744, 2015. Citado na página 18.
- COLE, S. R. et al. Nonsinusoidal beta oscillations reflect cortical pathophysiology in parkinson's disease. *Journal of Neuroscience*, Soc Neuroscience, v. 37, n. 18, p. 4830–4840, 2017. Citado na página 47.
- FELL, J. et al. Eeg analysis with nonlinear deterministic and stochastic methods: a combined strategy. *Acta neurobiologiae experimentalis*, v. 60, n. 1, p. 87–108, 2000. Citado na página 24.
- FLANDRIN, P. *Time-frequency/time-scale analysis*. [S.l.]: Academic press, 1998. Citado na página 17.
- GE, S. et al. Technology-based cognitive training and rehabilitation interventions for individuals with mild cognitive impairment: a systematic review. *BMC geriatrics*, BioMed Central, v. 18, n. 1, p. 1–19, 2018. Citado na página 25.
- HEINZEL, S. et al. Neural correlates of working memory deficits and associations to response inhibition in obsessive compulsive disorder. *NeuroImage: Clinical*, Elsevier, v. 17, p. 426–434, 2018. Citado na página 50.
- HOU, T. Y.; SHI, Z.; TAVALLALI, P. Sparse time frequency representations and dynamical systems. *arXiv preprint arXiv:1312.0202*, 2013. Citado na página 21.

- HSU, H.-T. et al. Analyses of eeg oscillatory activities during slow and fast repetitive movements using holo-hilbert spectral analysis. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 26, n. 9, p. 1659–1668, 2018. Citado 3 vezes nas páginas 21, 47 e 48.
- HU, L.; XIE, Y.; SUN, G. Computer-aided cognitive training based on electroencephalography-neurofeedback for english learning. *Educational Sciences: Theory & Practice*, v. 18, n. 5, 2018. Citado na página 25.
- HUANG, N. E. et al. On holo-hilbert spectral analysis: a full informational spectral representation for nonlinear and non-stationary data. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, The Royal Society Publishing, v. 374, n. 2065, p. 20150206, 2016. Citado 5 vezes nas páginas 17, 18, 20, 21 e 47.
- HUANG, N. E. et al. The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences*, The Royal Society, v. 454, n. 1971, p. 903–995, 1998. Citado na página 21.
- HUANG, N. E. et al. On instantaneous frequency. *Advances in adaptive data analysis*, World Scientific, v. 1, n. 02, p. 177–229, 2009. Citado na página 17.
- HYAFIL, A. Misidentifications of specific forms of cross-frequency coupling: three warnings. *Frontiers in neuroscience*, Frontiers, v. 9, p. 370, 2015. Citado na página 47.
- JUAN, C.-H. et al. Revealing the dynamic nature of amplitude modulated neural entrainment with holo-hilbert spectral analysis. *Frontiers in Neuroscience*, Frontiers, p. 977, 2021. Citado 2 vezes nas páginas 18 e 47.
- KARBACH, J.; VERHAEGHEN, P. Making working memory work: a meta-analysis of executive-control and working memory training in older adults. *Psychological science*, Sage Publications Sage CA: Los Angeles, CA, v. 25, n. 11, p. 2027–2037, 2014. Citado na página 16.
- KÖNEN, T.; STROBACH, T.; KARBACH, J. Working memory training. In: *Cognitive Training*. [S.l.]: Springer, 2021. p. 155–167. Citado na página 50.
- KOUZAK, C. d. P. V. et al. Smr neurofeedback training facilitates working memory performance in healthy older adults: A behavioral and eeg study. *Frontiers in behavioral neuroscience*, Frontiers, p. 321, 2018. Citado na página 49.
- KULKARNI, N. et al. A review on eeg based stress monitoring system using deep learning approach. *Mukt Shabd J*, v. 9, p. 1317–1325, 2020. Citado na página 26.
- LEE, T.-M. et al. Study of heart-rate variability in a video task using holo-hilbert spectral analysis. *Biomedical Signal Processing and Control*, Elsevier, v. 71, p. 103229, 2022. Citado na página 17.
- 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 49.
- LI, S.-C. et al. Transformations in the couplings among intellectual abilities and constituent cognitive processes across the life span. *Psychological science*, SAGE Publications Sage CA: Los Angeles, CA, v. 15, n. 3, p. 155–163, 2004. Citado na página 25.

LIANG, W.-K. et al. Frontoparietal beta amplitude modulation and its interareal cross-frequency coupling in visual working memory. *Neuroscience*, Elsevier, v. 460, p. 69–87, 2021. Citado na página 18.

LÓPEZ-AZCÁRATE, J. et al. Coupling between beta and high-frequency activity in the human subthalamic nucleus may be a pathophysiological mechanism in parkinson's disease. *Journal of Neuroscience*, Soc Neuroscience, v. 30, n. 19, p. 6667–6677, 2010. Citado na página 22.

LÖVDÉN, M. et al. Training-induced compensation versus magnification of individual differences in memory performance. *Frontiers in human neuroscience*, Frontiers, v. 6, p. 141, 2012. Citado na página 25.

MARLATS, F. et al. *Treinamento de neurofeedback SMR/theta melhora o desempenho cognitivo e a atividade de EEG em idosos com comprometimento cognitivo leve: um estudo piloto*. [S.l.]: Fronteiras, 2020. 147 p. Citado na página 49.

MARZBANI, H.; MARATEB, H. R.; MANSOURIAN, M. Neurofeedback: a comprehensive review on system design, methodology and clinical applications. *Basic and clinical neuroscience*, Iranian Neuroscience Society, v. 7, n. 2, p. 143, 2016. Citado na página 22.

MCEWEN, J. A.; ANDERSON, G. B. Modeling the stationarity and gaussianity of spontaneous electroencephalographic activity. *IEEE transactions on Biomedical Engineering*, IEEE, n. 5, p. 361–369, 1975. Citado na página 24.

MORADI, N. et al. Holo-hilbert spectral-based noise removal method for eeg high-frequency bands. *Journal of neuroscience methods*, Elsevier, v. 368, p. 109470, 2022. Citado 2 vezes nas páginas 16 e 17.

NESTORIUC, Y. et al. Biofeedback treatment for headache disorders: a comprehensive efficacy review. *Applied psychophysiology and biofeedback*, Springer, v. 33, n. 3, p. 125–140, 2008. Citado na página 16.

NGUYEN, K. T. et al. Unraveling nonlinear electrophysiologic processes in the human visual system with full dimension spectral analysis. *Scientific reports*, Nature Publishing Group, v. 9, n. 1, p. 1–13, 2019. Citado na página 18.

NIEDERMEYER, E.; ERNST, F. L. da. *Electroencephalography: basic principles, clinical applications, and related fields*. [S.l.]: Lippincott Williams & Wilkins, 2005. Citado na página 17.

PARK, D. C. et al. The impact of sustained engagement on cognitive function in older adults: The synapse project. *Psychological science*, Sage Publications Sage CA: Los Angeles, CA, v. 25, n. 1, p. 103–112, 2014. Citado na página 25.

PARSONS, B.; FAUBERT, J. Enhancing learning in a perceptual-cognitive training paradigm using eeg-neurofeedback. *Scientific Reports*, Nature Publishing Group, v. 11, n. 1, p. 1–10, 2021. Citado na página 25.

PFURTSCHELLER, G.; NEUPER, C. Motor imagery and direct brain-computer communication. *Proceedings of the IEEE*, IEEE, v. 89, n. 7, p. 1123–1134, 2001. Citado na página 17.

PRIORI, A. et al. Rhythm-specific pharmacological modulation of subthalamic activity in parkinson's disease. *Experimental neurology*, Elsevier, v. 189, n. 2, p. 369–379, 2004. Citado na página 22.

- PUTMAN, P. et al. Eeg theta/beta ratio as a potential biomarker for attentional control and resilience against deleterious effects of stress on attention. *Cognitive, Affective, & Behavioral Neuroscience*, Springer, v. 14, n. 2, p. 782–791, 2014. Citado na página 49.
- RAJABI, S.; PAKIZE, A.; MORADI, N. Effect of combined neurofeedback and game-based cognitive training on the treatment of adhd: A randomized controlled study. *Applied Neuropsychology: Child*, Taylor & Francis, v. 9, n. 3, p. 193–205, 2020. Citado 2 vezes nas páginas 25 e 49.
- ROSE, N. S. et al. Cognitive and neural plasticity in older adults' prospective memory following training with the virtual week computer game. *Frontiers in Human Neuroscience*, Frontiers, v. 9, p. 592, 2015. Citado na página 50.
- SANDBERG, P. et al. Executive process training in young and old adults. *Aging, Neuropsychology, and Cognition*, Taylor & Francis, v. 21, n. 5, p. 577–605, 2014. Citado na página 50.
- SANEI, S.; CHAMBERS, J. A. *EEG signal processing*. [S.l.]: John Wiley & Sons, 2013. Citado na página 24.
- SANNELLI, C. et al. A large scale screening study with a smr-based bci: Categorization of bci users and differences in their smr activity. *PLoS One*, Public Library of Science San Francisco, CA USA, v. 14, n. 1, p. e0207351, 2019. Citado na página 17.
- SEUNG, S. *Connectome: How the brain's wiring makes us who we are*. [S.l.]: HMH, 2012. Citado na página 17.
- SÖRNMO, L.; LAGUNA, P. *Bioelectrical signal processing in cardiac and neurological applications*. [S.l.]: Academic Press, 2005. v. 8. Citado 2 vezes nas páginas 23 e 24.
- SPORNS, O. *Discovering the human connectome*. [S.l.]: MIT press, 2012. Citado na página 17.
- STRIMBU, K.; TAVEL, J. *What are biomarkers?(2010) Curr. Opin. HIV AIDS*, 5. [S.l.]: MIT press, 2010. Citado na página 17.
- TANZER, I. O. et al. Numerical modeling in electro-and magnetoencephalography. Helsinki University of Technology, 2006. Citado na página 21.
- TEPLAN, M. et al. Fundamentals of eeg measurement. *Measurement science review*, v. 2, n. 2, p. 1–11, 2002. Citado na página 22.
- THOMPSON, I. et al. Guideline for the management of clinically localized prostate cancer: 2007 update. *The Journal of urology*, Wolters Kluwer Philadelphia, PA, v. 177, n. 6, p. 2106–2131, 2007. Citado na página 16.
- TIMMERS, D. Chapter six - treating attention deficits and impulse control. In: CANTOR, D. S.; EVANS, J. R. (Ed.). *Clinical Neurotherapy*. Boston: Academic Press, 2014. p. 139 – 169. ISBN 978-0-12-396988-0. Disponível em: <<http://www.sciencedirect.com/science/article/pii/B9780123969880000064>>. Citado na página 16.
- TIWARI, U.; CHAKRABORTY, R.; KOPPARAPU, S. K. Spectro temporal eeg biomarkers for binary emotion classification. *arXiv preprint arXiv:2202.03271*, 2022. Citado na página 48.

- TYNER, F. S.; KNOTT, J. R.; MAYER, W. B. *Fundamentals of EEG technology: Clinical correlates*. [S.l.]: Lippincott Williams & Wilkins, 1989. v. 2. Citado na página 22.
- WEBER, E. et al. Predicting successful learning of smr neurofeedback in healthy participants: methodological considerations. *Applied Psychophysiology and Biofeedback*, Springer, v. 36, n. 1, p. 37–45, 2011. Citado na página 30.
- WILCOXON, F. Individual comparisons by ranking methods. In: *Breakthroughs in statistics*. [S.l.]: Springer, 1992. p. 196–202. Citado na página 36.
- WILLIAMSON, D. F.; PARKER, R. A.; KENDRICK, J. S. The box plot: a simple visual method to interpret data. *Annals of internal medicine*, American College of Physicians, v. 110, n. 11, p. 916–921, 1989. Citado na página 37.
- WILLIS, S. L.; BELLEVILLE, S. Cognitive training in later adulthood. In: *Handbook of the psychology of aging*. [S.l.]: Elsevier, 2016. p. 219–243. Citado na página 16.
- WU, Z.; HUANG, N. E. On the filtering properties of the empirical mode decomposition. *Advances in Adaptive Data Analysis*, World Scientific, v. 2, n. 04, p. 397–414, 2010. Citado na página 21.
- ZINKE, K. et al. Working memory training and transfer in older adults: effects of age, baseline performance, and training gains. *Developmental psychology*, American Psychological Association, v. 50, n. 1, p. 304, 2014. Citado na página 25.

Apêndices

APÊNDICE A – PARECER DO COMITÊ DE ÉTICA

PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: Utilizando Treinamento Cognitivo para o Desenvolvimento de Operadores de Alto Desempenho

Pesquisador: Bruno Duarte Gomes

Área Temática:

Versão: 2

CAAE: 11015918.4.0000.0018

Instituição Proponente: Instituto de Ciências Biológicas

Patrocinador Principal: VALE S.A.
ASSOCIACAO INSTITUTO TECNOLOGICO VALE - ITV

DADOS DO PARECER

Número do Parecer: 3.601.269

Apresentação do Projeto:

Em ambientes de trabalho que requerem a operação de equipamentos de grande porte, como o caso da indústria da mineração, indivíduos precisam se adaptar às altas demandas de operação desses equipamentos para manter os níveis de segurança e produtividade elevados. Este ambiente de trabalho solicita uma alta demanda de suas habilidades operacionais e cognitivas como memória de trabalho e atenção espacial. Uma maneira adequada de se adequar estas capacidades cognitivas a estas altas demandas de produtividade através da aplicação de rotinas de treinamento tradicionais, isto é, com simuladores de realidade virtual (RV) e também com rotinas de treinamento cognitivo, de modo a se capacitar os recursos humanos da empresa. Em relação à capacitação, um ponto comum em debates acerca do aumento de produtividade é o de que os potenciais de um indivíduo devem ser particularizados e desenvolvidos, pois cada indivíduo possui seu ponto forte em termos de tempo de trabalho, assertividade e aprendizado de novas tarefas; principalmente, naqueles envolvidos em atividade de alta demanda. Neste contexto, a missão deste projeto inovadora por abordar o uso da técnica de treinamento cognitivo conjuntamente com simuladores de RV na capacitação dos operadores de máquinas de grande porte da VALE. Neste contexto, este projeto de pesquisa visa o estudo e aplicação de técnicas de treinamento cognitivo visando a complementação ou associação aos métodos tradicionais de treinamento de pessoal realizados atualmente nos simuladores de RV da VALE (p.ex. simulador de escavadeira). Assim, para se atingir estes objetivos serão exploradas

Endereço: Rua Augusto Corrêa nº 01- Campus do Guamá, UFPA- Faculdade de Enfermagem do ICS - sala 13 - 2º and.

Bairro: Guamá

CEP: 66.075-110

UF: PA

Município: BELEM

Telefone: (91)3201-7735

Fax: (91)3201-8028

E-mail: cepccs@ufpa.br

Continuação do Parecer: 3.601.269

tcnicas de anlise de desempenho comportamental e registros eletrofisiologicos usando o Eletroencefalografia (EEG). E como resultado, acredita-se ser possvel obter um incremento de habilidades cognitivas relacionadas a funes executivas como memria de trabalho, para um grupo de operadores de modo seguro e saudvel.

Objetivo da Pesquisa:

Objetivo Primário: O objetivo geral deste projeto de pesquisa o estudo e aplicao de tcnicas de treinamento cognitivo visando a complementao ou associao aos mtodos tradicionais de treinamento de pessoal realizados atualmente nos simuladores de realidade virtual da VALE (p.ex. simulador de escavadeira). Acredita-se que esta nova abordagem possa trazer ganhos no processo de capacitao resultando em maior segurana e produtividade.

Objetivo Secundário: Os objetivos especificos sero cumpridos de forma a atender o objetivo geral deste projeto, e so eles: 1. Estudar e aplicar pelo menos uma metodologia de treinamento cognitivo juntamente com as metodologias de capacitao existentes no S11D, de modo que esta associao aprimore s habilidades operacionais e cognitivas de um grupo de operadores que faro parte do estudo deste projeto;2. Integrar o treinamento cognitivo ao treinamento tradicional (isto , com simuladores) do S11D, de modo que ele possa ser realizado dentro de um tempo considerado aceitvel ;3. Definir, de acordo com os resultados obtidos da pesquisa, qual o melhor momento para aplicao do treinamento cognitivo, isto , se o mesmo ser aplicado antes do treinamento no simulador, aps o treinamento no simulador ou mesmo antes e depois do treinamento tradicional.

Avaliação dos Riscos e Benefícios:

Riscos: O nico risco previsto um leve desconforto fsico durante o treinamento, uma vez que o headset (aparelho que mede o EEG) utilizado para captura de dados de EEG possui peso aproximado de 500 gramas. **Benefícios:** Aumento da segurana e produtividade de operadores de mquinas de grande porte.

Comentários e Considerações sobre a Pesquisa:

O protocolo encaminhado, nesta versão, dispõe de metodologia e critérios definidos conforme resolução 466/12 do CNS/MS. trata da resolução de pendências descritas no parecer nº3.487.867. considerado aceito por este colegiado.

Endereço: Rua Augusto Corrêa nº 01- Campus do Guamá ,UFPA- Faculdade de Enfermagem do ICS - sala 13 - 2º and.
Bairro: Guamá **CEP:** 66.075-110
UF: PA **Município:** BELEM
Telefone: (91)3201-7735 **Fax:** (91)3201-8028 **E-mail:** cepccs@ufpa.br

UFPA - INSTITUTO DE
CIÊNCIAS DA SAÚDE DA
UNIVERSIDADE FEDERAL DO
PARÁ



Continuação do Parecer: 3.601.269

Considerações sobre os Termos de apresentação obrigatória:

Os termos apresentados , nesta versão, contemplam os sugeridos pelo sistema CEP/CONEP.

Conclusões ou Pendências e Lista de Inadequações:

Diante do exposto somos pela aprovação do protocolo. Este é nosso parecer, SMJ.

Considerações Finais a critério do CEP:

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_940231.pdf	18/09/2019 14:06:56		Aceito
Outros	TermodeAceitedoOrientador.pdf	02/04/2019 17:17:56	Bruno Duarte Gomes	Aceito
Outros	ProjetoPOADparaComitedeEtica.doc	02/04/2019 17:17:15	Bruno Duarte Gomes	Aceito
Outros	Termo_de_Consentimento_da_Instituicao.jpg	14/02/2019 15:25:26	Bruno Duarte Gomes	Aceito
Outros	Termo_de_Compromisso_do_Pesquisador.jpg	14/02/2019 15:24:06	Bruno Duarte Gomes	Aceito
Outros	DeclaracaodelsencaodeonusFinanceiroaUFPA.jpg	23/01/2019 12:00:42	Bruno Duarte Gomes	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLEComiteEtica.docx	21/12/2018 16:09:09	Bruno Duarte Gomes	Aceito
Projeto Detalhado / Brochura Investigador	ProjetoDetalhadoComitedeEtica.pdf	17/12/2018 15:11:06	Bruno Duarte Gomes	Aceito
Folha de Rosto	Folha1_ProjS11D.pdf	17/12/2018 10:49:17	Bruno Duarte Gomes	Aceito

Situação do Parecer:

Aprovado

Necessita Apreciação da CONEP:

Não

Endereço: Rua Augusto Corrêa nº 01- Campus do Guamá ,UFPA- Faculdade de Enfermagem do ICS - sala 13 - 2º and.

Bairro: Guamá

CEP: 66.075-110

UF: PA

Município: BELEM

Telefone: (91)3201-7735

Fax: (91)3201-8028

E-mail: cepccs@ufpa.br

UFPA - INSTITUTO DE
CIÊNCIAS DA SAÚDE DA
UNIVERSIDADE FEDERAL DO
PARÁ



Continuação do Parecer: 3.601.269

BELEM, 26 de Setembro de 2019

Assinado por:
Wallace Raimundo Araujo dos Santos
(Coordenador(a))

Endereço: Rua Augusto Corrêa nº 01- Campus do Guamá ,UFPA- Faculdade de Enfermagem do ICS - sala 13 - 2º and.
Bairro: Guamá **CEP:** 66.075-110
UF: PA **Município:** BELEM
Telefone: (91)3201-7735 **Fax:** (91)3201-8028 **E-mail:** cepccs@ufpa.br

Anexos

ANEXO A – Mapas espectrais para Grupo Controle

Figura 21 – Mapas espectrais GC - Sujeito 1

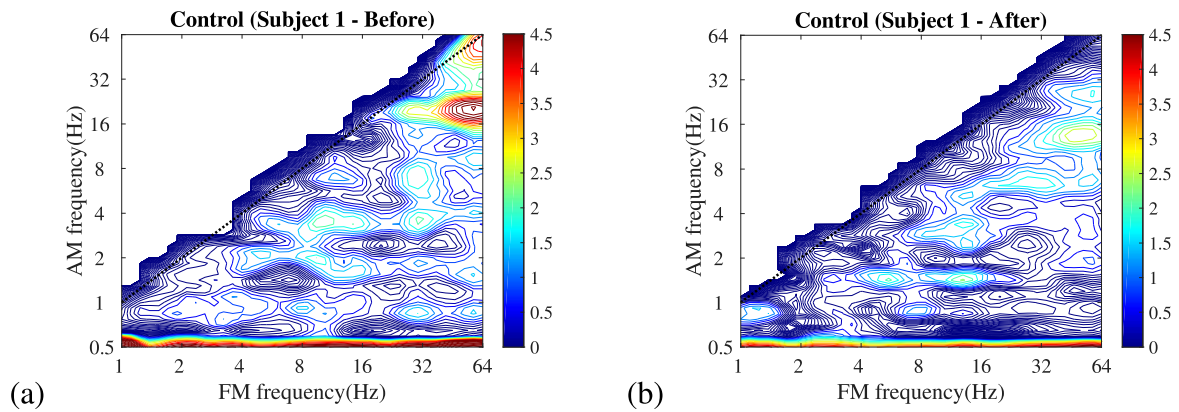


Figura 22 – Mapas espectrais GC - Sujeito 2

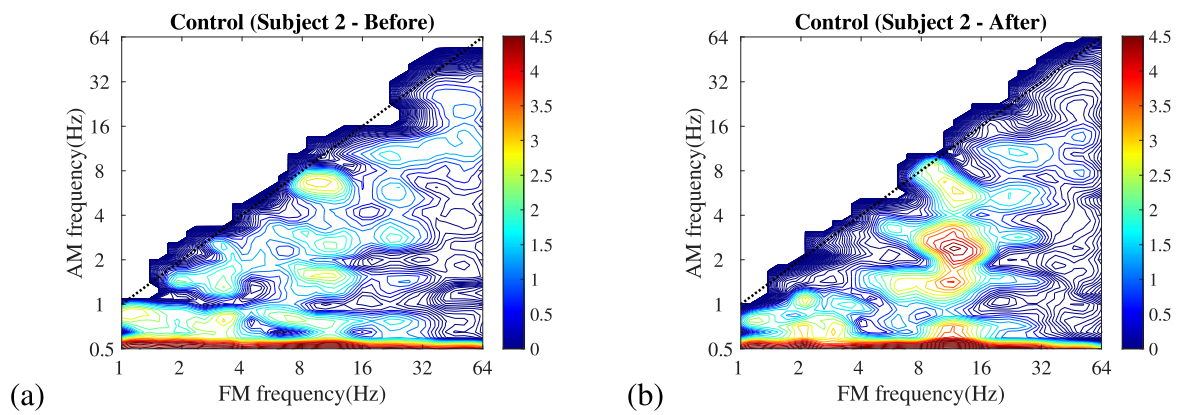


Figura 23 – Mapas espectrais GC - Sujeito 3

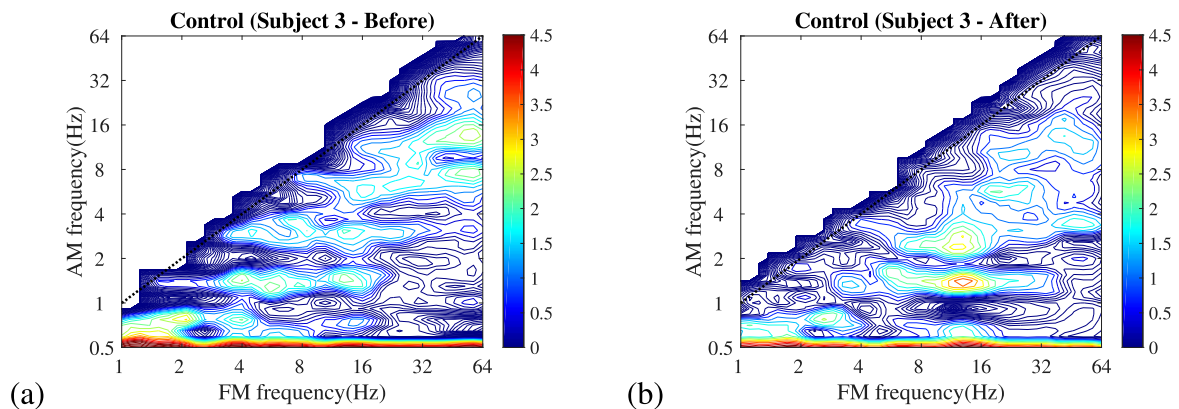


Figura 24 – Mapas espectrais GC - Sujeito 4

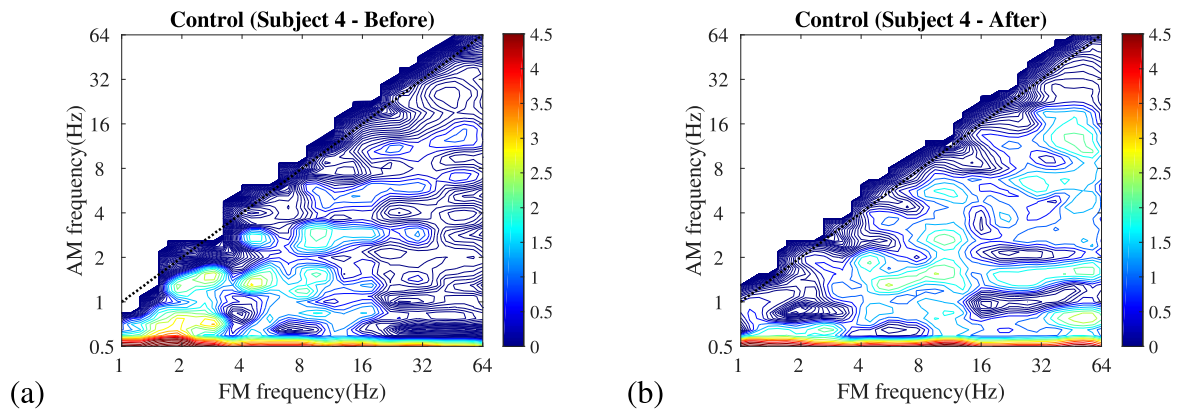


Figura 25 – Mapas espectrais GC - Sujeito 5

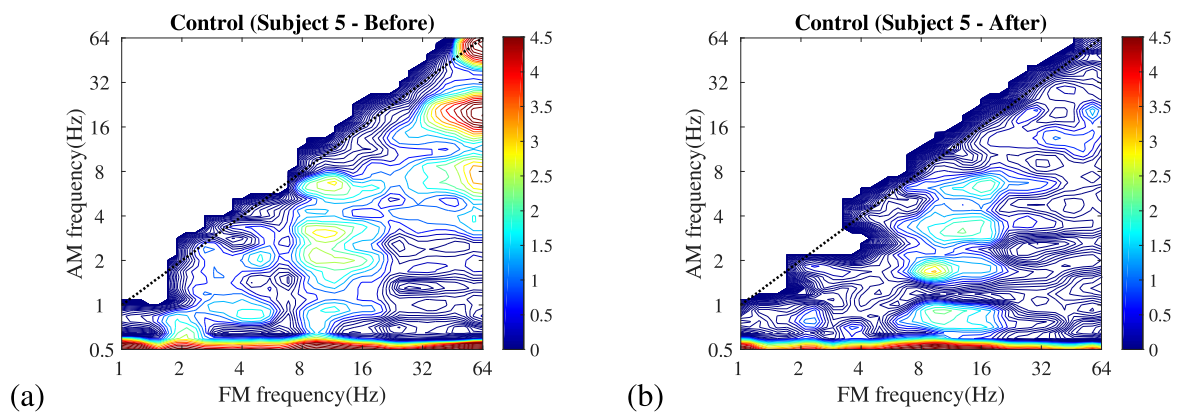


Figura 26 – Mapas espectrais GC - Sujeito 6

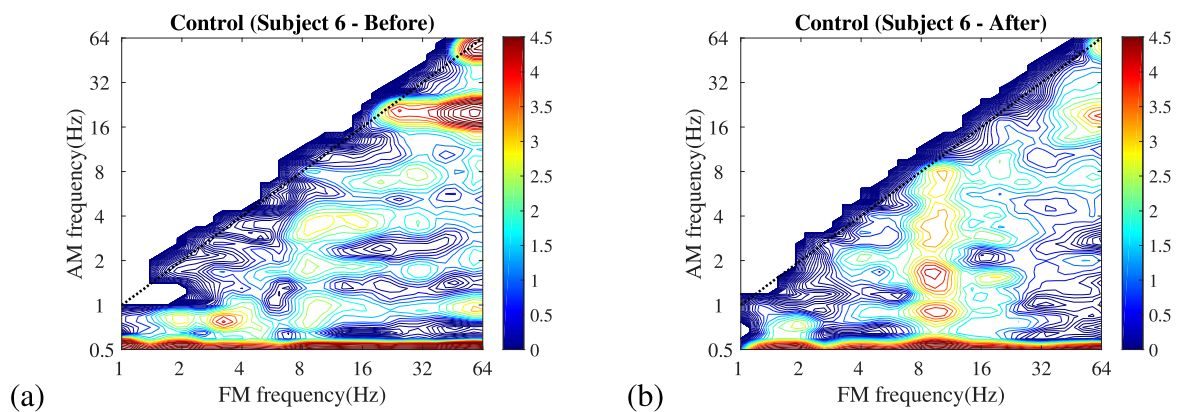


Figura 27 – Mapas espectrais GC - Sujeito 7

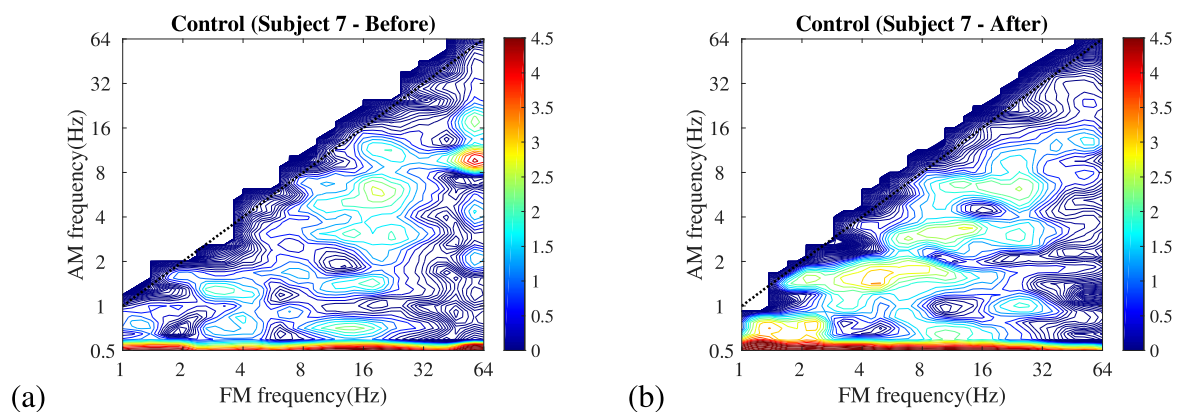
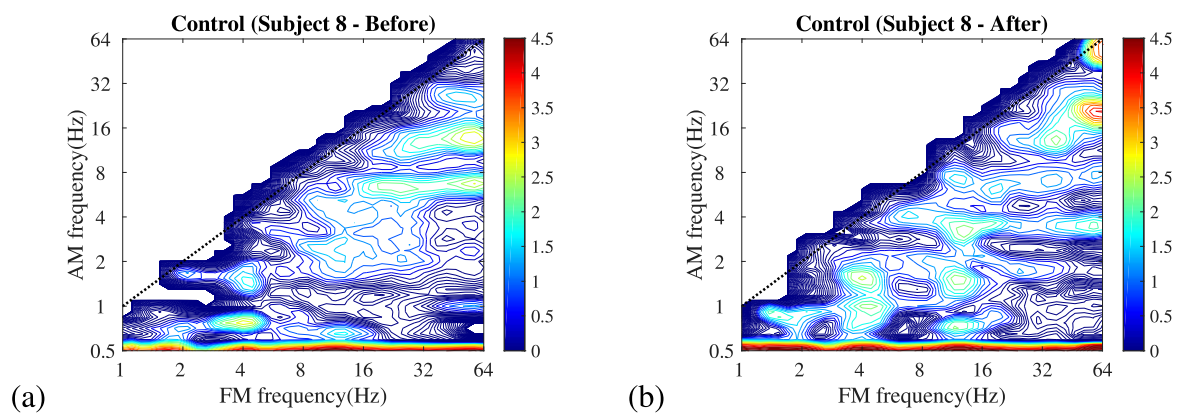


Figura 28 – Mapas espectrais GC - Sujeito 8



ANEXO B – Mapas Espectrais para Grupo Treinado

Figura 29 – Mapas espectrais GT - Sujeito 1

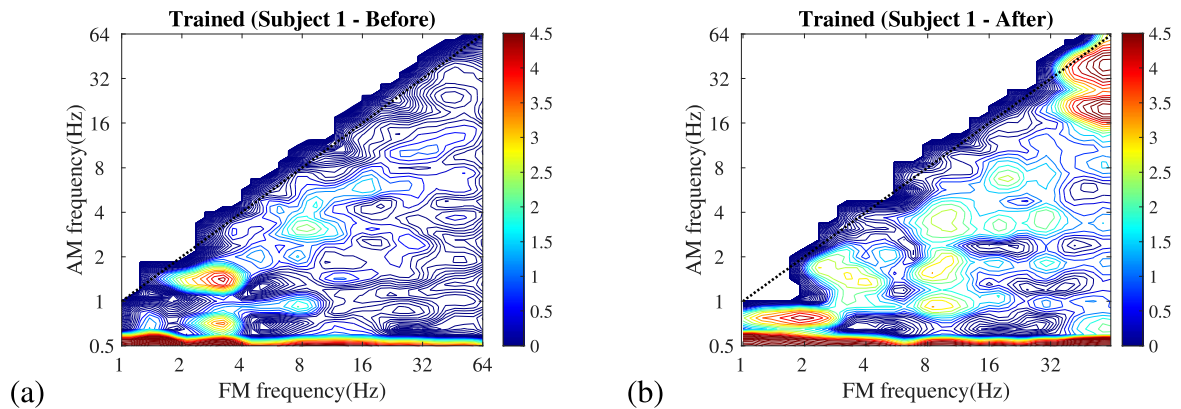


Figura 30 – Mapas espectrais GT - Sujeito 2

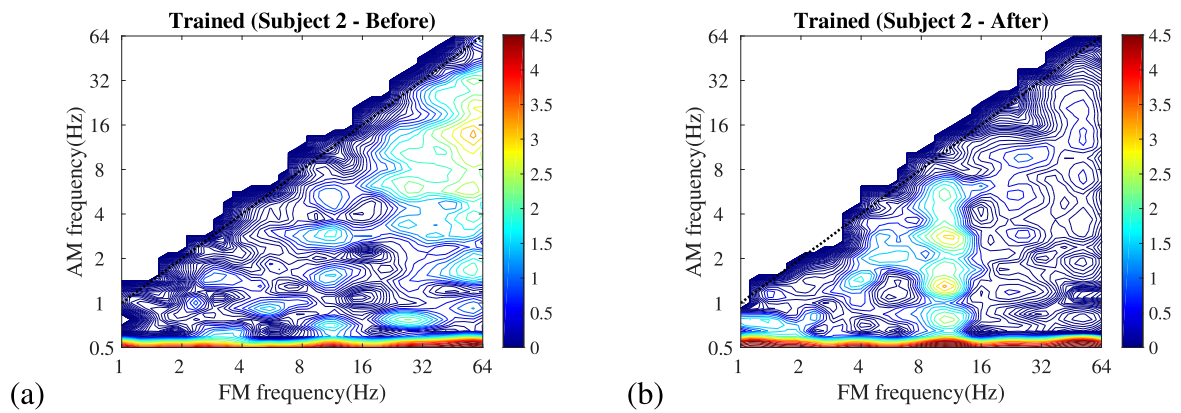


Figura 31 – Mapas espectrais GT - Sujeito 3

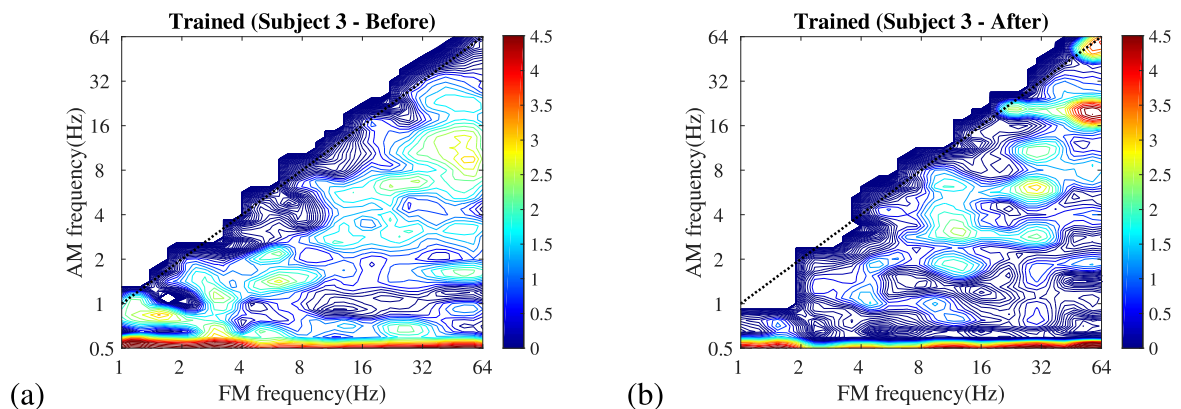


Figura 32 – Mapas espectrais GT - Sujeito 4

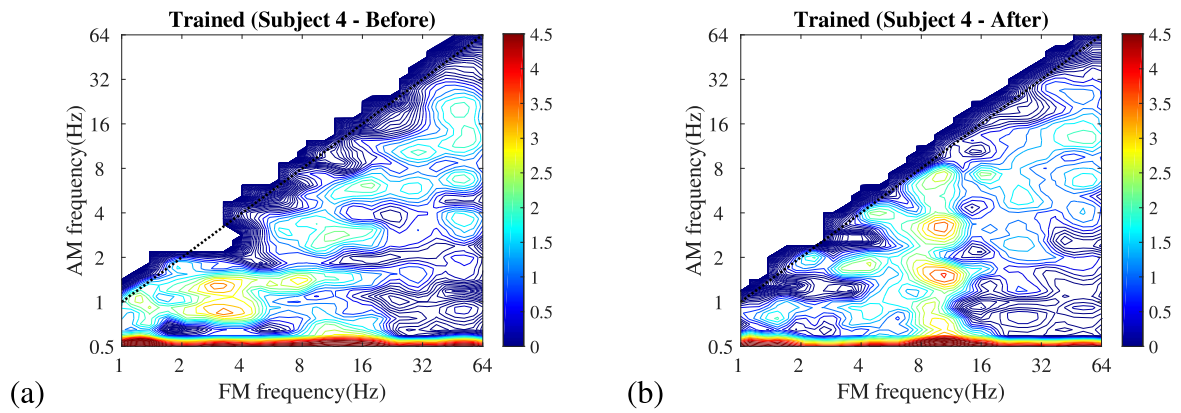


Figura 33 – Mapas espectrais GT - Sujeito 5

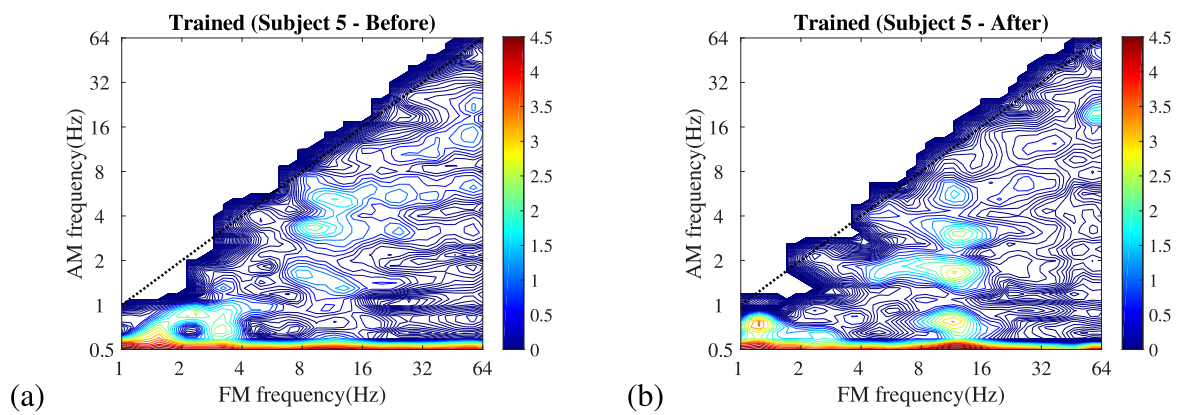


Figura 34 – Mapas espectrais GT - Sujeito 6

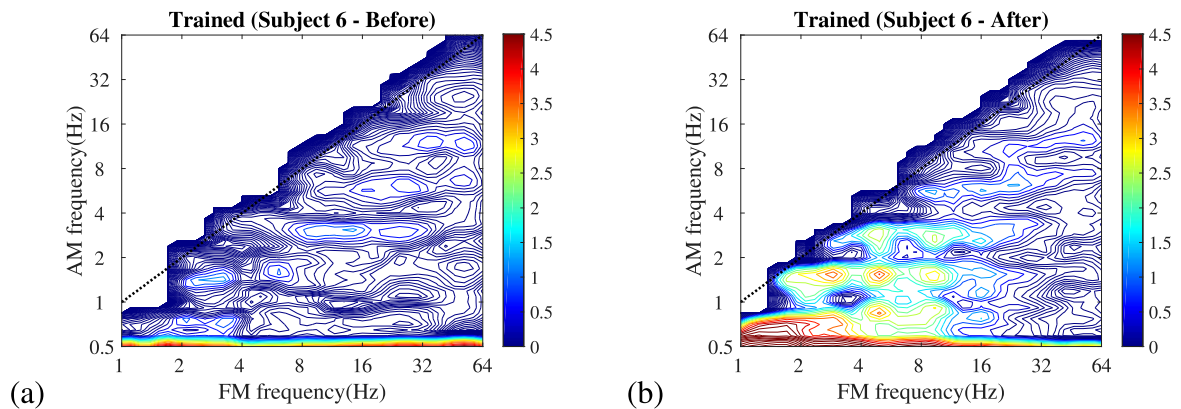


Figura 35 – Mapas espectrais GT - Sujeito 7

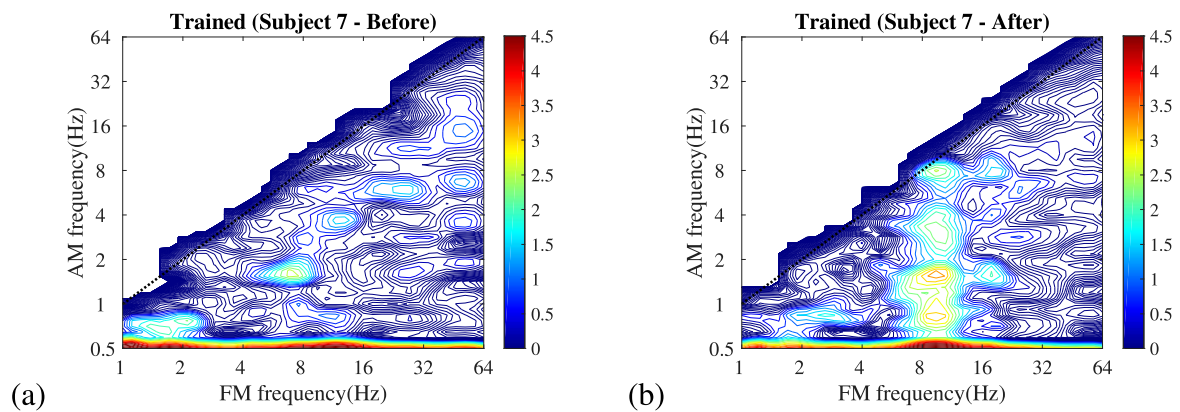


Figura 36 – Mapas espectrais GT - Sujeito 8

