



CENTRO UNIVERSITÁRIO SENAI CIMATEC

PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM

COMPUTACIONAL E TECNOLOGIA INDUSTRIAL

Doutorado em Modelagem Computacional e Tecnologia Industrial

Tese de doutorado

**Amplitude da flutuação e correlação cruzada em sinais
eletroencefalográficos: uma modelagem com a função
de flutuação rms e o coeficiente de correlação cruzada
 ρ_{DCCA}**

Apresentada por: Florêncio Mendes Oliveira Filho

Orientador: Ivan Costa da Cunha Lima

Co-orientador: Gilney Figueira Zebende

Abril de 2019

Florêncio Mendes Oliveira Filho

Amplitude da flutuação e correlação cruzada em sinais eletroencefalográficos: uma modelagem com a função de flutuação rms e o coeficiente de correlação cruzada ρ_{DCCA}

Tese de doutorado apresentada ao Programa de Pós-graduação em Modelagem Computacional e Tecnologia Industrial, Curso de Doutorado em Modelagem Computacional e Tecnologia Industrial do CENTRO UNIVERSITÁRIO SENAI CIMATEC, como requisito parcial para a obtenção do título de **Doutor em Modelagem Computacional e Tecnologia Industrial**.

Área de conhecimento: Sistemas complexos

Orientador: Ivan Costa da Cunha Lima

CENTRO UNIVERSITÁRIO SENAI CIMATEC

Co-orientador: Gilney Figueira Zebende

DEPARTAMENTO DE FÍSICA - UEFS

Nota sobre o estilo do PPGMCTI

Esta tese de doutorado foi elaborada considerando as normas de estilo (i.e. estéticas e estruturais) propostas aprovadas pelo colegiado do Programa de Pós-graduação em Modelagem Computacional e Tecnologia Industrial e estão disponíveis em formato eletrônico (*download* na Página Web http://ead.fieb.org.br/portal_faculdades/dissertacoes-e-teses-mcti.html ou solicitação via e-mail à secretaria do programa) e em formato impresso somente para consulta.

Ressalta-se que o formato proposto considera diversos itens das normas da Associação Brasileira de Normas Técnicas (ABNT), entretanto opta-se, em alguns aspectos, seguir um estilo próprio elaborado e amadurecido pelos professores do programa de pós-graduação supracitado.

Ficha catalográfica elaborada pela Biblioteca do Centro Universitário SENAI CIMATEC

O48a Oliveira Filho, Florêncio Mendes

Amplitude da flutuação e correlação cruzada em sinais eletroencefalográficos: uma modelagem com a função de flutuação rms e o coeficiente de correlação cruzada ρ DCCA / Florêncio Mendes Oliveira Filho. – Salvador, 2019.

117 f. : il. color.

Orientador: Prof. Dr. Ivan Costa da Cunha Lima.

Coorientador: Prof. Dr. Gilney Figueira Zebende.

Tese (Doutorado em Modelagem Computacional e Tecnologia Industrial) – Programa de Pós-Graduação, Centro Universitário SENAI CIMATEC, Salvador, 2019.

Inclui referências.

1. EEG. 2. Série temporal. 3. DFA. 4. ρ DCCA. I. Centro Universitário SENAI CIMATEC. II. Lima, Ivan Costa da Cunha. III. Zebende, Gilney Figueira. IV. Título.

CDD: 620.00113



Federação das Indústrias do Estado da Bahia

Centro Universitário SENAI CIMATEC

Doutorado em Modelagem Computacional e Tecnologia Industrial

A Banca Examinadora, constituída pelos professores abaixo listados, leu e aprovou a Tese de doutorado, intitulada "**Amplitude da flutuação e correlação cruzada em sinais eletroencefalográficos: uma modelagem com a função de flutuação rms e o coeficiente de correlação cruzada ρ_{DCCA}** ", apresentada no dia 25 de abril de 2019, como parte dos requisitos necessários para a obtenção do Título de Doutor em Modelagem Computacional e Tecnologia Industrial.

Orientador:

Prof. Dr. Ivan Costa da Cunha Lima
SENAI CIMATEC

Coorientador:

Prof. Dr. Gilney Figueira Zebende
UEFS

Membro Interno:

Prof. Dr. Alex Alisson Bandeira Santos
SENAI CIMATEC

Membro Interno:

Prof. Dr. Renelson Ribeiro Sampaio
SENAI CIMATEC

Membro Externo:

Prof. Dr. Juan Alberto Leyva Cruz
UEFS

Membro Externo:

Prof. Dr. Paulo Jorge Canas Rodrigues
UFBA

Dedico este trabalho primeiro a meu amigo e Pai Jeová Deus.
A minha mãe Maria de Lourdes, em memória, pelos ensinamentos passados. Uma
pessoa especial. Muitas Saudades!
Ao meu Pai Florêncio Mendes, pelo carinho.
A minha esposa Pollyana, pela paciência e contribuição na árdua jornada.
Aos meus filhos João Florêncio e Flora que entenderam por várias vezes a minha
ausência e souberam pacientemente aguardar.

Agradecimentos

Ao professor orientador e, principalmente amigo, Dr. Gilney Figueira Zebende, meu muito obrigado de coração. Poucos são tão privilegiados como eu por ter tido a sorte de conviver com uma pessoa tão generosa, dedicada e eficiente. A você Professor, meu muito obrigado mesmo. Sem a sua participação este projeto não teria existido.

Ao professor orientador Dr. Ivan Costa da Cunha Lima, pela amizade e incentivo à pesquisa. Um exemplo de pessoa. Muito obrigado.

Ao professor Dr. Juan Alberto Leyva Cruz, parceiro, incentivador, colaborador e amigo. A você professor, meu muito obrigado de coração.

Ao meu grupo de pesquisa sempre motivado: Dr. Arleys Pereiro Nunes de Castro, muito obrigado amigo. Sua colaboração foi fundamental na construção deste trabalho. Dr. Aloisio Machado da Silva Filho, Dr. Everaldo Freitas Guedes, Msc. Andrea de Almeida Brito, Msc. Basílio Fernandez.

Aos parceiros da cidade de Itaberaba / Centro Médico de Imagem Cardio Vida: Denize Mary Azevedo Oliveira Sá Teles - Secretária de Saúde, Irlis Azevedo Oliveira Sá Teles - Assistente Social, Daise Mary Azevedo Oliveira - Pesquisadora, Thais Mariana Oliveira - Pedagoga, Hérico Leite de Souza - Médico Cardiologista, Geanny Souza, Assistente Social - Gestora Hospitalar, Aline Souza dos Santos - Técnica de Enfermagem, Chris Borges - Pesquisadora.

Aos professores do MCTI.

A equipe do Centro Universitário SENAI CIMATEC em especial a Julie Miranda dos Santos.

Aos meus amigos do programa PPGMCTI.

Aos meus pais, Florêncio Mendes Oliveira e Maria de Lourdes Azevedo Oliveira, e aos meus irmãos, Denize, Daise, Deny, Marlon, Ismar, Júlio, Francisco e Deise. Conseguimos!

A todos que colaboraram para a execução deste trabalho.

Salvador, Brasil
25 de Abril de 2019

Florêncio Mendes Oliveira Filho

Resumo

Apesar das limitações de resolução espacial, a Eletroencefalografia (EEG) continua sendo uma ferramenta valiosa e atual para pesquisas e diagnósticos. Investigações associadas a distúrbios degenerativos do sistema neural: Alzheimer, doença de Parkinson, distúrbios relacionados a resposta motora e sobretudo processos cognitivos, estão relacionados com o uso do EEG. Com uma resolução temporal da ordem de milissegundos, a leitura do EEG se mostra mais eficiente quando comparado com a tomografia computadorizada e a ressonância magnética. Em termos clínicos a significância da aplicação remete a algumas anormalidades na leitura dos sinais, levando a considerar um certo grau de subjetividade no exame visual do traçado e comportamento. Independente do distúrbio que se pretende investigar ou processo degenerativo, e pelo fato do EEG apresentar uma boa resolução temporal, a amplitude do sinal torna-se muito importante para identificar desordens ocasionadas pela atividade elétrica do cérebro. Diante deste cenário, este trabalho pretende propor um modelo computacional, baseado na função de flutuação rms (raiz quadrática média), $F_{DFA}(n)$, para mensurar a amplitude da flutuação entre regiões distintas do encéfalo e interpretar de maneira auto-afim sua correlação cruzada. Como resultados, analisamos duas tarefas: uma primeira tarefa realizado por estímulos motores e uma segunda, estimulada pela leitura de um texto. Para estímulos motores, mostramos que as séries temporais complexas do EEG exibem flutuações características dependendo do canal analisado. A fim de demonstrar a eficácia da técnica proposta, analisamos quatro canais distintos aqui representados por F_332 , F_637 (região frontal da cabeça) e P_349 , F_654 (região parietal da cabeça). Verificamos que a amplitude da função rms F_{DFA} é maior para os canais frontais do que para os parietais. Para tabular melhor esta informação, foi calculado a diferença entre F_{DFA} (em escala logarítmica). Para o estímulo gerado pela leitura (cérebro treinado / cérebro não treinado), foram escolhidos 11 bio-eletrodos localizados nas regiões frontal, parietal, temporal e occipital do cérebro de duas pessoas. A diferença entre os indivíduos aparece para escalas de tempo $n < 128$ ($f > 1Hz$). Acredito que esse estudo possa trazer contribuições dos efeitos gerados pelos registros de EEG, acrescidos a metodologias existentes, assim como tornar-se um catalisador para estudos futuros que evidenciem a dinâmica das respostas motoras e cognitivas de humanos com complexos estímulos.

Palavras chave: EEG, Série Temporal, DFA , $\rho DCCA$

Abstract

Despite the limitations of spatial resolution, Electroencephalography (EEG) remains a valuable and current tool for research and diagnosis. Investigations associated with degenerative disorders of the neural system: Alzheimer's, Parkinson's disease, disorders related to motor response and mainly cognitive processes, are related to the use of EEG. With a temporal resolution of the order of milliseconds, the EEG reading is more efficient when compared with computed tomography and magnetic resonance imaging. In clinical terms, the significance of the application refers to some abnormalities in the reading of the signs, leading to consider a certain degree of subjectivity in the visual examination of the tracing and behavior. Regardless of the disorder to be investigated or the degenerative process, and because the EEG presents a good temporal resolution, the amplitude of the signal becomes very important to identify disorders caused by the electrical activity of the brain. Considering this scenario, this work intends to propose a computational model, based on the rms fluctuation function (mean square root), $F_{DFA}(n)$, to measure the amplitude of the fluctuation between distinct regions of the brain and to interpret in a self -About its cross-correlation. As results, we analyzed two tasks: a first task performed by motor stimuli and a second task, stimulated by the reading of a text. For motor stimuli, we show that complex time series of the EEG exhibit characteristic fluctuations depending on the channel analyzed. In order to demonstrate the efficacy of the proposed technique, we have examined four distinct channels represented here by F_332 , F_637 (front head region) and P_349 , F_654 (parietal region of the head). We have found that the amplitude of the rms function F_{DFA} is larger for the front channels than for the parietal ones. To better tabulate this information, the difference between F_{DFA} (on a logarithmic scale) was calculated. For the stimulus generated by the reading (trained brain / untrained brain), 11 bio-electrodes were chosen located in the frontal, parietal, temporal and occipital regions of the brain of two people. The difference between individuals appears for time scales $n < 128$ ($f > 1Hz$). I believe that this study can bring contributions from the effects generated by EEG records, additions to existing methodologies, as well as become a catalyst for future studies that demonstrate the dynamics of motor and cognitive responses of humans with complex stimuli.

Palavras chave: EEG, Time Series, DFA , $\rho DCCA$

Sumário

1	Introdução	1
1.1	Definição do Problema	4
1.2	Objetivos	4
1.3	Importância da Pesquisa	5
1.4	Hipóteses	6
1.5	Aspectos Metodológicos	6
1.6	Organização da Tese do Doutorado	8
2	Revisão da Literatura	9
2.1	Eletroencefalografia (EEG)	9
2.2	Complexidade no sinal de EEG	11
2.3	Uso Clínico do EEG	14
2.4	O Uso do EEG na Pesquisa	19
2.5	Vantagens do EEG	21
2.6	Funções Cerebrais: Técnicas Existentes	21
3	Séries Temporais	24
3.1	Análise de Séries Temporais: aspectos gerais	24
3.1.1	Tendência	27
3.1.2	Sazonalidades	29
3.1.3	Técnicas Descritivas	30
3.1.4	Autocorrelação	32
3.1.5	Modelos Probabilísticos e Processos Estacionários	33
3.1.6	Método das Médias Móveis	34
3.1.7	Método dos Mínimos Quadrados	35
3.1.8	Modelagem de uma Série Temporal	37
3.1.9	Expoente de Hurst Baseado em Escala de Intervalo	40
3.2	Métodos para Séries Temporais não Estacionárias	42
3.2.1	Detrended Fluctuation Analysis - DFA	42
3.2.2	Função de Flutuação - rms	45
3.2.3	Detrended Cross-Correlation Analysis - DCCA	48
3.2.4	Coefficiente de Correlação Cruzada - $\rho DCCA$	51
4	Resultados	57
4.1	Auto-correlação nos sinais de EEG humanos motores / imaginários: Uma visão sobre as flutuações da F_{DFA}	57
4.2	Análise dos bio-sinais do EEG durante a tarefa de leitura pelo método DFA	76
4.3	Ferramentas Desenvolvidas	86
5	Considerações Finais	92
5.1	Trabalhos futuros	93
5.2	Produção Acadêmica	93
	Referências	96

Lista de Tabelas

4.1	α_{DFA} dos canais complementares (C_{39} , C_{z11} e C_{413})	61
4.2	Média com os α_{DFA} dos canais complementares (C_{39} , C_{z11} e C_{413})	62

Lista de Figuras

1.1	Diferença na frequência do canal F_332 , localizado na região frontal, lado esquerdo do encéfalo. Indivíduo $S086$ da base do Physionet, participante do experimento disponível em: www.physionet.org/pn4/eegmidb/ . . .	2
1.2	Imagem gerada com o Wavelet cycles / FFT (Tempo x Frequência). Aqui temos a totalidade da atividade dos componentes em uma imagem. A técnica de Wavelet é utilizada para analisar sinais digitais, e também na compressão de imagens digitais. O arquivo utilizado para gerar as trilhas foi o indivíduo $S086$ da base do Physionet, participante do experimento disponível em: www.physionet.org/pn4/eegmidb/	3
1.3	Transformada de Fourier aplicada no sinal do canal F_332 , região frontal lado esquerdo do encéfalo. Indivíduo $S020$ da base do Physionet, participante do experimento disponível em: www.physionet.org/pn4/eegmidb/ . . .	3
1.4	Representação visual da metodologia empregada na pesquisa.	6
2.1	(a) Configuração de gravação do EEG. (b) Ondas monitoradas com EEG. . .	9
2.2	Ondas monitoradas com EEG.	11
2.3	Rede neural. Os dados desta imagem foram retirados da base do physionet, disponível no endereço: https://www.physionet.org/ . O arquivo gerado foi do indivíduo $S086$	12
2.4	Amplitudes neuronais com oscilações entre de 4-8 Hz.	13
2.5	Posição dos eletrodos. Sistema 10 - 20.	15
2.6	Comparando bandas de EEG.	17
2.7	Bandas de frequência em Hz.	19
3.1	Temos aqui dados brutos do sinal de EEG. Referem-se ao estímulo realizado pela leitura de um pequeno texto. As séries temporais geradas, foram os bio-eletrodos escolhidos: F_3 , F_4 , P_3 , P_4 . F_3 , F_4 localizado na parte frontal, enquanto P_3 , P_4 fica localizado na parte parietal do encéfalo. Cada série gerada possui 19.980 pontos. Experimento próprio usando o aparelho NEUROMAP $EQSA226$, sistema internacional (10–20). Clínica Cardiovida.	25
3.2	Observações de uma série temporal com previsões de origem t e horizonte h (MORETTIN; TOLOI, 1981).	29
3.3	Padrões característicos em séries temporais (EHLERS, 2009).	29
3.4	Medições anuais de vazões do Rio Nilo em Ashwan entre 1871 e 1970 (pontos), com polinômios de graus 3 e 6 ajustados por mínimos quadrados (EHLERS, 2009).	32
3.5	Método dos mínimos quadrados.	37
3.6	Modelo aditivo (a) / Modelo multiplicativo (b).	39
3.7	Modelo do reservatório Hurst (1951) usado para o cálculo de $X(t, \tau)$ (FEDER, 1988).	41
3.8	Modelo do reservatório Hurst (1951) usado para o cálculo de $R(\tau)$ (FEDER, 1988).	41
3.9	Dados brutos do canal O_1 , hemisfério esquerdo, região occipital do indivíduo $S049$. Disponível em https://www.physionet.org/	43
3.10	Canais utilizados na função rms. (ZEBENDE <i>et al.</i> , 2017)	45

3.11	Valor médio do $\Delta \log F_{32:xx}$ entre o canal F_{332} e outros três. Cada curva representa a diferença entre F_{332} , F_{637} , P_{349} e P_{654}	47
3.12	Divisão dos sinais integrados R_k e R'_K em N-n boxes (com superposição) de tamanho 4. Cada um contendo $n + 1$ valores. Fonte: adaptado de FILHO (2014)	49
3.13	Vizinhos próximos x Vizinhos distantes.	53
3.14	Tarefa real.	53
3.15	Tarefa imaginária.	54
3.16	Áreas ativas do encéfalo: tarefa real.	55
3.17	Áreas ativas do encéfalo: tarefa imaginária.	56
4.1	Canais Complementares: C_{39} , C_{z11} e C_{413}	58
4.2	Individuo $S060$	59
4.3	Individuo $S071$	59
4.4	Individuo $S086$	60
4.5	Imagens do encéfalo e traçado eletroencefalográfico.	76
4.6	Programa Monta Matriz	87
4.7	Modelo estrutural gerado pelo programa Monta Matriz	87
4.8	Arquivo .loc para Matlab / eeglab.	88
4.9	Programa ρ DCCA Desenho	89
4.10	ρ DCCA Desenho - Forte correlação (ρ DCCA > 0.666).	90
4.11	ρ DCCA Desenho - Fraca correlação (ρ DCCA < 0.333).	90

Lista de Siglas

CT	<i>Tomografia Computadorizada</i>
DCCA	<i>Detrended Cross-Correlation Analysis</i>
DFA	<i>Detrended Fluctuation Analysis</i>
DPA	<i>Transtorno de Processamento Auditivo</i>
DPS	<i>Processamento Digital de Sinais</i>
ECoG	<i>Eletrocorticografia</i>
EDF	<i>Formato de Dados Europeu</i>
EEG	<i>Eletroencefalografia</i>
EROS	<i>Sinal Óptico Relacionado ao Evento</i>
ERP	<i>Potencial Relacionado a Eventos</i>
FDP	<i>Função Densidade de Probabilidade</i>
FFT	<i>Transformada Rápida de Fourier</i>
FIRDA	<i>Delta rítmico frontal intermitente</i>
ICA	<i>Análise dos Componentes Independentes</i>
IEEG	<i>Eletroencefalografia Intracraniana</i>
ME	<i>Magnetoencefalografia</i>
MQ	<i>Mínimos Quadrados</i>
NIRS	<i>Espectroscopia no Infravermelho Próximo</i>
NREM	<i>Movimento não Rápido dos Olhos</i>
OIRDA	<i>Delta rítmico intermitente occipital</i>
PET	<i>Tomografia por Emissão de Prótons</i>
REM	<i>Movimento Rápido dos Olhos</i>
RMN	<i>Ressonância Magnética Nuclear</i>
RM	<i>Ressonância Magnética</i>
RMI	<i>Ressonância Magnética por Imagem</i>
SPECT	<i>Tomografia Computadorizada de Emissão de Fóton Único</i>
TC	<i>Tomografia Computadorizada</i>
TDAH	<i>Distúrbio do Déficit de Atenção</i>
UTI	<i>Unidade de terapia Intensiva</i>
ρ DCCA	<i>Coefficiente de Correlação Cruzada</i>

Introdução

A diferença de potencial extraído das correntes eletroquímicas do córtex cerebral em resposta a estímulos tem sido uma técnica importante para registrar pequenas mudanças comportamentais, como exemplo, abrir e fechar as mãos, movimentar os pés ou até realizar a leitura de um pequeno texto (ARGI, 2015). Em termos clínicos, essas medidas quando registradas, os chamados biosinais, tem aplicações diretas em diagnósticos associados a tumores, distúrbios do sono, profundidade da anestesia, coma, encefalopatias, mortes encefálicas, derrame, epilepsia e outros distúrbios cerebrais que levam a algumas anormalidades nas leituras do sinal (ARGI, 2015; BRONZINO, 2000).

Como forma de entendimento dos biosinais, a eletroencefalografia, que é um método de monitoramento eletrofisiológico¹ surge para registrar a atividade elétrica do cérebro. É um procedimento a priori, não-invasivo e a técnica acopla eletrodos ao longo do couro cabeludo (NIEDERMEYER, 2005). Quando comparado com outras técnicas como a tomográfica computadorizada (TC)² e a ressonância magnética (RM)³ o EEG apresenta uma maior vantagem em função da sua resolução temporal (permite gravar complexos padrões da atividade neural em frações de segundos), em compensação, uma baixa resolução espacial (TEPLAN, 2002; BEAUCHAMP *et al.*, 2011).

Toda a organização dos dados registrados pela aparelho de eletroencefalografia é armazenado em um arquivo EDF (European Data Format). Neste arquivo são armazenado informações tais como: um canal de anotações contendo, início, duração e a posição do canal, um seção com os registros das amplitudes de cada sinal por canal e outra seção com cabeçalho, contendo dados do paciente.

Muitos trabalhos publicados nesta linha, convergiram para levantar a hipótese de que o padrão implícito de ativação neuronal dos sinais de EEG, tem característica não-linear, com dinâmica auto-afim, enquanto os próprios sinais EEG são não-estacionários (POLONNIKOV *et al.*, 2003; NI *et al.*, 2015). A literatura sustenta também, que a análise fractal⁴

¹É o estudo das propriedades elétricas de células e tecidos biológicos. Envolve medidas de alterações de voltagem ou corrente elétrica ou manipulações em uma ampla variedade de escalas, desde proteínas de canais de íon único até órgãos inteiros, como o coração e cérebro.

²Uma tomografia computadorizada utiliza combinações processadas por computador de várias medidas de raios X tiradas de diferentes ângulos para produzir imagens transversais de áreas virtuais e específicas de um objeto digitalizado, permitindo que o usuário veja dentro do objeto sem cortar (LINS *et al.*, 1993).

³A ressonância magnética (MRI) é uma técnica de imagem médica usada em radiologia para formar imagens da anatomia e dos processos fisiológicos do corpo tanto na saúde quanto na doença. Os scanners de ressonância magnética usam campos magnéticos fortes, gradientes de campos elétricos e ondas para gerar imagens dos órgãos do corpo (LINS *et al.*, 1993).

⁴"fractal"do latim adjetivo fractus (que significa quebrado ou fraturado), com o correspondente verbo latino frangere significando "Quebrar"ou criar fragmentos irregulares (IEVA *et al.*, 2014; IEVA *et al.*, 2015).

de sinais de EEG revelam comportamentos de escala que podem não ser consistentes com o processo monofractal. Contudo, estudos revelam que estes sinais podem ser melhor modelados como processo multifractal (ZORICK; MANDELKERN, 2013; VLADIMIR *et al.*, 2015; ZHENHU *et al.*, 2015).

Registros também apontam que os espectros gerados por sinais de EEG apresentam diferentes frequências, ver Figura 1.1, permitindo conjecturar que essas ondas não trabalham de forma isolada, ou seja, existe correlação entre elas. A literatura também sustenta que modelos matemáticos empíricos são aplicados nestes resultados, a fim de analisar predições na tomada de decisão, quando excitados a aprender algo (processo cognitivo). Para tais estudos, usam-se os modelos matemáticos, baseados em transformações integráveis para sinais contínuos, tais como, Hilbert, Wavelets e Fourier, ver Figura 1.2 e 1.3. Vale salientar que as técnicas propostas por Hilbert, Wavelets e Fourier, analisam os registros no domínio da frequência, ou seja, analisam amplitude, magnitude e mudança de fase (GUEDES, 1977; KANASEWICH, 1974; SEDGEWICK, 1995).

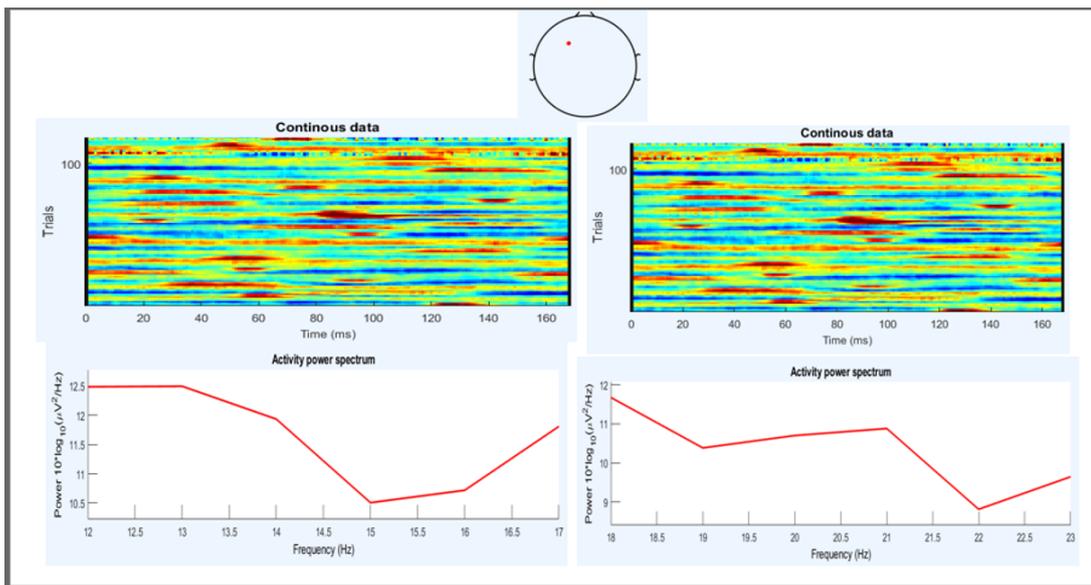


Figura 1.1: Diferença na frequência do canal F_{332} , localizado na região frontal, lado esquerdo do encéfalo. Indivíduo $S086$ da base do Physionet, participante do experimento disponível em: www.physionet.org/pn4/eegmdb/ .

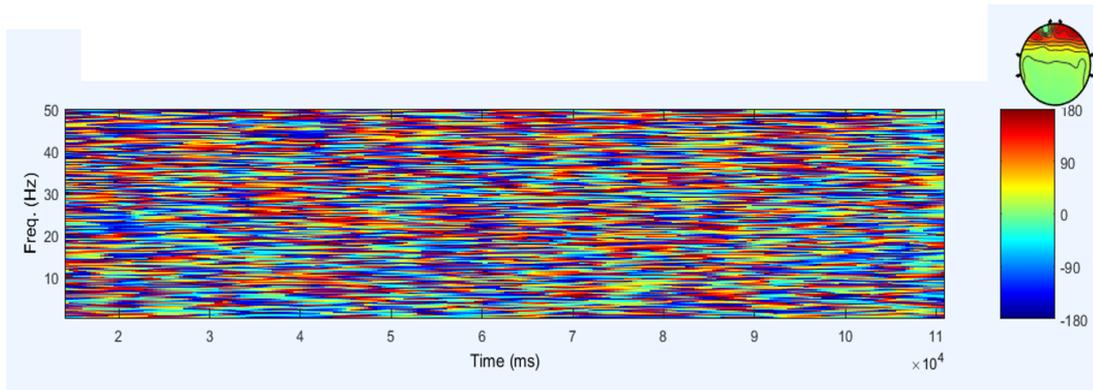


Figura 1.2: Imagem gerada com o Wavelet cycles / FFT (Tempo x Frequência). Aqui temos a totalidade da atividade dos componentes em uma imagem. A técnica de Wavelet é utilizada para analisar sinais digitais, e também na compressão de imagens digitais. O arquivo utilizado para gerar as trilhas foi o indivíduo *S086* da base do Physionet, participante do experimento disponível em: www.physionet.org/pn4/eegmidb/ .

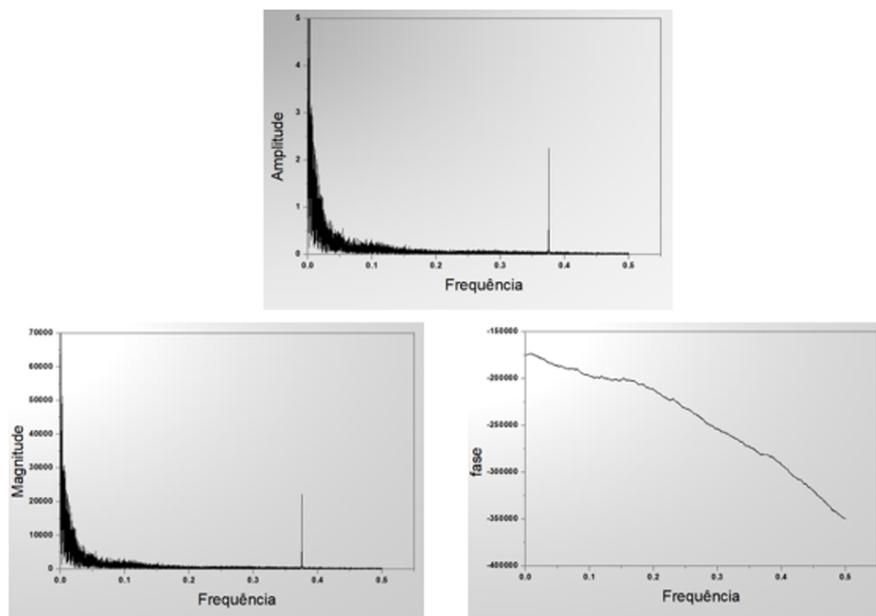


Figura 1.3: Transformada de Fourier aplicada no sinal do canal F_332 , região frontal lado esquerdo do encéfalo. Indivíduo *S020* da base do Physionet, participante do experimento disponível em: www.physionet.org/pn4/eegmidb/ .

A literatura associada ao contextos aqui mencionados, transformações integráveis para sinais contínuos no domínio da frequência, absorveu de outra forma os impactos significativos no desempenho de dados neurofisiológicos tais como: a diferença da amplitude da flutuação do sinal para regiões diferentes do encéfalo, direção preferencial, perturbação a um hemisfério, variabilidade da atividade neural no córtex cerebral e coerência cerebral⁵ (CASTELLONE *et al.*, 2003; HAYKIN, 2000; CHEN *et al.*, 2018).

⁵O estudo da coerência permite identificar o quanto duas áreas do cérebro está em sincronismo para a mesma faixa de frequência.

1.1 Definição do Problema

Tem sido frequente nos manuscritos que analisam doenças relacionadas aos distúrbios degenerativos do sistema neural (Alzheimer), distúrbios neurológicos crônicos e progressivo resultante de tremores, rigidez, lentidão e instabilidade postural (Doença de Parkinson), assim como distúrbios relacionados a respostas motoras, relatar a necessidade de investigar e mensurar as correlações entre áreas do cérebro humano. O nível de correlação (fraco, médio e forte) pode ser decisivo para entender um pouco mais sobre a formação e controle por área do encéfalo. Interpretar por meio de modelos matemáticos e recursos computacionais o detalhe do desenho dessas correlações e também de suas amplitudes, torna-se tão importante quanto a morfologia bruta.

Diante deste cenário, a presente pesquisa pretende responder as seguintes perguntas:

Como as séries temporais complexas do EEG exibem flutuações características, dependendo do canal analisado, por meio da amplitude da flutuação?

Seria possível visualizar em uma interface computacional, o nível de correlação cruzada (fraco, médio e forte), em sinais eletroencefalográficos, por área do encéfalo com dados reais e de maneira dinâmica?

1.2 Objetivos

Geral:

Propor um modelo computacional, baseado na função de flutuação (raiz quadrática média) rms, $F_{DFA}(n)$, para mensurar a amplitude da flutuação entre regiões distintas do encéfalo e interpretar de maneira auto-afim sua correlação cruzada via coeficiente de correlação cruzada sem tendência $\rho DCCA$.

Específico:

I. Comparar regiões do encéfalo por meio da autocorrelação e correlação cruzada e avaliar como a amplitude da função de flutuação rms, $F_{DFA}(n)$, comporta-se com sinais de EEG.

II. Analisar a atividade cerebral quando estimulado pela leitura (cognição), realizada por indivíduos usando um aparelho de EEG (Neuromap EQSA260) com 22 canais por meio da função de flutuação rms, $F_{DFA}(n)$.

III. Interpretar computacionalmente a coerência temporal, da atividade cerebral, por meio do coeficiente de correlação cruzada ρ_{DCCA} .

1.3 Importância da Pesquisa

Os recursos computacionais trouxeram ampla possibilidades de olhar para o cérebro através dos biosinais. Com várias formas de entender comportamentos, tendências, sincronismos e sobretudo biomarcações, aumentou muito a chance de contribuir com diagnósticos, principalmente de distúrbios degenerativas com o Alzheimer, reabilitações motoras complexas e a doença de Parkinson. De forma significativa, autores trazem importantes contribuições para abordagem com sinais de eletroencefalografia (JÚNIOR *et al.*, 2001; SCHMITZ *et al.*, 2005).

Parte dessas contribuições vem de estudos com variáveis em condições clínicas. Em contrapartida, existem poucas discussões com respostas a estímulos (SCHMITZ *et al.*, 2005; NUNEZ *et al.*, 2006; WILSON, 2010). Dois aspectos reforçam a importância de explorar o EEG. Primeiro, que a utilização de técnicas não invasivas, que extraem representações mensuráveis do funcionamento cerebral, é uma das mais promissoras abordagens atualmente empregada no estudo da aprendizagem motora e fala (cognição). Segundo, que o conhecimento da composição de frequência da atividade elétrica, é um elemento fundamental, tanto em pesquisa quanto em aplicações clínicas. Para ambas abordagens, a análise quantitativa torna-se importante, pois o EEG convencional é baseado no exame visual do traçado e comportamento, portanto, um significativo componente de subjetividade. Mesmo com essa robusta técnica, há ainda discussões intensas sobre a atividade neural. Abordagens relacionadas como direção preferencial, perturbação a um hemisfério e variabilidade da atividade neural no córtex cerebral, são perguntas ainda em aberto (SATO *et al.*, 2010; CHEN *et al.*, 2018; SCHMITZ *et al.*, 2005).

Sendo assim, a análise meramente qualitativa do sinal EEG é insuficiente para as diversas utilizações experimentais e clínicas que a neurofisiologia compreende, sendo necessário e suficiente, diferentes e sucessivas transformações matemáticas para obter sua tradução num sinal mensurável e dele retirar o máximo de informações. Nessa linha, grandes desafios envolvem o desenvolvimento de sistemas e modelos matemáticos eficientes e compatíveis ao contexto fisiológico humano. Contudo, surge uma grande necessidade por métodos computacionais capazes de extrair, medir, analisar e classificar as características relevantes dos sinais EEG de forma automatizada para a realização de diagnósticos.

Tratando-se de benefícios e contribuições do contexto apresentado, o presente estudo possibilitará um aditivo metodológico e novas teorias acerca do conhecimento no tratamento e classificação de sinais eletroencefalográfico, assim como, propor uma nova ferramenta

para mensurar a coerência temporal entre áreas do encéfalo e também correlacionar essas áreas de maneira dinâmica e auto-afim.

1.4 Hipóteses

A amplitude da função do sinal entre dois canais ativos de EEG, quando estimulados por processo motor é maior para os canais frontais em relação aos canais temporais e parietais.

A correlação cruzada, mensurada de maneira dinâmica, servirá como ferramenta para o monitoramento de distúrbios relacionados à atividade motora.

1.5 Aspectos Metodológicos

Algumas etapas definem o traçado metodológico. A figura 1.4 ilustra a representação visual das etapas do projeto implementado para a construção da tese.

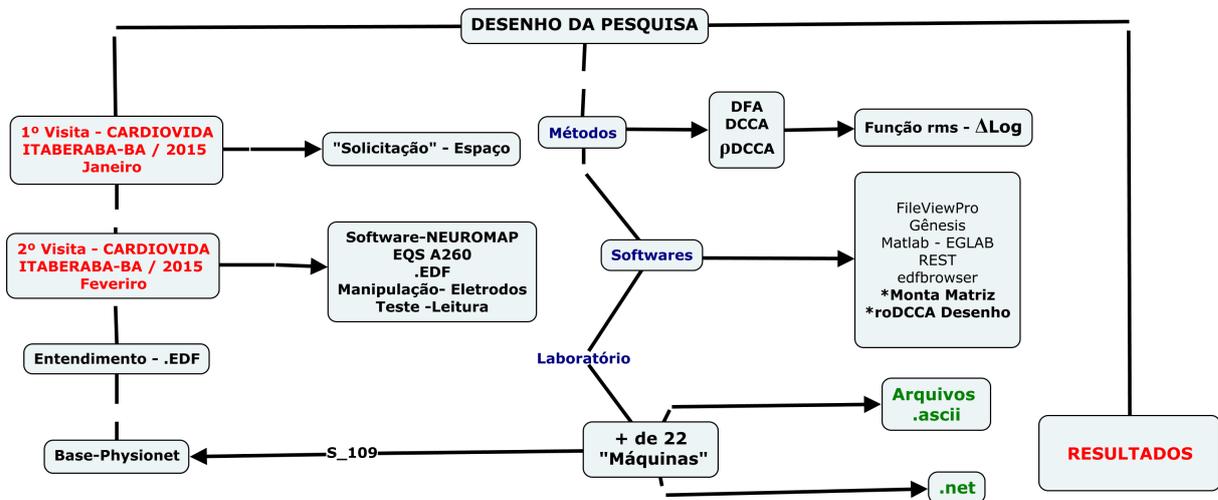


Figura 1.4: Representação visual da metodologia empregada na pesquisa.

Algumas etapas definem o traçado metodológico.

I ETAPA: A primeira etapa foi caracterizada pelos encontros realizados na clínica Cardiovida, localizado na cidade de Itaberaba-Ba. Além da aprovação dos proprietários (Hérico Leite de Souza, cardiologista e Geanny Souza, assistente social e gestora hospitalar), contei com a participação da técnica de enfermagem Aline Souza dos Santos.

Os procedimentos desenvolvidos foram:

- (I) Conhecimento e funcionalidades do aparelho NEUROMAP EQSA260 de 26 canais, versão: 3.2.31. N° de Série: NT129505;
- (II) Embasamento teórico a respeito da posição dos eletrodos / eletrodo de referência;
- (III) Realização e acompanhamento de testes;
- (IV) Instalação, configuração de filtros, medição de impedância, modulação para uso de redes (Internet e Intranet).

O IV procedimento foi importante para a construção do 2° artigo da tese intitulado "**Análise dos bio-sinais do EEG durante a tarefa de leitura pelo método DFA**". Apresentado no 4° capítulo desta tese.

II ETAPA: Uma segunda etapa, fase direcionada para a base do Physionet, disponível no endereço <www.physionet.org/pn4/eegmidb/>. Essa base é composta por um arquivo contendo 109 indivíduos que realizaram testes motores relacionados a resposta por estímulos. Trata-se uma base com um número de observações suficiente, considerando os métodos estatísticos modelados. A base também servirá para outros estudos, inclusive pesquisas com arquiteturas e topologias de redes neurais (em andamento).

III ETAPA: Nesta etapa, foi realizado um tratamento nos arquivos ".EDF", transformando para arquivos ".txt". Também foram criados os programas "executáveis" em linguagem C++ para calcular os métodos *DFA*, $\Delta\log$, *DCCA* e $\rho DCCA$. Esta etapa foi direcionada para a construção do 1° artigo da tese intitulado "**Auto-correlação nos sinais de EEG humanos motores / imaginários: Uma visão sobre as flutuações da F_{DFA}** ". Apresentado no 4° capítulo deste texto dissertativo.

IV ETAPA: Para esta etapa foram desenvolvidos dois programas: Monta Matriz e $\rho DCCA$ Desenho. A finalidade do programa Monta matriz é reconhecer e ler o arquivo rhoDCCA.txt e converter em uma planilha do excel. A estrutura da planilha é discretizada em uma matriz quadrada com diagonal principal igual a 1. Já o programa $\rho DCCA$ Desenho tem como objetivo ler todas as correlações geradas a partir do Monta Matriz. A priori o programa foi criado para interpretar uma base do physionet, disponível no endereço: <<http://www.physionet.org>>.

1.6 Organização da Tese do Doutorado

Tendo em vista contemplar o objetivo deste estudo, a tese está organizada da seguinte forma:

- **Capítulo 1 - Introdução;** Uma contextualização do objeto de estudo. Apresento a definição do problema, objetivo geral, objetivos específicos, importância da pesquisa, hipóteses, aspectos metodológicos e a forma estrutural por capítulos.
- **Capítulo 2 - Revisão da literatura;** Apresenta um contexto com pontos importantes da eletroencefalografia, tais como: Complexidade do sinal, o uso clínico, o uso na pesquisa, vantagens, desvantagens e um breve contexto sobre técnicas empregadas para estudar as funções cerebrais existentes.
- **Capítulo 3 - Análise de Séries Temporais;** O capítulo aborda também teoria relativa ao estudo de séries temporais e sobre os métodos empregados na pesquisa, tais como: DFA, Função de Flutuação - rms, DCCA e ρ DCCA.
- **Capítulo 4 - Resultados;** Neste capítulo serão apresentados os resultados do estudo na forma de artigos publicados em periódicos indexados. Apresentamos também uma descrição das ferramentas utilizadas para desenvolvimento e interpretação dos dados.
- **Capítulo 5 - Considerações finais e trabalhos futuros.** É apresentado as conclusões, contribuições, algumas atividades de pesquisa a serem desenvolvidas no futuro, assim como, a produção acadêmica desenvolvida no período de 2015 - 2019 .

2.1 Eletroencefalografia (EEG)

A eletroencefalografia(EEG) é um método de acompanhamento eletrofisiológico ideal para anotar estímulos ou desordens ocasionadas pela atividade elétrica do cérebro, ver figura 2.1. É a priori um procedimento não-invasivo e a técnica é feita colocando eletrodos ao longo do couro cabeludo, apesar de que eletrodos invasivos sejam em algumas circunstâncias, usados às vezes, na electrocorticografia intracraniana. A técnica da eletroencefalografia intracraniana (IEEG), é um tipo de monitoramento eletrofisiológico que utiliza eletrodos colocados diretamente na superfície do cérebro para registrar a atividade elétrica do córtex cerebral. Em contraste, eletrodos de eletroencefalografia (EEG) convencionais monitoram essa atividade de fora do crânio. A eletroencefalografia mede as flutuações de tensão resultantes da corrente iônica dentro dos neurônios no encéfalo (NIEDERMEYER, 2005).

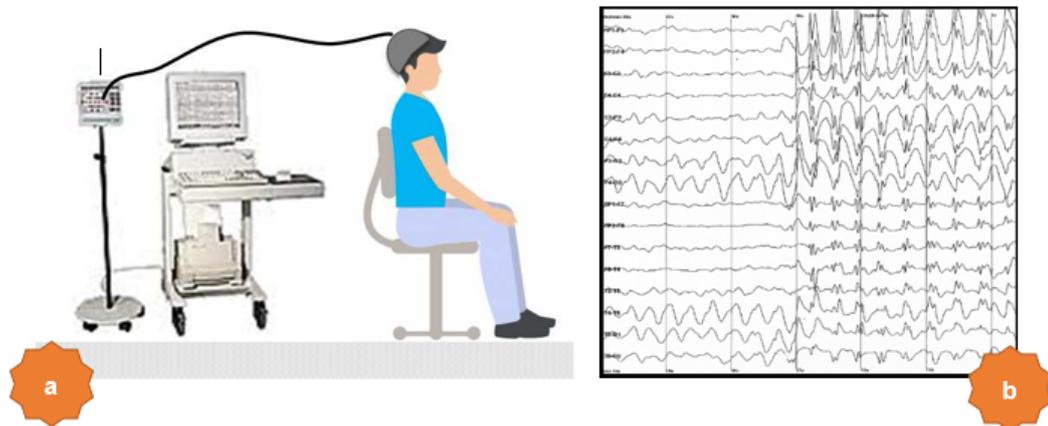


Figura 2.1: (a) Configuração de gravação do EEG. (b) Ondas monitoradas com EEG.

Em condições clínicas, o EEG refere-se ao registro da atividade natural do cérebro ao longo de um período de tempo, conforme registrado em vários eletrodos acoplados no couro cabeludo (TATUM, 2014b). As aplicações de diagnóstico geralmente se concentram em potenciais relacionados a eventos ou no conteúdo espectral do EEG. Um potencial relacionado a eventos é a resposta cerebral medida que consiste no resultado direto de um evento sensorial, cognitivo ou motor específico, mais formalmente, é qualquer resposta eletrofisiológica uniformizada a um estímulo. Já o espectro de energia de uma série temporal $x(t)$, descreve a distribuição de potência em componentes de frequência compondo

esse sinal.

De acordo com [Tatum \(2014b\)](#) na análise de Fourier, qualquer sinal físico pode ser decomposto em um número de frequências discretas, ou um espectro de frequência em um intervalo contínuo. Quando associados, a análise de Fourier e o potencial relacionado a eventos, o tempo potencial de flutuações bloqueadas como o início de estímulos ou o posicionamento de botão e a resposta cerebral, permite entender os tipo de oscilações neurais, popularmente conhecidas na literatura como ondas celebrais, que podem ser observadas em sinais de EEG no domínio da frequência por meio ondas sinusoidais ([NIEDERMEYER, 2005](#)).

Com um contexto clínico muito forte, o EEG tem uma contribuição importante em diagnósticos associados a epilepsia, que por consequências da sua função, evidencia anormalidades no traçado e leitura do sinal. Vale salientar que, para a Organização Mundial de Saúde, a epilepsia faz parte de um grupo de transtornos neurológicos caracterizados por crises epiléticas, sendo que essas crises epiléticas são caracterizadas por episódios que podem variar de períodos breves e quase indetectáveis a longos períodos de agitação vigorosa ([FISHER *et al.*, 2005](#); [EADIE, 2012](#); [MAGIORKINIS *et al.*, 2010](#)). O diagnóstico geralmente pressupõe excluir outras condições que possam provocar sintomas semelhantes (como o desmaio) e perceber se existem quaisquer causas imediatas. A epilepsia é muitas vezes confirmada através de um eletroencefalograma (EEG) ([FISHER *et al.*, 2005](#)). Como aplicação direta podemos citar também o distúrbio do sono, práticas médicas associadas ao processo anestésico, estado de inconsciência, processos degenerativos crônicos como as encefalopatias e sobretudo a perda total das funções cerebrais (incluindo a atividade involuntária necessária para sustentar a vida) como a morte encefálica.

O EEG costumava ser um método tradicional e importante de primeira linha para diagnosticar distúrbios cerebrais focais (tumores e derrame cerebral), porém a aplicação desse método diminuiu com a chegada de técnicas de imagem distribuídas com alta resolução, como a ressonância magnética por imagem (MRI) e sobretudo a tomografia computadorizada (CT). Entretanto com uma resolução espacial limitada, a eletroencefalografia continua a ser uma ferramenta relevante para a pesquisa e diagnósticos. É uma das poucas técnicas móveis disponíveis e oferece uma resolução temporal de milissegundos que não é possível com tomografia computadorizada (CT), tomografia por emissão de prótons (PET) ou ressonância magnética por imagem (MRI) ([CHERNECKY; BERGER, 2013](#)).

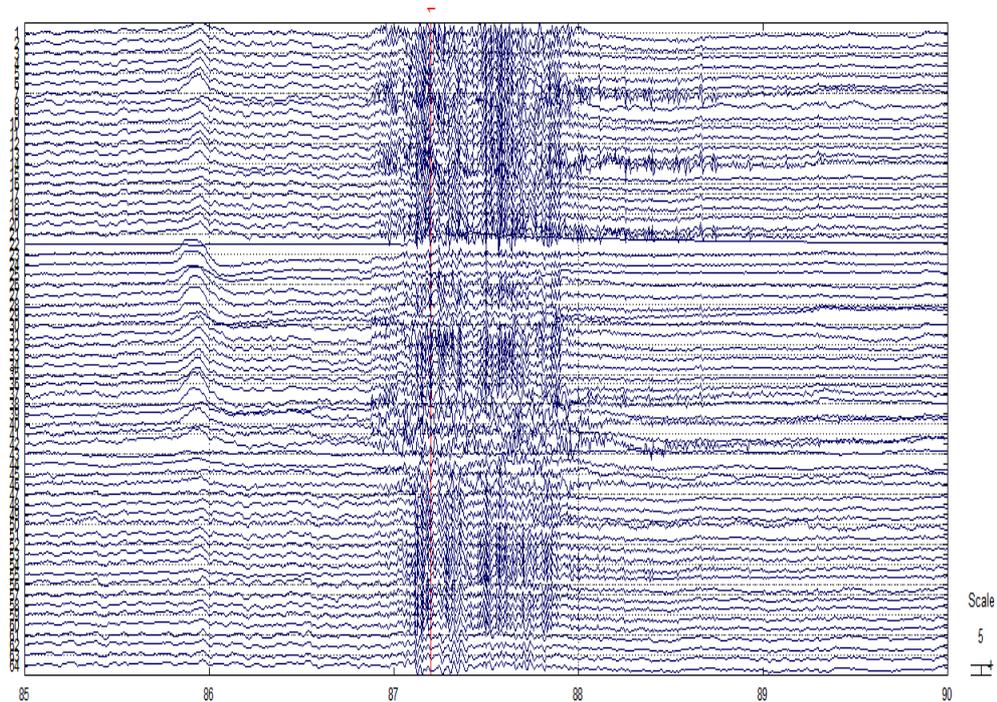


Figura 2.2: Ondas monitoradas com EEG.

A Figura 2.2 foi gerada a partir do arquivo S086R03 extraído da base do phisionet <<https://www.physionet.org/>>. Trata-se de um teste motor (movimento real dos pés com duração de 2 minutos, monitorado pelo sistema BCI2000) registrado por 64 canais. O mapa eletrofisiológico foi gerado pelo toolbox do MATLAB ICA/EEG. Disponível em <<http://sccn.ucsd.edu/>>. Aqui temos a atividade elétrica cerebral, captada através da utilização de eletrodos colocados sobre o couro cabeludo. Pelos impulsos naturalmente gerados pelos neurônios é possível avaliar a normalidade (ou não) do ritmo e da intensidade da atividade cerebral. Os impulsos elétricos são amplificados, captados e registrados por meio de eletrodos, que os envia para o aparelho de EEG.

2.2 Complexidade no sinal de EEG

O EEG humano é uma medida da variação na voltagem no couro cabeludo gerado pelo aglomerado de redes neuronais, ver Figura 2.3. A complexidade evidente nessas voltagens se manifesta através de flutuações em todas as escalas de tempo, desencadeando elevações na tensão que podem durar por frações de segundo a minutos, gerando assim uma

variabilidade que representa uma estrutura fractal ao EEG e está associada a um padrão subjacente de não estacionariedade (CHÁVEZ *et al.*, 2003). Ver Figura 2.4 .




Figura 2.3: Rede neural. Os dados desta imagem foram retirados da base do physionet, disponível no endereço: <https://www.physionet.org/>. O arquivo gerado foi do individuo S086.

A visualização da rede neural, vista na Figura 2.3, mostra a correlação entre os canais. Condiz a uma rede composta por 64 nós e 998 arestas. O grafo ilustrativo foi gerado pelo software gephi (versão 0.92) distribuído pelo algoritmo Fruchterman Reingold. A ligação entre os nós mede a correlação cruzada entre os canais com base no método $\rho DCCA$, proposto por (ZEBENDE, 2011).

O Gephi é uma ferramenta para analistas de dados e cientistas interessados em explorar e entender gráficos. Como o Photoshop, mas para dados gráficos, o usuário interage com a representação, manipula as estruturas, formas e cores para revelar padrões ocultos. O objetivo é ajudar os analistas de dados a criar hipóteses, descobrir intuitivamente padrões, isolar singularidades de estruturas ou falhas durante a terceirização de dados. É uma

ferramenta complementar às estatísticas tradicionais, já que o pensamento visual com interfaces interativas é agora reconhecido para facilitar o raciocínio. Este é um software para análise exploratória de dados.

O Algoritmo de Fruchterman-Reingold é um algoritmo de layout direcionado à força. A idéia de um algoritmo de layout direcionado à força é considerar uma força entre dois nós. Nesse algoritmo, os nós são representados por anéis e as arestas são molas entre eles. A força atrativa é análoga à força da mola e a força repulsiva é análoga à força elétrica. A idéia básica é minimizar a energia do sistema movendo os nós e alterando as forças entre eles.

Nesse algoritmo, a soma dos vetores de força determina qual direção um nó deve mover. A largura da etapa, que é uma constante, determina o quanto um nó se move em uma única etapa. Quando a energia do sistema é minimizada, os nós param de se mover e o sistema atinge seu estado de equilíbrio. A desvantagem disso é que, se definirmos uma largura de passo constante, não há garantia de que o sistema atingirá o equilíbrio.

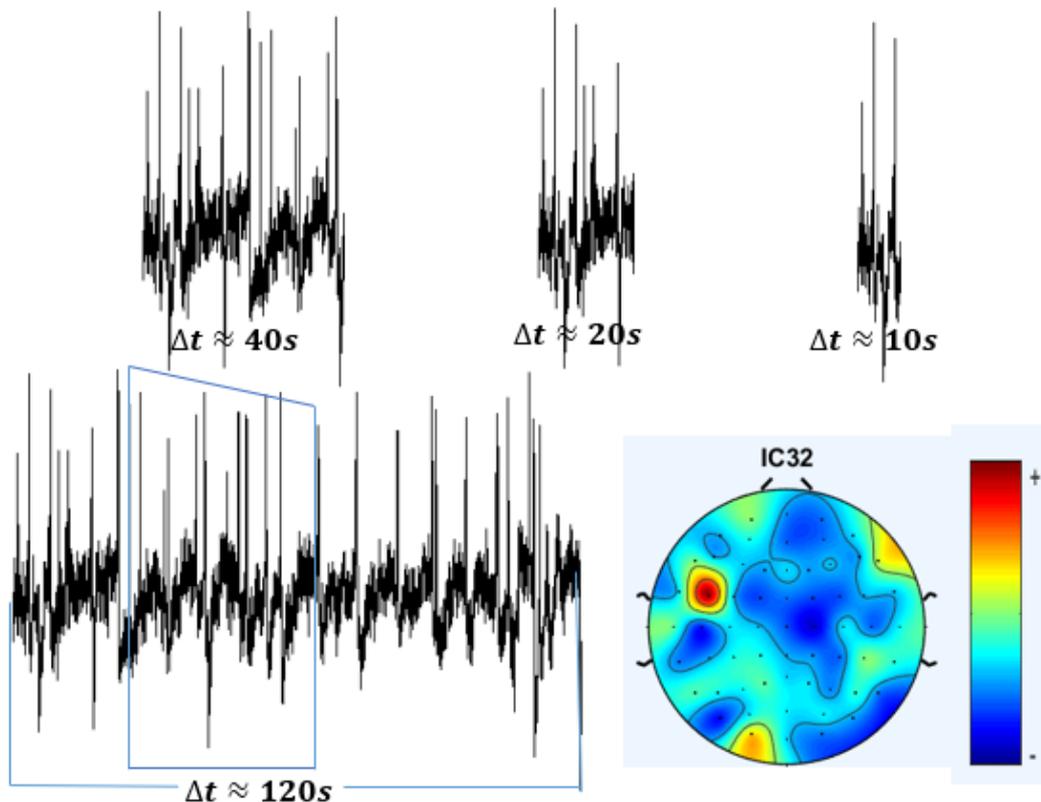


Figura 2.4: Amplitudes neuronais com oscilações entre de 4-8 Hz.

Na Figura 2.4, as flutuações do sinal de EEG bruto são espalhados pela amplitude das oscilações neurais, mostra a amplitude das oscilações entre 4 - 8 Hz, ao longo de 120 segundos, com uma taxa de 0.00625 ms. Além de estar sujeito a flutuações substanciais e variabilidade, a complexidade do EEG é caracterizada pela presença de fontes distintas

de atividade que crescem em semelhança quando vistas em escalas de tempo longas.

Assim a complexidade no EEG rege-se ao menos por três fenômenos:

- flutuações no EEG bruto;
- a modularidade funcional do cérebro mostra características auto-similares em cada nível de análise;
- O padrão não linear com dinâmica auto-afim.

2.3 *Uso Clínico do EEG*

Um registro clínico rotineiro de EEG geralmente dura de 20 a 30 minutos, mais o tempo de preparação. Frequentemente envolve a gravação de eletrodos no couro cabeludo. O EEG de rotina é tipicamente usado em circunstâncias clínicas para distinguir crises epiléticas de outros tipos de crises, como crises psicogênicas não epiléticas, síncope (desmaios), distúrbios de movimento⁶ subcorticais e variantes de enxaqueca, para diferenciar encefalopatia orgânica ou delirium de doenças primárias. Também Síndromes psiquiátricas, como catatonia, para servir como um teste auxiliar de morte encefálica, para prognosticar, em certos casos, em pacientes com coma, e para determinar se desmamar medicamentos anti-epiléticos (NIEDERMEYER, 2005).

Na maioria das vezes, a eletroencefalografia de rotina não é suficiente para formar o diagnóstico e /ou de instituir a melhor orientação em termos de tratamento. Em situações assim, tentativas podem ser feitas para registrar um EEG enquanto uma convulsão está ocorrendo. Este procedimento é conhecido como ictalgravação. Ictal refere-se a um estado ou evento fisiológico, como convulsão, derrame ou dor de cabeça. A palavra se origina do latim ictus, significando um golpe ou um derrame. Para obter este estado ou evento (Ictal), o EEG é a priori realizado acompanhado de um vídeo sincronizado em tempo e gravação de áudio. O procedimento pode ser realizado em um ambulatório ou durante a internação hospitalar, preferencialmente em uma unidade de monitoramento de epilepsia com profissionais treinados no atendimento com pacientes com convulsões.

O EEG também pode ser usado em unidades de terapia intensiva (UTI) para monitoramento de função cerebral, monitorar convulsões, estado epilético, para monitorar o efeito do sedativo, anestesia em pacientes em coma medicamente induzido (para tratamento de convulsões refratárias ou aumento intracraniano), pressão arterial, e para monitorar da-

⁶Distúrbios do movimento são síndromes clínicas com um excesso de movimento ou uma escassez de movimentos voluntários e involuntários, não relacionados à fraqueza ou espasticidade (LITVAN *et al.*, 2012).

nos cerebrais secundários em condições como a hemorragia subaracnóidea (atualmente um método de pesquisa)(NIEDERMEYER, 2005).

Trabalhos recentes utilizando técnicas com aprendizado de máquinas, tais como redes neurais com características temporais extraídas do lobo frontal dados de ondas cerebrais que mostram altos níveis de sucesso na classificação de estados mentais (descontraído, neutro, concentrado) e estados mentais emocionais (negativo, neutro, positivo) (BIRD *et al.*, 2018a; BIRD *et al.*, 2018b). Vale relatar que o aprendizado de máquina é um estudo científico de algoritmos e modelos estatísticos que os sistemas computacionais usam para melhorar progressivamente seu desempenho em uma tarefa específica. Algoritmos de aprendizado de máquina constroem um modelo matemático de dados de amostra, conhecido como "dados de treinamento", para fazer previsões ou decisões sem ser explicitamente programado para executar a tarefa (KOZA *et al.*, 1996).

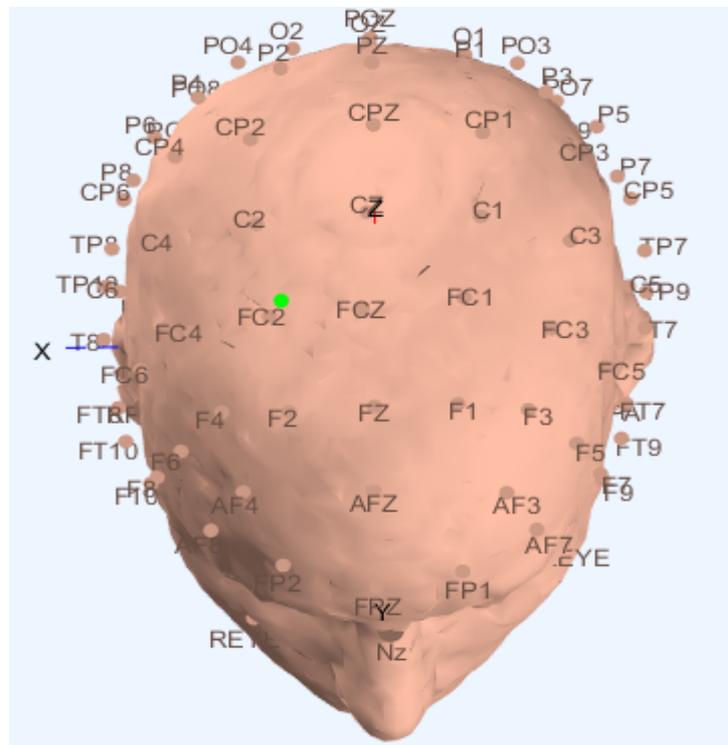


Figura 2.5: Posição dos eletrodos. Sistema 10 - 20.

A figura 2.5 mostra a imagem espacial com a localização dos pontos convencionados para posição dos eletrodos, pelo sistema 10 - 20. O arquivo usado para gerar a figura está disponível na base do physionet (<<https://www.physionet.org/>>). O indivíduo escolhido foi o S086R03. O software usado para geração do mapa eletrofisiológico foi o toolbox do MATLAB ICA/EEG.

Alguns detalhes sobre a figura 2.6.

O conceito de sono, reportado para a banda delta (< 4 Hz) / normalidade, refere-se ao sono não-rápido dos movimentos oculares, coletivamente, os estágios 1-3 do sono, anteriormente conhecidos como estágios 1-4. O sono de movimento rápido dos olhos (REM) não está incluído (SCHMITZ *et al.*, 2005).

Para a banda Beta (16-31 Hz): os benzodiazepínicos (BZD, BDZ, BZs), às vezes chamados de "benzos", são uma classe de drogas psicoativas cuja estrutura química central é a fusão de um anel de benzeno e um anel de diazepina. O primeiro desses medicamentos, o clordiazepóxido (Librium), foi descoberto acidentalmente por Leo Sternbach em 1955 e disponibilizado em 1960 pela Hoffmann-La Roche, que desde 1963 também comercializa o diazepam benzodiazepínico (CAHN; POLICH, 2013).

Já a síndrome de Dup15q é o nome comum para a síndrome de duplicação do cromossomo 15q11.2 – q13.1. Este é um distúrbio do neurodesenvolvimento, causado pela duplicação parcial do cromossomo 15, que confere um forte risco para o transtorno do espectro do autismo, epilepsia e deficiência intelectual (FROHLICH *et al.*, 2016).

Para a banda de Mu (16 – 31 Hz), o autismo é um distúrbio do desenvolvimento caracterizado por dificuldades de interação e comunicação social e por comportamento restrito e repetitivo. Os pais costumam notar sinais durante os primeiros dois ou três anos da vida de seus filhos (OBERMAN *et al.*, 2005).

A maior parte do sinal cerebral observado no EEG do couro cabeludo cai no intervalo de 1 a 20 Hz (a atividade abaixo ou acima dessa faixa provavelmente é artefactual, sob técnicas de registro clínico padrão). As formas de onda são subdivididas em larguras de banda conhecidas como alfa, beta, teta e delta para significar a leitura do EEG usado na prática clínica (TATUM, 2014a).

As definições teóricas sempre foram mais cuidadosamente definidas para incluir todas as frequências. Infelizmente, não há acordo em trabalhos de referência padrão sobre o que esses intervalos devem ser. Os valores para o extremo superior do alfa e o extremo inferior do beta incluem 12, 13, 14 e 15. Se o limite for tomado como 14 Hz, o beta mais lento tem onda aproximadamente a mesma duração que o pico mais longo (70 ms), o que torna este o valor mais útil para identificar a coerência cerebral.

	Localização	Normalmente	Patologia
DELTA <4Hz	Fortemente em adultos, posteriormente em crianças	Sono adulto de ondas lentas, bebês. Tarefas de atenção	Lesões subcorticais, lesões difusas, encefalopatia, lesões
TETA 4-7 Hz	Encontrado em locais não relacionados à tarefa em mãos	Maior em crianças pequenas, sonolência em adultos	Lesões subcorticais focais, encefalopatia metabólica
ALFA 8-15 Hz	Regiões posteriores da cabeça, ambos os lados	Relaxado / refletindo, fechando os olhos	Coma
BETA 16-31 Hz	Ambos os lados, ondas de baixa amplitude	Pensamento ativo, foco, alerta alto, ansioso	Síndrome de Dup15q
GAMA >32 Hz	Córtex somatossensorial	Exibe durante processamento sensorial cruzado (Ex. som e visão)	Diminuição na atividade da banda gama (declínio)
Mu 8-12 Hz	Córtex sensório-motor	Mostra os neurônios motores do estado de repouso	Autismo

Figura 2.6: Comparando bandas de EEG.

Sobre os padrões de onda:

i) Uma onda delta é uma onda cerebral de alta amplitude com uma frequência de oscilação entre 0,5 e 4 hertz. As ondas delta, como outras ondas cerebrais, são registradas com um eletroencefalograma (EEG) e geralmente estão associadas ao estágio profundo 3 do sono NREM, também conhecido como sono de ondas lentas, e ajudam a caracterizar a profundidade do sono. Pode ocorrer focalmente com lesões subcorticais e na distribuição geral com lesões difusas, encefalopatia metabólica, hidrocefalia ou lesões na linha média profunda. Geralmente é mais proeminente em adultos (por exemplo, FIRDA - delta

rítmico frontal intermitente) e posteriormente em crianças (por exemplo, OIRDA - delta rítmico intermitente occipital) (TATUM, 2014a).

ii) A onda teta é vista normalmente em crianças pequenas. Pode ser visto em sonolência ou excitação em crianças mais velhas e adultos; também pode ser visto em meditação. O excesso de teta para a idade representa atividade anormal. Pode ser visto como uma perturbação focal em lesões subcorticais focais; pode ser visto na distribuição generalizada em transtorno difuso ou encefalopatia metabólica ou em transtornos profundos da linha média ou em alguns casos de hidrocefalia (CAHN; POLICH, 2013).

iii) As ondas alfa são oscilações neurais na faixa de frequência de 8-12 Hz, decorrentes da atividade elétrica síncrona e coerente (em fase ou construtiva) de células marcapasso talâmicas em humanos. As ondas alfa são um tipo de ondas cerebrais detectadas por eletroencefalografia (EEG) ou magnetoencefalografia (MEG), e podem ser quantificadas usando eletroencefalografia quantitativa (qEEG) (GERRARD; MALCOLM, 2007).

iv) A onda beta, ou ritmo beta, é uma oscilação neural (ondas cerebrais) no cérebro com uma faixa de frequência entre 12,5 e 30 Hz (12,5 a 30 ciclos por segundo). As ondas beta podem ser divididas em três seções: Ondas Beta Baixas (12,5 a 16 Hz, "Potência Beta 1"); Ondas Beta (16,5 a 20 Hz, "Potência Beta 2"); e Beta Ondas Altas (20,5 a 28 Hz, "Potência Beta 3"). A atividade beta está intimamente ligada ao comportamento motor e é geralmente atenuada durante os movimentos ativos (PFURTSCHELLER; SILVA, 1999).

v) Uma onda gama é um padrão de oscilação neural em humanos com uma frequência entre 25 e 100 Hz, embora 40 Hz seja típico. De acordo com uma teoria popular, as ondas gama podem estar implicadas na criação da unidade de percepção consciente (o problema da ligação). No entanto, não há acordo sobre a teoria; como sugere o pesquisador (KRAMIS *et al.*, 1975; CASSEL, 2010).

vi) As ondas mu, também conhecidas como ritmos mu, ritmos arciformes ou ritmos sensorio-motores, são padrões sincronizados de atividade elétrica envolvendo grandes números de neurônios, provavelmente do tipo piramidal, na parte do cérebro que controla o movimento voluntário. Esses padrões, medidos por eletroencefalografia (EEG), magnetoencefalografia (MEG) ou eletrocorticografia (ECoG), se repetem com frequência de 7,5 a 12,5 (e principalmente 9 – 11) Hz e são mais proeminentes quando o corpo está fisicamente em repouso (OBERMAN *et al.*, 2005).

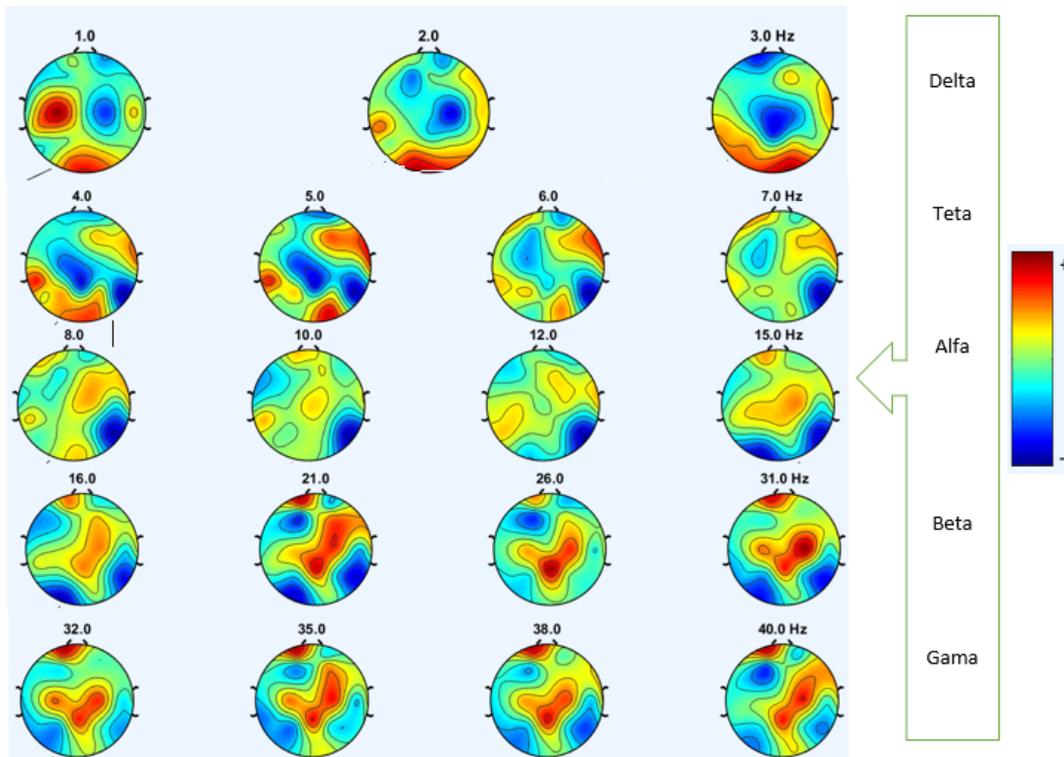


Figura 2.7: Bandas de frequência em Hz.

A figura 2.7 foi gerado com um arquivo .EDF de 21 canais do experimento da leitura que gerou o manuscrito "Análise dos bio-sinais do EEG durante a tarefa de leitura pelo método DFA". Disponível no capítulo 4. As imagens foram geradas pela ferramenta MATLAB ICA/EEG. Disponível em <<http://sccn.ucsd.edu/>>. A figura mostra os intervalos por banda, assim como, a relação do quanto duas ou mais áreas do cérebro estão ativas para a mesma faixa de frequência (coerência cerebral).

2.4 O Uso do EEG na Pesquisa

Um potencial relacionado a eventos (ERP) e o EEG são empregados extensivamente em pesquisas, mas também para estudar as funções humanas, tais como engolir (COLIZOLI *et al.*, 2018a; YANG *et al.*, 2016). Muitas técnicas tem relação direta com os campos da neurociência, ciência cognitiva, psicologia cognitiva, neurolinguística e psicofisiológica. Como uma variedade de aplicações, muitas técnicas de EEG usadas em pesquisas, não são padronizadas suficientemente para uso clínico, sobretudo, em estudos relacionadas com a deficiência mental, tais como: transtorno de processamento auditivo (DPA), transtorno de déficit de atenção e hiperatividade (TDAH), distúrbio do déficit de atenção (DDA ou ADHD em Inglês) está se tornando mais amplamente conhecido (CUELLAR *et al.*, 2016; JESTROVIĆ *et al.*, 2015).

Devido a diversos fatores o EEG está relacionado a diversos campos da ciência entre estes é possível citar:

Neurociência (ou neurobiologia): é o estudo científico do sistema nervoso. É um ramo multidisciplinar da biologia, que combina fisiologia, anatomia, biologia molecular, biologia do desenvolvimento, citologia, modelagem matemática e psicologia para entender as propriedades fundamentais e emergentes de neurônios e circuitos neurais (GRAEFF, 2003).

A ciência cognitiva: é o estudo interdisciplinar e científico da mente e seus processos. Ele examina a natureza, as tarefas e as funções da cognição em um sentido amplo (ALLEN, 1991). Tem consigo inputs teóricos para o desenvolvimento dessa ciência. O modelo neuronal, pautado nas operações de uma célula nervosa e suas conexões, mostrando que podiam ser modelados em termos da lógica. As síndromes neuropsicológicas, investigando o perfil das capacidades cognitivas que resultavam de danos ao cérebro humano. Baseia-se também na teoria da informação, sugerindo que a informação pode ser totalmente divorciada de qualquer conteúdo ou assunto específico, simplesmente com a decisão única entre duas alternativas igualmente plausíveis (STILLINGS *et al.*, 1995).

Psicologia cognitiva: é o estudo de processos mentais como "atenção, uso da linguagem, memória, percepção, resolução de problemas, criatividade e pensamento". Grande parte do trabalho derivado da psicologia cognitiva foi integrado em várias outras disciplinas modernas de estudo psicológico, incluindo psicologia educacional, psicologia social, psicologia da personalidade, psicologia anormal, psicologia do desenvolvimento e economia (MYERS, 2003).

Neurolinguística: é o estudo dos mecanismos neurais no cérebro humano que controlam a compreensão, produção e aquisição da linguagem. Como um campo interdisciplinar, a neurolinguística desenha métodos e teorias de campos como neurociência, lingüística, ciência cognitiva, distúrbios da comunicação e neuropsicologia (KUTAS; HILLYARD, 1980).

Psicofisiologia: é o ramo da psicologia que se ocupa das bases fisiológicas dos processos psicológicos. Embora a psicofisiologia tenha sido um amplo campo geral de pesquisa nas décadas de 1960 e 1970, ela agora se tornou bastante especializada e se ramificou em subespecializações, como psicofisiologia social, psicofisiologia cardiovascular, psicofisiologia cognitiva e neurociência cognitiva (RAMOS, 2008).

2.5 Vantagens do EEG

São muitos os métodos usados para se compreende as funções cerebrais (ressonância magnética funcional, tomografia por emissão de pósitrons, magnetoencefalografia, espectroscopia de ressonância magnética nuclear, eletrocorticografia, tomografia computadorizada de emissão de fóton único, espectroscopia de infravermelho próximo e sinal óptico relacionado com eventos), mas mesmo assim, com uma baixa resolução espacial o EEG possui muitas vantagens sobre muitas dessas técnicas acima citadas. Possui baixo custo de hardware, impede a disponibilidade limitada de tecnólogos para fornecer atendimento imediato em hospitais de alto tráfego, tem uma resolução temporal muito alta, na ordem de milissegundos, em vez de segundos, registra em taxas de amostragem entre 250 e 2000 Hz em ambientes clínicos e de pesquisa, é tolerante ao movimento do sujeito, ao contrário da maioria das outras técnicas de neuroimagem, não envolve a exposição a radioligandos, ao contrário da tomografia por emissão de pósitrons, pode ser usado em indivíduos incapazes de fazer uma resposta motora, podem ser detectados mesmo quando o assunto não está atendendo aos estímulos, e também pode rastrear mudanças cerebrais durante diferentes fases da vida (MURPHY; BRUNBERG, 1997; VESPA *et al.*, 1999; SCHULTZ, 2012; SCHENCK, 1996; O'REGAN *et al.*, 2010; HAMAINEN *et al.*, 1993; HINTERBERGER *et al.*, 2003; SERENO *et al.*, 1998; FEINBERG, 2012).

Evidentemente, o EEG também apresenta desvantagens quando comparados com outros métodos, sobretudo no que se espera da técnica. Algumas desvantagens: baixa resolução espacial no couro cabeludo, mede fracamente a atividade neural que ocorre abaixo das camadas superiores do cérebro (o córtex), não é possível identificar locais específicos no cérebro em que vários neurotransmissores, drogas, etc. podem ser encontrados, muitas vezes leva muito tempo para conectar um paciente ao EEG, pois ele exige a colocação precisa de dezenas de eletrodos na cabeça e o uso de vários géis, soluções salinas e / ou pastas para mantê-los no lugar (embora possa ser usado um tampão), a relação sinal-ruído é ruim, portanto é necessário uma análise sofisticada dos dados, e um número relativamente grande de sujeitos para extrair informações úteis do EEG (SRINIVASAN, 1999; SCHLOGL *et al.*, 2002).

2.6 Funções Cerebrais: Técnicas Existentes

Uma breve descrição sobre algumas técnicas para estudar as funções cerebrais existentes.

Ressonância magnética funcional: Essa técnica mede a atividade cerebral através da detecção de alterações associadas ao fluxo sanguíneo. Ampara-se no fato de que o fluxo sanguíneo cerebral e a ativação neural estão acoplados. Baseiam-se no princípio de que os

núcleos dos átomos, que em estado normal giram com spins em orientações randômicas, quando colocados num campo magnético, se orientam. Se a esses núcleos orientados for aplicado um pulso de rádio-freqüência, eles absorvem e emitem uma quantidade de energia cuja freqüência precisa de ressonância depende das próprias características do núcleo e do campo magnético. Quando o cérebro é submetido a um campo magnético ao qual uma freqüência de rádio é superimposta, seus tecidos emitem freqüências diferentes por terem constituições físico-químicas distintas. Isso torna possível diferenciar os sinais emitidos pela substâncias cinzenta ou branca e também pelo líquido céfalo-raquidiano, gerando uma imagem de grande precisão espacial. No caso da RM funcional, essa diferenciação permite detectar alterações da atividade neuronal local com a precisão de milímetros. O processamento de informações num determinado circuito cerebral traduz-se por uma intensificação da atividade neuronal, com conseqüente influxo de sangue oxigenado.

Tomografia por emissão de pósitrons: é uma técnica de imagem funcional de medicina nuclear que é usada para absorver processos metabólicos no corpo como uma ajuda para o diagnóstico da doença. O sistema detecta pares de raios gama emitidos indiretamente por um radionuclídeo emissor de pósitrons, mais comumente o flúor-18, que é introduzido no corpo em uma molécula biologicamente ativa chamada traçador radioativo.

Magnetoencephalography: é uma técnica de neuroimagem funcional para o mapeamento da atividade cerebral através da gravação de campos magnéticos produzidos por correntes elétricas que ocorrem naturalmente no cérebro, usando magnetômetros muito sensíveis. Matrizes de SQUIDS (dispositivos de interferência quântica supercondutores) são atualmente o magnetômetro mais comum, enquanto o magnetômetro SERF (spin exchange-free-relax) está sendo investigado para futuras máquinas.

Espectroscopia de ressonância magnética nuclear (RMN): comumente conhecida como espectroscopia ou espectroscopia de ressonância magnética, é uma técnica espectroscópica para observar campos magnéticos locais ao redor de núcleos atômicos. A amostra é colocada em um campo magnético e o sinal de RMN é produzido pela excitação da amostra de núcleos com ondas de rádio em ressonância magnética nuclear, que é detectada com receptores de rádio sensíveis.

Eletrocorticografia (ECoG), ou eletroencefalografia intracraniana (iEEG): é um tipo de monitoramento eletrofisiológico que utiliza eletrodos colocados diretamente na superfície exposta do cérebro para registrar a atividade elétrica do córtex cerebral. Em contraste, eletrodos de eletroencefalografia (EEG) convencionais monitoram essa atividade de fora do crânio.

Tomografia computadorizada de emissão de fóton único (SPECT, ou menos comumente, SPET): é uma técnica tomográfica de medicina nuclear que utiliza raios

gama. É muito semelhante à imagiologia planar da medicina nuclear convencional utilizando uma câmara gama (isto é, cintigrafia).

Espectroscopia no Infravermelho Próximo (NIRS): é um método espectroscópico que utiliza a região do infravermelho próximo do espectro eletromagnético (de 780 nm a 2500 nm). Aplicações típicas incluem diagnósticos médicos e fisiológicos e pesquisa incluindo glicemia, oximetria de pulso, neuroimagem funcional, medicina esportiva, treinamento esportivo de elite, ergonomia, reabilitação, pesquisa neonatal, urologia (contração da bexiga) e neurologia (acoplamento neurovascular).

Sinal Óptico Relacionado ao Evento (EROS): é uma técnica de varredura do cérebro que utiliza a luz infravermelha através de fibras ópticas para medir mudanças nas propriedades ópticas de áreas ativas do córtex cerebral. O sinal óptico rápido (EROS) mede as alterações na dispersão da luz infravermelha que ocorrem com a atividade neural.

Séries Temporais

3.1 Análise de Séries Temporais: aspectos gerais

Em vários problemas da matemática e de suas aplicações, busca-se uma função f que cumpra certas condições. É frequente, nesse caso, a partir desta função obter-se uma sequência de dados f_1, f_2, \dots, f_n , que podem ser independentes da situação (evento) anterior ou não. Como parte dos procedimentos estatísticos, o estudo de séries temporais possui destaque evidente, e neste âmbito, pelo simples fato da ordem dos dados ser crucial, o uso de técnicas específicas ganha destaque.

Dados de séries temporais surgem em vários campos do conhecimento como: na Economia (preços diários de ações, taxa mensal de desemprego, produção industrial), na Medicina (eletrocardiograma, **eletroencefalograma**), em Meteorologia (precipitação pluviométrica, temperaturas diárias, velocidade do vento), etc. É possível encontrar na literatura uma infinidade de publicações que abordam o conceito e procedimentos da análise de séries temporais, destaque para [Fonseca *et al.* \(2000\)](#), [Ehlers \(2009\)](#), [Morettin \(2004\)](#), entre outros.

[Morettin \(2004\)](#), afirma que matematicamente, podemos definir uma série temporal como um conjunto de valores $y_1, y_2, y_3, \dots, y_i$, para a variável de intervalo y registrados no tempo $t_1, t_2, t_3, \dots, t_i$. Então, a variável y pode ser expressa em função do tempo.

$$y = f(t) \tag{3.1}$$

[Esquivel *et al.* \(2013\)](#), fortalece os conceitos acima explicando que o estudo de série temporal surge com a necessidade de se obter previsões precisas de eventos futuros ou suas consequências, sejam elas epidemiológicas, econômicas, climáticas ou de qualquer natureza. Sendo assim, algumas características são de extrema importância para um estudo de série temporal e como destaque temos:

- Observações correlacionadas são mais difíceis de analisar e requer técnicas específicas;
- É necessário levar em conta a ordem temporal das observações;
- Fatores complicadores como presença de tendências e variações sazonais ou cíclicas

podem ser difíceis de estimar ou remover;

- A seleção de modelos podem ser bastante complicada e de difícil interpretação;
- É mais difícil de lidar com observações perdidas e dados discrepantes, devido a natureza sequencial.

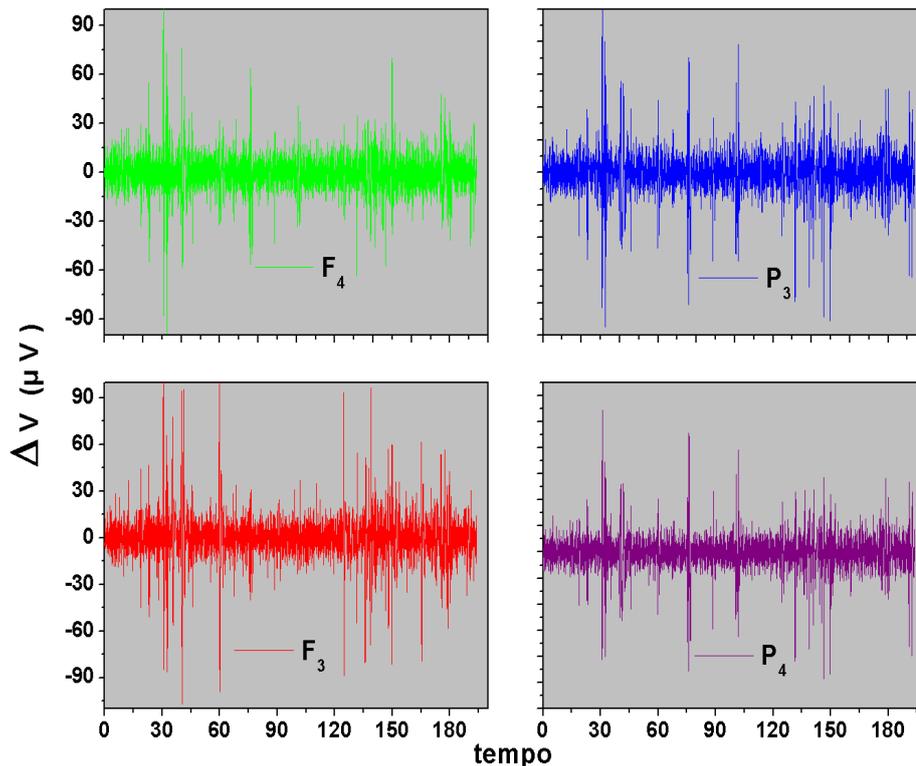


Figura 3.1: Temos aqui dados brutos do sinal de EEG. Referem-se ao estímulo realizado pela leitura de um pequeno texto. As séries temporais geradas, foram os bio-eletrodos escolhidos: F_3 , F_4 , P_3 , P_4 . F_3 , F_4 localizado na parte frontal, enquanto P_3 , P_4 fica localizado na parte parietal do encéfalo. Cada série gerada possui 19.980 pontos. Experimento próprio usando o aparelho NEUROMAP EQSA226, sistema internacional (10 – 20). Clínica Cardiovida.

Para [Morettin \(2004\)](#), as séries temporais podem ser terminologicamente classificadas como:

- Discretas, ou seja, quando T é um conjunto de observações finitas de pontos, ou seja, $Z = 1, 2, 3, \dots, T$, definido por (Z_T) .
- Contínuas, ou seja, quando as observações são realizadas continuamente no tempo, $T = [t : t_1 < t < t_2]$. Por exemplo, medições durante dois minutos de um eletrocardiograma.

- Determinísticos, ou seja, quando os valores futuros de uma série são definidos por meio de uma função matemática.
- Estocástica, ou seja, quando a série possui uma ou mais variáveis como entrada e saída. Como exemplo, podemos citar o método de Monte Carlo no cálculo de integrais ou experimentos amostrais.
- Multivariado, ou seja, quando a série temporal é representada por um vetor de ordem k , definido por: $Z_1(t), \dots, Z(k), t < T$.

[Ehlers \(2009\)](#), coloca como objetivo inicial da análise de séries temporais a realização de inferências sobre as propriedades ou características básicas do mecanismo gerador do processo estocástico das observações da série. Assim, através da abstração de regularidades contidas nos fenômenos observáveis de uma série temporal existe a possibilidade de se construir um modelo matemático como uma representação simplificada da realidade. Após a formulação do modelo matemático, obtido pela seleção entre as alternativas de classes de modelos identificadas como apropriadas para essa representação e subsequente estimação de seus parâmetros, é possível utilizá-lo para testar alguma hipótese ou teoria a respeito do mecanismo gerador do processo estocástico e realizar a previsão de valores futuros da série temporal.

[Morettin \(2004\)](#), afirma que uma previsão é uma manifestação relativa a sucessos desconhecidos em um futuro determinado. A previsão não constitui um fim em si, mas um meio de fornecer informações e subsídios para uma consequente tomada de decisão, visando atingir determinados objetivos. Considerando um conjunto de observações de uma série temporal coletadas até o instante t e de um modelo que represente esses fenômenos, a previsão do valor da série no tempo $t + h$ pode ser obtida.

[Souza \(1989\)](#), dependendo do valor assumido pelo horizonte de previsão, classificam as previsões dos valores futuros de uma série temporal como de curto, médio ou longo prazo. Desse modo, diante da possibilidade de existência de diferentes horizontes de previsão, especifica técnicas distintas para prognosticar os valores futuros de uma série temporal:

- previsão múltiplos passos: esta abordagem, adotada para longos horizontes de previsão, procura identificar as tendências gerais e os pontos de inflexão mais relevantes na série temporal. Na previsão múltiplos passos, o conjunto de valores correntes é empregado na realização da previsão para determinado instante; esta previsão é, então, introduzida entre as observações passadas, compondo, desta forma, um novo conjunto de dados, sobre o qual será obtida a previsão do tempo subsequente.
- previsão simples passo: nesta técnica não há incorporação de previsões aos dados utilizados para encontrar a próxima previsão, sendo esta, independente dos valo-

res anteriormente previstos. A previsão é feita apenas para o período de tempo imediatamente posterior ao atual, a partir das observações da série temporal.

Para Ehlers (2009), a garantia da otimização das previsões de uma série temporal somente é alcançada adotando como horizonte de previsão o instante de tempo imediatamente subsequente à origem t . Naturalmente, a investigação do poder preditivo do modelo especificado como o mais adequado para explicar o mecanismo gerador das observações de uma série temporal é um processo empírico de verificação, visto que são feitas comparações entre as previsões e as observações, a fim de confirmar a habilidade do modelo matemático em descrever a estrutura definida pelos dados da série temporal analisada. É importante salientar que o caráter previsional de um determinado modelo, para Morettin (2004), não pode ser sustentado quando forem identificadas mudanças estruturais nas observações obtidas a partir da origem, em relação àquelas utilizadas para a elaboração do modelo.

Ehlers (2009), traz várias abordagens ao estudo de uma série temporal, entre elas podemos citar as técnicas descritivas, os modelos probabilísticos e os métodos não paramétricos. Salienta que as técnicas descritivas estão diretamente associadas a gráficos e identificação de padrões. Já os modelos probabilísticos, estão associados à seleção, comparação, adequação, estimação e predição, e os modelos não paramétricos, estes com a função de alisamento ou suavização. Além de outras abordagens, como: modelos de espaço de estados, modelos não lineares, séries multivariadas, estudos longitudinais, processos de longa dependência e modelos para volatilidade.

Como exemplo do modelo espaço de estado, podemos citar a transformada de Laplace. Essa transformada se destaca pelo fato dos seus limites de integração se tornar conveniente para problemas que possuem dependência temporal. Esta técnica está presente quase sempre em estudos da dinâmica e do controle de processos. É usada em sistemas lineares e permite converter equações diferenciais comuns em equações algébricas. A transformada de Laplace tem seu nome em homenagem ao matemático francês Pierre Simon Laplace.

3.1.1 Tendência

Em geral segundo Fonseca *et al.* (2000), uma série apresenta crescimento ou decréscimo com diversos tipos de padrões, a esses padrões dar-se o nome de tendência. Esses comportamentos podem ser definidos na figura 3.3. Podemos verificamos em (a) clara tendência de crescimento bem como um padrão sazonal ao longo dos anos. Em (b) temos a existência de padrão cíclico. (c) apresenta algumas alterações estruturais em torno do ano de 1900. Já (d) apresenta tendência com padrão de crescimento, porém a amplitude do padrão sazonal aumenta bastante a partir de 1971.

Modelos clássicos de séries temporais $[Z_t, t = 1, \dots, N]$ supõem basicamente três componentes importantes. Uma tendência T_t , uma componente sazonal S_t e um termo aleatório a_t , sendo que: $Z_t = T_t + S_t + a_t$, com $t \in N$ e a_t com média zero e variância constante. Se $([a_t, t = 1, \dots, N])$ são observações de por exemplo um ruído branco (sinal aleatório com igual intensidade em diferentes frequências), então $E(a_t, S_t) = 0, s \neq t$, nos poderemos, eventualmente, relaxar esta suposição, tomando a_t como um processo estacionário. Segue-se que $[Z_t]$ será não estacionária ou divergente.

O interesse principal em considerar um modelo do tipo $Z_t = T_t + S_t + a_t$, será o de estimar T_t e construir a série livre de sazonalidade ou de sazonalidade ajustada. Isto é, se \hat{S}_t é uma estimativa de S_t , sendo, $Z_t^{SA} = Z_t - \hat{S}_t$ (série sazonal ajustada).

As componentes T_t e S_t , em geral, são bastante relacionadas e a influência da tendência sobre a componente sazonal pode ser muito forte, por duas razões, conforme (PIERCE, 1979):

- (a) métodos de estimação de S_t podem ser bastante afetados se não levarmos em conta a tendência;
- (b) a especificação de S_t depende da especificação de T_t .

Sendo assim, não devemos isolar uma das componentes sem tentar isolar a outra. Estimando-se T_t e S_t e subtraindo de Z_t obteremos uma estimativa da componente aleatória a_t . Será $Z_t = T_t + a_t$, onde a_t é ruído branco, com média zero e variância σ_a^2 .

Existem vários métodos de se estimar T_t . Os mais utilizados consistem em:

- (i) ajustar uma função do tempo, com um polinômio, uma exponencial ou outra função suave de t ;
- (ii) suavizar (ou filtrar) os valores da série ao redor de um ponto, para estimar a tendência naquele ponto.

Estimando-se a tendência através de \hat{T}_t , podemos obter a série ajustada ou livre de tendência, $Y_t = Z_t - \hat{T}_t$.

Um procedimento que é também utilizado para eliminar a tendência de uma série é aquele de tomar diferenças, como foi definido pela figura 3.2. Pierce (1979) afirma que, normalmente para séries econômicas por exemplo, a primeira diferença $\Delta Z_t = Z_t - Z_{t-1}$, já é estacionária.

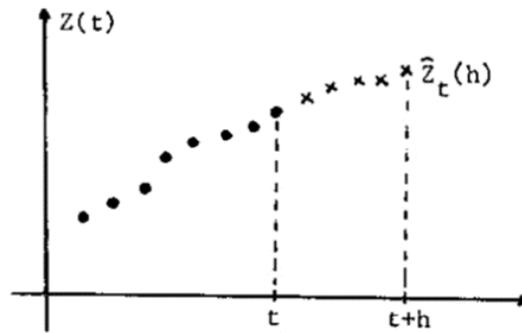


Figura 3.2: Observações de uma série temporal com previsões de origem t e horizonte h (MORETTIN; TOLOI, 1981).

Uma informação importante para as observações e definir o erro quadrático médio previsto. Este cálculo mostra que pelo menos para séries temporais gaussianas, a previsão de $Z(t+h)$ em termos de X_n é mais precisa a medida que $|t(h)|$ se aproxima de 1. Neste caso, pode ser definido como $E[Z(t+h) - \hat{Z}_t(h)]^2$.

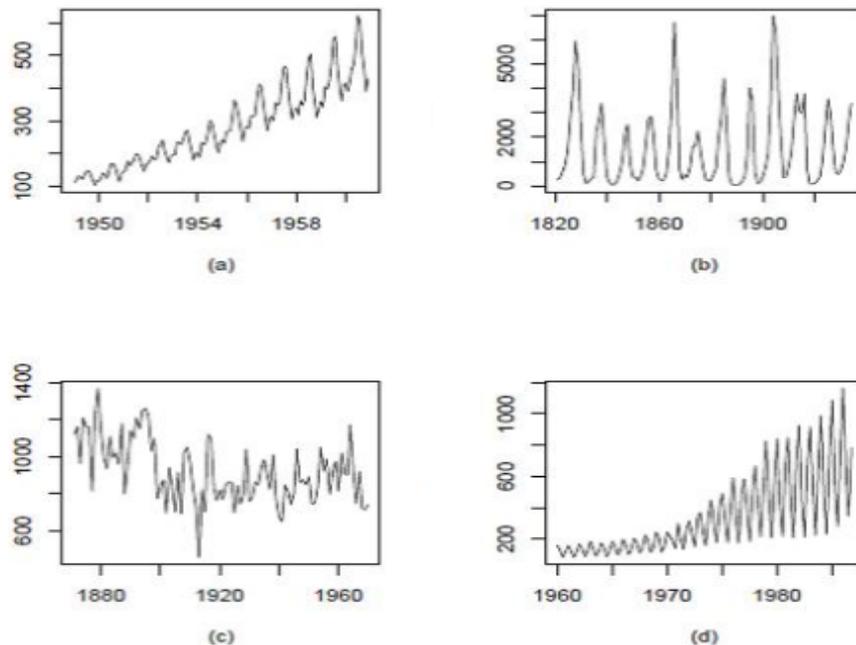


Figura 3.3: Padrões característicos em séries temporais (EHLERS, 2009).

3.1.2 Sazonalidades

Sazonalidade é qualquer evento ou comportamento que acontece sempre em uma mesma época dentro de um intervalo de tempo específico, ou seja, um comportamento ou padrão que se repete de tempos em tempos. É importante destacar que a sazonalidade pode acontecer dentre vários diferentes intervalos de tempo, ou seja, existem sazonalidades dentro

do dia, semana, mês ou ano ou até a sazonalidade por conta de eventos especiais.

Vale salientar, em específico, que para sinais eletroencefalográficos o padrão sazonal torna-se evidente para tempos da ordem de milissegundos, segundos ou minutos. Já no ramo comercial, como exemplo, é muito natural esperar que as vendas mensais de brinquedos terão um pico no mês de dezembro e talvez um pico secundário em outubro. Este padrão possivelmente se repetirá ao longo de vários anos.

Alguns modelos sazonais com destaque em aplicações com séries temporais recebe destaque: sazonalidades determinísticas, funções trigonométricas, sazonalidades estocásticas, essa com variável endógena e defasagem sazonal no modelo ARMA periódicos, também o modelo ARMA sazonal.

Destaque também para tipos sazonais como:

- Sazonalidade Aditiva: Neste tipo as séries apresentam flutuações sazonais dentro de um padrão mais ou menos constante, não importando o nível global da série.
- Sazonalidade Multiplicativa: O tamanho das flutuações varia dependendo do nível global da série.

3.1.3 Técnicas Descritivas

[Ehlers \(2009\)](#), no contexto de séries temporais, o estudo representado graficamente dos dados ao longo da pesquisa é de extrema importância. Comportamentos associados como crescimento e decrescimento, padrões cíclicos entre outros são muito relevantes e facilitadores. Desta forma, a construção gráfica temporal deve ser sempre o primeiro passo e sobretudo antecedendo qualquer análise ou tomada de decisão.

Propriedades importantes de uma série temporal assume uma forma de composição clássica, isto é,

$$X_t = T_t + S_t + a_t \quad (3.2)$$

onde T_t é a componente tendência, C_t é a componente cíclica ou sazonal e R_t a componente aleatória. Para tal a componente cíclica se repete a cada intervalo fixo, e as variações

periódicas podem ser captadas por esse tipo de componente.

Por não apresentar um consenso por partes do autores citados no embasamento teórico desta pesquisa, podemos associar tendência como uma mudança de longo prazo no nível médio da série. Uma forma simples de verificar tendência pode ser visto por:

$$X_t = \alpha + \beta t + \epsilon_t, \quad (3.3)$$

onde α e β são constantes a serem estimados e ϵ é o erro aleatório, com média zero. Sendo que o nível médio em um intervalo t pode ser dado por:

$$m_t = \alpha + \beta t. \quad (3.4)$$

Um modo geral de se lidar com dados sazonais com tendências é ajustar um polinômio de grau n , sendo n de $1^\circ, 2^\circ, \dots$. Ver figura 3.4.

$$X_t = \beta_0 + \beta_1 + \dots + \beta_p t^p + \epsilon_t \quad (3.5)$$

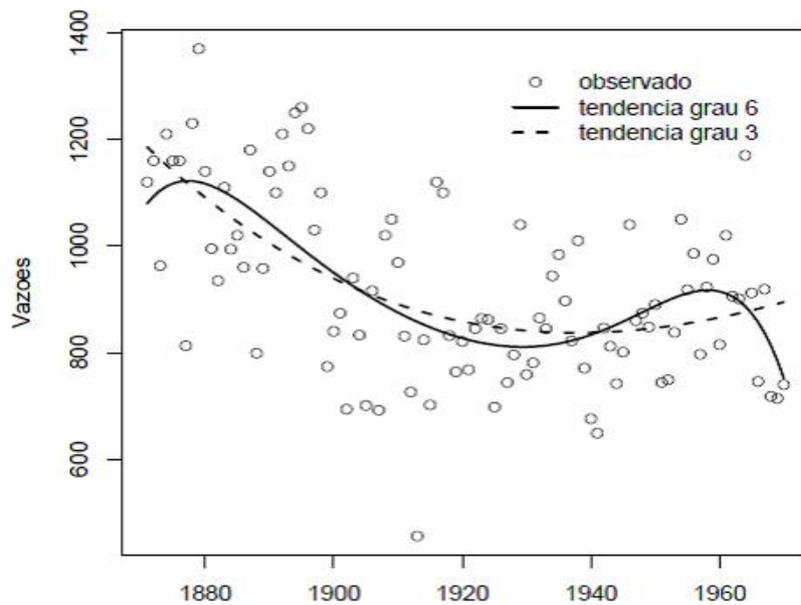


Figura 3.4: Medições anuais de vazões do Rio Nilo em Ashwan entre 1871 e 1970 (pontos), com polinômios de graus 3 e 6 ajustados por mínimos quadrados (EHLERS, 2009).

3.1.4 Autocorrelação

Uma importante ferramenta para se identificar as propriedades de uma série temporal consiste de uma série de quantidades chamadas de coeficiente de autocorrelação amostral. Conforme Souza & Camargo (2004), a idéia do coeficiente de correlação é similar a correlação para n pares de observações de variáveis, desta forma definimos o coeficiente de correlação amostral como sendo:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (3.6)$$

Para tanto, queremos medir a correlação entre as observações de uma mesma variável em diferentes horizontes de tempo. Assim, dado n observações x_1, \dots, x_n de uma série temporal discreta podemos formar os pares $(x_1, x_2), \dots, (x_{n-1}, x_n)$. Considerando x_1, \dots, x_{n-1} e x_2, \dots, x_n como duas variáveis o coeficiente de correlação entre elas é dado por:

$$r = \frac{\sum_{t=1}^{n-1} (x_t - \bar{x}_1)(x_{t+1} - \bar{x}_2)}{\sqrt{\sum_{t=1}^{n-1} (x_t - \bar{x}_1)^2 \sum_{t=1}^{n-1} (x_{t+1} - \bar{x}_2)^2}}. \quad (3.7)$$

em que as médias amostrais são denotadas pelas seguintes expressões:

$$\bar{x}_1 = \sum_{t=1}^{n-1} \frac{x_t}{n-1} \quad (3.8)$$

e

$$\bar{x}_2 = \sum_{t=2}^n \frac{x_t}{(n-1)}. \quad (3.9)$$

Como o coeficiente r mede as correlações entre observações sucessivas, assim ele é chamado de coeficiente de autocorrelação ou coeficiente de correlação serial. Vale salientar que é usual simplificar a equação 3.7 utilizando-se médias de todas as observações (EHLERS, 2009).

3.1.5 Modelos Probabilísticos e Processos Estacionários

Para Morettin (2008), um processo estocástico pode ser definido como um conjunto de variáveis aleatórias ordenas no tempo e definidas em um conjunto de T pontos, que pode ser contínuo ou discreto.

Uma maneira de caracterizar um processo estocástico é através da distribuição de probabilidade conjunta de $X(t_1), \dots, X(t_k)$ em um intervalo de tempo t_1, \dots, t_k , para qualquer valor de k . Considerada uma tarefa complexa e que possivelmente costuma descrever um processo puramente estocástico, podendo ser definida pela funções: média 3.10, variância 3.11 e autocovariância 3.12.

$$\mu(t) = E[X(t)], \quad (3.10)$$

$$\sigma^2(t) = Var[X(t)] \quad (3.11)$$

e

$$\gamma(t_1, t_2) = E[X(t_1) - \mu(t_1)][X(t_2) - \mu(t_2)] \quad (3.12)$$

Para $t_1 = t_2$, a função de variância se torna um caso especial da função de autocovariância. Em momento de ordem mais alta do processo também são definidos, porém não raramente utilizados na prática e as funções média e covariância são iguais.

Conforme [Ehlers \(2009\)](#), um processo estocástico é dito estacionário ou de ordem fracamente estacionária se sua função média é constante e sua função de autocovariância depende apenas da defasagem. A defasagem é caracterizada em um processo de análise temporal da distribuição conjunta X_{t_1} e X_{t_2} da distância $t_2 - t_1$, representado pelas equações:

$$Cov[X[t], X(t + \tau)] = \gamma(\tau) \quad (3.13)$$

Ainda para [Ehlers \(2009\)](#), nenhuma outra suposição é feita a respeito dos momentos de ordem mais alto.

3.1.6 Método das Médias Móveis

O método das médias móveis tem com objetivo suavizar as variações da série por meio de um processo de sucessivas médias (aritmética, geométrica, etc.). Sendo assim a tendência não é forçada adapta-se a qualquer função matemática, e a priori o método não permite previsões. Levando em conta que o método das médias móveis é considerado um bom recurso para suavizar as flutuações sazonais em séries de curto prazo. O método apresenta uma característica importante que é, quanto maior a ordem da média, maior a suavização das variações (cíclicas sazonais ou aleatórias). Uma das desvantagens do método é o desaparecimento dos dados iniciais e do fim da série, seu uso pode gerar momentos cíclicos ou de comportamentos que não existam nas séries originais, sobretudo as médias móveis são fortemente afetados por valores externos ([DIGGLE, 1990](#); [EVERITT, 1995](#)).

Uma média móvel simples sobre n elementos é constituída das médias não ponderadas dos subconjuntos de n elementos em um conjunto de dados. Por exemplo, dado um conjunto de M elementos p_1, \dots, p_M , o primeiro elemento da média movel é

$$MM = \frac{p_1 + \dots + p_n}{n}$$

$$MM = \frac{1}{n} \sum_{i=1}^n p_i$$

O segundo é

$$MM' = \frac{p_2 + \dots + p_{n+1}}{n}$$

$$MM' = \frac{1}{n} \sum_{i=2}^{n+1} p_i$$

ou ainda $MM' = MM + \frac{p_{n+1}}{n} - \frac{p_1}{n}$, e assim por diante, até o subconjunto.

3.1.7 Método dos Mínimos Quadrados

O método dos mínimos quadrados é uma abordagem padrão na análise de regressão para aproximar a solução de sistemas sobredeterminados (Um sistema superdeterminado é quase sempre inconsistente (não tem solução) quando construído com coeficientes aleatórios.), isto é, conjuntos de equações nas quais existem mais equações do que incógnitas. "Mínimos quadrados" significa que a solução global minimiza a soma dos quadrados dos resíduos nos resultados de cada equação (STIGLER, 1981; WIENS, 1995).

A aplicação mais importante está no ajuste de dados. O ajuste consiste no processo de construção de uma curva, ou função matemática, que tem o melhor ajuste para uma série de pontos dados, possivelmente sujeitos a restrições. O ajuste de curva pode envolver tanto a interpolação, em que é necessário um ajuste exato aos dados, ou suavização, em que uma função "suave" é construída que se encaixa aproximadamente os dados.

O melhor ajuste no sentido de mínimos quadrados minimiza a soma dos resíduos quadrados (um resíduo sendo: a diferença entre um valor observado e o valor ajustado fornecido por um modelo). Quando o problema tem incertezas substanciais na variável independente (a variável x), então os métodos de regressão simples e de mínimos quadrados têm problemas; nesses casos, a metodologia necessária para ajustar modelos de erros em variáveis pode ser considerada, em vez daquela para mínimos quadrados (WIENS, 1995).

Problemas de mínimos quadrados se dividem em duas categorias: lineares ou mínimos quadrados ordinários e mínimos quadrados não-lineares, dependendo se ou não os resíduos são lineares em todos os desconhecidos. O problema linear dos mínimos quadrados ocorre na análise estatística de regressão; tem uma solução de forma fechada. O problema não-linear é geralmente resolvido pelo refinamento iterativo; em cada iteração o sistema é aproximado por um linear, e assim o cálculo do núcleo é similar em ambos os casos.

Os mínimos quadrados polinomiais descrevem a variância de uma predição da variável dependente como uma função da variável independente e os desvios da curva ajustada. Na estatística matemática, os mínimos quadrados polinomiais compreendem uma ampla gama de métodos estatísticos para estimar um polinômio subjacente que descreve observações (STIGLER, 1981).

Quando as observações vêm de uma família exponencial e condições suaves são satisfeitas, estimativas de mínimos quadrados e estimativas de máxima verossimilhança são idênticas (CHARNES *et al.*, 1976). O método dos mínimos quadrados também pode ser derivado como um método de estimador de momentos.

Em resumo ao contexto, para Morettin (2008), o método dos mínimos quadrados deve seguir três passos importantes quando pretendemos determinar a tendência de uma série temporal:

1° passo: Elaborar o gráfico para definir visualmente quais funções matemáticas que podem ser ajustadas;

2° passo: Determinar o parâmetro das funções escolhidas e definimos os modelos;

3° passo: Determinar qual a função é a melhor ajustada para os dados.

Conforme os modelos médias móveis e o método dos mínimos quadrados, podemos definir algumas funções com a finalidade de analisarmos uma série temporal.

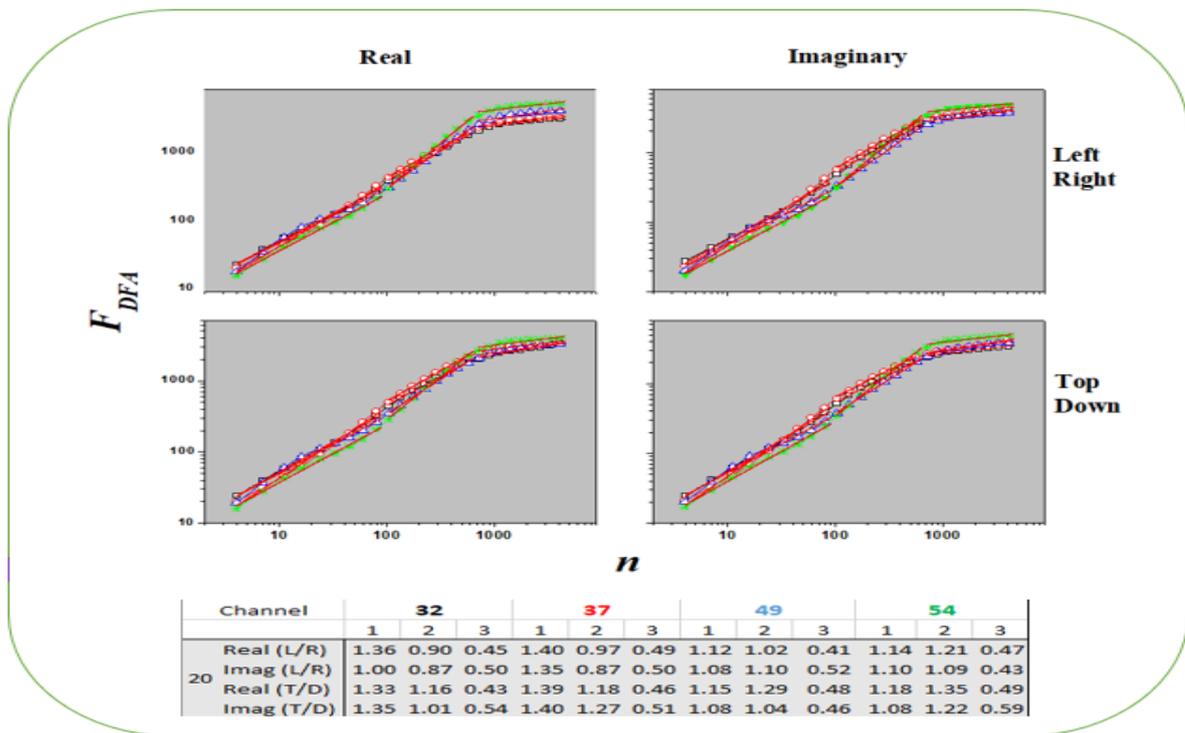


Figura 3.5: Método dos mínimos quadrados.

O ajuste realizado pelo método dos mínimos quadrados na figura 3.5, refere-se aos canais 32, 37, 49 e 54, localizados, respectivamente, na região frontal e parietal dos hemisférios esquerdo/direito do encéfalo. A proposta da aplicação aqui é atender uma das etapas previstas pelo método F_{DFA} , ou seja, interpretar o coeficiente de inclinação da reta. Mais detalhes do ajuste, pode ser visto na subseção 3.2.1. A tabela localizada na parte inferior da figura 3.5, mostra o ajuste do polinômio (de primeira ordem) encontrado para cada experimento 1, 2 e 3 (1 : $4 \leq n \leq 90$; 2 : $91 \leq n \leq 655$; 3 : $n > 655$). Os dados foram retirados do banco da Physionet, disponível no endereço: <https://www.physionet.org/>. O individuo escolhido foi o S020. A atividade realizada foi um teste motor (movimento real dos pés com duração de 2 minutos, monitorado pelo sistema BCI2000) registrado por 64 canais. Os dados da tabela foram publicados pelo autor e disponível em (ZEBENDE *et al.*, 2017).

3.1.8 Modelagem de uma Série Temporal

Vários motivos do ponto de vista teórico poderiam ser apresentados como modelagem de uma série temporal, contudo, Morettin (2004), atrelam dois motivos básicos para modelar uma série temporal, a primeira é transformar os dados originais de uma série, com a finalidade de estabilizar a variância e tornar o efeito sazonal aditivo. Uma outra razão é obter uma série mais próxima possível de uma distribuição simétrica aproximadamente

normal, ou seja, média igual a zero ou variância igual a 1.

O modelo sazonal aditivo abordado por [Morettin & Toloï \(1981\)](#), retrata duas abordagens para a combinação de todas as quatro componentes previstas por uma série temporal. Componentes essas conhecidas como: Tendência(T), Ciclo(C), Sazonalidade(S) e erro(E).

A tendência (T) descreve o comportamento da variável retratada na série temporal no longo prazo. Há três objetivos básicos na sua identificação: avaliar o seu comportamento para utilizá-lo em previsões, removê-la da série para facilitar a visualização das outras componentes, ou ainda identificar o nível da série (o valor ou faixa típica de valores que a variável pode assumir, se não for observado comportamento crescente ou decrescente no longo prazo).

A obtenção da tendência pode ser feita de três formas: através de um modelo de regressão (como o modelo linear - reta), através de médias móveis, ou através de ajuste exponencial (que não deixa de ser uma média móvel). Um forma de testar a tendência em uma série temporal é realizar a construção de seu gráfico. Através dele é possível revelar características importantes, sobretudo, observações aberrantes como outliers. Além da inspeção gráfica, é possível utilizar testes de hipóteses estatísticos para verificar se existe tendência na série. Pode ser feito de duas maneiras: (a) antes de estimar a tendência; (b) depois que se obtém uma estimativa. No caso (b) é possível efetuar testes formais somente no caso do ajuste polinomial, pois aqui ([Morettin & Toloï \(1981\)](#), [Morettin \(2004\)](#), [Morettin \(2008\)](#), [Ehlers \(2009\)](#)) temos uma teoria desenvolvida para os estimadores de mínimos quadrados.

As variações cíclicas ou ciclos (C), são flutuações nos valores da variável com duração superior a um período específico (exemplo: um ano), e que se repetem com certa periodicidade (alguns autores não incluem as variações cíclicas no modelo clássico da série temporal) que podem ser resultado de variações da economia como períodos de crescimento ou recessão, ou fenômenos climáticos, como exemplo, o El Niño (que se repete com periodicidade superior a um ano). Já as variações sazonais ou sazonalidade (S), são flutuações nos valores da variável com duração inferior a um ano, e que se repetem todos os anos, geralmente em função das estações do ano (ou em função de feriados ou festas populares, ou por exigências legais. Um bom exemplo é o período para entrega da declaração de Imposto de Renda).

Um fator também relevante que deve ser previsto nas componentes de uma série temporal, é a existência de irregularidade. Essa componente existe quando há flutuações randômicas, causadas por eventos imprevisíveis e não periódicos. Esse componente é também conhecido como ruído. Normalmente decorrem de causas naturais ou sociais como secas, greves, enchentes, guerras etc.

O modelo aditivo é recomendado, quando a sazonalidade não depende das outras componentes:

$$Y = T + C + S + E \quad (3.14)$$

Em situação em que se percebe as amplitudes sazonais variando com a tendência, o modelo mais adequado é o multiplicativo:

$$Y = T.C.S.E \quad (3.15)$$

Esse modelo pressupõe que à medida que os dados aumentam o padrão sazonal também aumenta. A maioria dos gráficos de séries temporais exhibe esse padrão. Nesse modelo, os componentes de tendência e sazonais são multiplicados e depois adicionados ao componente de erro.

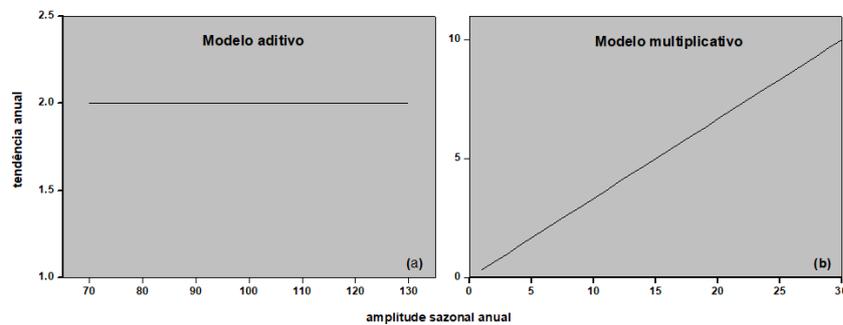


Figura 3.6: Modelo aditivo (a) / Modelo multiplicativo (b).

Pela figura 3.6 (a), observa-se que não existe uma dependência da sazonalidade sobre a tendência, o que confirma a utilização de um modelo aditivo. Na mesma figura 3.6 (b), pode-se observar que a reta ajustada apresenta uma inclinação diferente de zero em relação ao eixo das abscissas, indicando uma dependência da sazonalidade sobre a tendência e confirmando a adequabilidade de um modelo multiplicativo para o relacionamento dos componentes da série (FÁVERO *et al.*, 2003).

3.1.9 Expoente de Hurst Baseado em Escala de Intervalo

A persistência é uma das evidências mais importantes para caracterizar o padrão de uma série de fatores relacionados a sinais fisiológicos, climáticos, econômicos, entre outros. Simplesmente porque esta é uma propriedade variável de longa memória onde a dependência do tempo persistir entre as observações distantes (MICHELE *et al.*, 1998; VECCHIET *et al.*, 1996). Essas séries podem ser caracterizadas por padrões cíclicos diferentes, mas não periódicos. Mandelbrot (1982), Rundle *et al.* (1997), Hall & Wolff (1995) apontam que esses longos processos de memória têm uma dimensão fractal⁷.

Um dos testes mais utilizados para determinar a dimensão fractal de uma dada série temporal é a análise R/S proposto por (HURST, 1951), sendo a estatística R/S definida como sendo o quociente entre o intervalo das somas parciais dos desvios das médias de uma série de tempo e o desvio padrão. Hurst foi um hidrólogo que passou parte da sua vida observando e dedicando o seu cotidiano, registrando e relacionando situações vividas nas águas do rio, como exemplo, situação de esvaziamento total ou perda de água (transbordo). Ele tinha como objetivo descrever os problemas de dimensionamento da represa. O modelo de reservatório previsto pelo hidrólogo, levou em conta os seguintes passos (ver nas figuras 3.7 e 3.8 o esquema de um reservatório de água mostrando o significado das variáveis para a análise R/S , adaptado de Feder, 1988.):

- Sendo o fluxo de água que entra pelo reservatório (figura 3.8) no instante t dado por $\xi(t)$, então para um tempo τ ;

- determina-se seu valor médio, isto é, $\langle \xi \rangle_\tau = \frac{1}{\tau} \sum_{t=1}^{\tau} \xi(t)$;

- Calcula-se as seguinte variáveis;

$$X(t, \tau) = \sum_{v=1}^t \xi(v) - \langle \xi \rangle_\tau, \quad (3.16)$$

- e, nesta etapa, calcula-se a diferença entre o maior máximo e mínimo de $X(t, \tau)$, para $1 \leq t \leq \tau$, pela expressão:

$$R(\tau) = \text{Max}[X(t, \tau)] - \text{Min}[X(t, \tau)], \quad (3.17)$$

- Feito isto. Calcula-se o desvio padrão.

⁷A origem do termo dimensão fractal, foi introduzido por Mandelbrot (1982). Surge então como uma alternativa de medição já que pode assumir valores fracionários, obtendo assim o grau de complexidade de uma forma.

$$S(\tau) = \sqrt{\frac{1}{\tau} \sum_{t=1}^{\tau} [\xi(t) - \langle \xi \rangle_{\tau}]^2}, \quad (3.18)$$

- Finalmente, dividindo-se $R(\tau)$ por $S(\tau)$, tendo assim uma relação:

$$R/S = \frac{R(\tau)}{S(\tau)}. \quad (3.19)$$

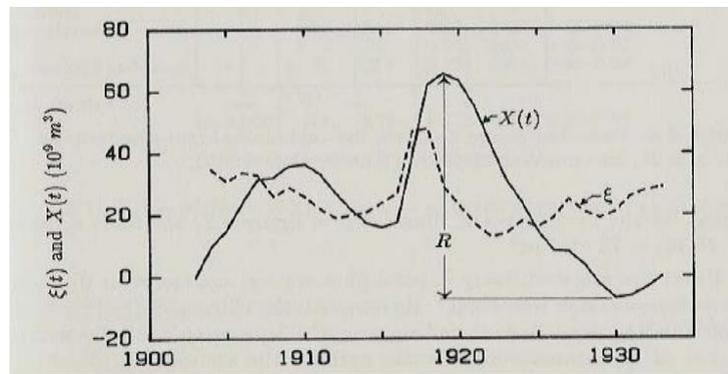


Figura 3.7: Modelo do reservatório Hurst (1951) usado para o cálculo de $X(t, \tau)$ (FEDER, 1988).

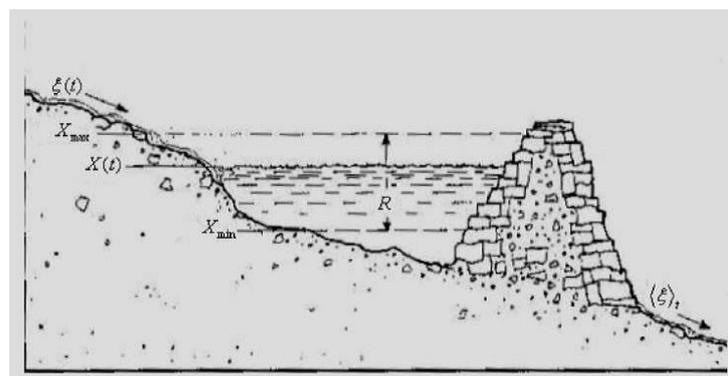


Figura 3.8: Modelo do reservatório Hurst (1951) usado para o cálculo de $R(\tau)$ (FEDER, 1988).

Hurst, percebeu, que se considerarmos distintos tamanhos de τ a relação R/S , segue uma lei de potência, do tipo:

$$R/S = (\tau/2)^H, \quad (3.20)$$

onde H representa o expoente de Hurst.

Esta análise é robusta no sentido de que o seu comportamento só é influenciada pela longa persistência, detecta ciclos não periódico que são de maior ou igual ao do período de amostra e é também um método sensível para a detecção de comprimento em processos aleatórios. Mandelbrot (1982), Rundle *et al.* (1997), Hall & Wolff (1995) indicam que a análise de R/S é também capaz de deduzir que muitos fenômenos naturais são processos aleatórios não independentes, com significativa estatística.

De posse do modelo R/S , sabe-se que $0.0 \leq H \leq 1.0$, com as seguintes propriedades, se $H = 0.5$ a série é denotada como browniana ou descorrelacionada (aleatória), se o valor de H estiver entre 0 e 0.5, pode-se inferir que a série apresenta um comportamento de antipersistência, ou seja, um aumento de tendência implica na série redução futura ou uma redução na série implica aumento futuro. Estando o valor de H entre 0.5 e 1.0, a série é dita persistente.

Para Zebende *et al.* (2013), Silva *et al.* (2015), o modelo estatístico R/S proposto por Hurst em 1951, originalmente aplicado em hidrologia, tem aplicação em diversas áreas como exemplo: estudo de temperaturas globais, volatilidade de ativos financeiros entre outros. O método analiticamente necessita de filtragem antes da aplicação com objeto de retirada de tendência.

3.2 Métodos para Séries Temporais não Estacionárias

3.2.1 Detrended Fluctuation Analysis - DFA

Em estudo com autocorrelação, verificamos que determinadas variáveis têm a propriedade de apresentar correlações entre si, em função de influências do passado que geram consequências em dados correntes. Como exemplo, podemos citar a vulnerabilidade das variáveis econômicas de medidas impostas pelos governos que geralmente provocam efeito no presente e em momentos subseqüentes. Se não considerados, estes efeitos podem comprometer o estudo de comportamento da variável. Para identificar tal situação, além da técnica da autocorrelação, destaca-se como uma importante ferramenta o método DFA (Detrended Fluctuation Analysis).

O método DFA foi proposto por Peng (1994) tem-se demonstrado muito útil em diversas áreas de aplicação, a priori, o método é uma derivação do expoente R/S proposto por Hurst (1951) e permite identificar a auto-afinidade⁸ e também correlação de longo alcance em sinais com tendências polinomiais que possivelmente esteja indeterminando informações na correlação. Tal método tem apontado como promissor para análise em escalas características, principalmente em variáveis possíveis de vulnerabilidade por influências externas, que é uma especulação gerando uma grande instabilidade nas relações monetárias e financeiras internacionais. Pela facilidade de detectar influências do passado que geram consequências correntes, o DFA tem demonstrado muito perceptível e acompanhado de um vasto campo de aplicação, tais como: Zebende G.F; Machado Filho (2009), Freitas (2009), Pedron (2007), Talkner P.; Weber (2000), Filho (2005), Vassoler (2012), Peng (1992), Peng (1998), Peng (1995), Peng (1994), Zebende *et al.* (2016), Zebende *et al.* (2017) entre tantos outros. Conforme Peng (1994), para que o método DFA seja aplicado é necessário seguir os passos abaixo descrito.

Considerando um série temporal da variável $Y_i = Y_1, \dots, Y_2$, com $i = 1, \dots, N_{max}$ e N_{max} o número total de pontos na série temporal. Como exemplo: a intensidade do sinal de EEG correlacionado. Pode ser o canal O_1 do hemisfério esquerdo, região occipital de um individuo com aproximadamente 20 mil pontos, ver Figura 3.9.

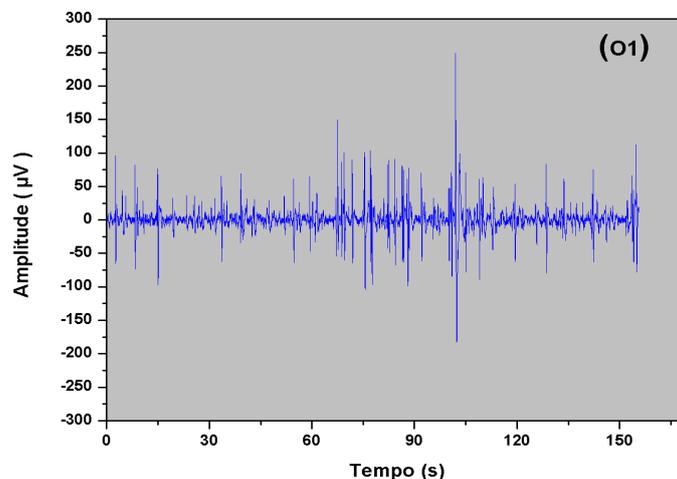


Figura 3.9: Dados brutos do canal O_1 , hemisfério esquerdo, região occipital do individuo $S049$. Disponível em <<https://www.physionet.org/>>.

Então, com essa série temporal de tamanho N_{max} , o passo agora para entendimento do método *DFA* consiste em determinar os desvios de cada observação em relação a média, conforme a equação 3.23. Assim, obtém-se a série integrada que será denotada por $y(k)$.

⁸Auto-afinidade: é uma característica estatística, que permite correlacionar um fenômeno quando observado em diferentes escalas (MANDELBROT, 1982).

$$\langle u \rangle = \frac{1}{N} \sum_{i=1}^N u_i \quad (3.21)$$

$$y(k) = \sum_{i=1}^k [u(i) - \langle u \rangle] \quad (3.22)$$

A série integrada $y(k)$ é dividida em intervalos (caixas ou box) de tamanho n . Para cada tamanho n de caixa, é ajustado um polinômio de grau ≥ 1 . Esse ajuste representa a tendência local $y_n k$ em cada caixa de tamanho n . Todo processo é obtido pelo método dos mínimos quadrados, conforme seção 3.1.7.

Em razão da etapa anterior, a série integrada $y(k)$ é subtraída da série ajustada $y_n k$ em cada tamanho n de caixa. Após, para cada caixa de tamanho n será calculado a raiz quadrática média F_n , denotada pela equação 3.23:

$$F(n) = \sqrt{\frac{1}{N} \sum_{k=1}^N [y(k) - y_n(k)]^2} \quad (3.23)$$

O cálculo acima é repetido para uma ampla gama de escalas (caixa de tamanhos n), de forma que $4 \leq n \leq \frac{N}{4}$. Por seguinte, verifica-se a função $F_{DFA}(n)$ caracteriza uma lei de potência do tipo, ver equação 3.24. Em que α_{DFA} será o indicador de correlação de longo alcance. Este expoente é obtido por meio de uma relação linear entre o $\log F_{DFA}(n)$ e $\log(n)$, de tal forma que, o α_{DFA} seja o coeficiente de inclinação da reta. Assim podemos interpretar esta relação da seguinte forma:

$$F_{DFA}(n) \sim n^{\alpha_{DFA}} \quad (3.24)$$

coeficiente	tipo de sinal
$\alpha_{DFA} < 0.5$	antipersistente
$\alpha_{DFA} \simeq 0.5$	ruído branco não correlacionado
$\alpha_{DFA} > 0.5$	persistente correlacionada de longo alcance
$\alpha_{DFA} \simeq 1$	$1/f$ ruído
$\alpha_{DFA} > 1$	não estacionário
$\alpha_{DFA} \simeq 3/2$	ruído browniano

Como descrito acima, em todo o estudo com séries temporais, a auto-similaridade pode ser modelado matematicamente pelas leis de potência. Se dividirmos todas as etapas do processo em segmentos de igual comprimento, n , torna-se possível visualizá-lo efetivamente em escalas deferentes. Assim, o que o DFA possibilita é a detecção de correlação de longo alcance e auto- afinidade embutida em séries temporais aparentemente não estacionárias e, sobretudo evita a detecção espúria de correlações de longo alcance (ZEBENDE *et al.*, 2016; ZEBENDE *et al.*, 2017).

3.2.2 Função de Flutuação - rms

A Proposta da função de flutuação raiz quadrática média (*rms*) surge com a proposta de medir a diferença de flutuação entre dois canais de EEG (Zebende *et al.* (2017)). A ferramenta é um incremento dado ao método DFA (Peng (1992)) e demonstrou ser muito útil na aplicação de sinais eletrofisiológico. Por meio desta função (*rms*), podemos estudar o quanto duas regiões do encéfalo estão correlacionadas para a mesma escala (coerência temporal).

Na prática, calculamos o DFA de duas série temporais e seu logaritmo individualmente. Em seguida, subtrai o resultado das logaritmos.

A utilidade da função de flutuação *rms* no experimento motor / imaginário disponível no endereço <<https://www.physionet.org/>> permitiu comparar as atividades cerebrais entre os canais F_332 e P_349 localizados no hemisfério esquerdo e os canais F_637 e P_654 localizados no hemisfério direito, ver a Figura 3.10.

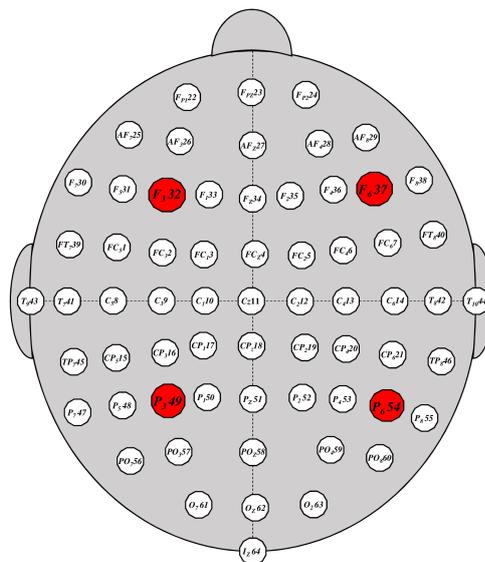


Figura 3.10: Canais utilizados na função rms. (ZEBENDE *et al.*, 2017)

Na Figura 3.10 temos os canais utilizados para o cálculo da função *rms*. Em vermelho temos os canais escolhidos: F_332 e P_349 localizados no hemisfério esquerdo e F_637 e P_654 localizados no hemisfério direito. Todo o encéfalo engloba 64 eléctrodos e atende ao sistema internacional 10 – 20.

$$\Delta \log F_{32:xx} = \Delta \log F_{DFA-32} - \Delta \log F_{DFA-xx} \quad (3.25)$$

Da função $\Delta \log F_{32:xx}$ (equação: 3.25) podemos inferir que a amplitude da flutuação relativa a *rms* pode ser vista por três condições:

- Se $\Delta \log F_{32:xx} > 0$, então a amplitude da função de flutuação *rms* em torno do canal F_332 em relação ao canal xx, é maior;
- Se $\Delta \log F_{32:xx} = 0$, então a amplitude da função de flutuação *rms* em torno do canal F_332 em relação ao canal xx, é zero;
- Se $\Delta \log F_{32:xx} < 0$, então a amplitude da função de flutuação *rms* em torno do canal F_332 em relação ao canal xx, é menor.

Alguns trabalhos já citam a função *rms*.

[Ghosh et al. \(2018\)](#) em seu artigo "Chaos based nonlinear analysis to study cardiovascular responses to changes in posture", faz um análise com dados públicos de eletrocardiograma e da pressão arterial, retirados do banco de dados physionet, com uma nova perspectiva de análise de séries temporais não-lineares com características multifractais.

[Baravalle et al. \(2018a\)](#) no seu artigo "Discriminating imagined and non-imagined tasks in the motor cortex area: Entropy-complexity plane with a wavelet decomposition", mostra que os eletroencefalogramas refletem a atividade elétrica do cérebro, que pode ser considerada governada por uma dinâmica não linear caótica. Considera os registros do eletroencefalograma humano durante diferentes atividades do tipo motor. Caracterizamos as diferentes dinâmicas do córtex de acordo com tarefas motoras distintas e movimentos imaginários usando uma abordagem de teoria da informação e uma decomposição wavelet.

[Baravalle et al. \(2018b\)](#) em seu manuscrito "Causal Shannon-Fisher characterization of motor/imagery movements in EEG", descreve que os padrões de oscilações neurais são talvez a característica mais saliente do EEG, pois são atividades rítmicas do cérebro que podem ser geradas por interações entre os neurônios. As oscilações em larga escala podem

ser medidas pelo EEG como os diferentes padrões de oscilação refletidos nas diferentes bandas de frequência, e podem nos fornecer novos insights sobre as funções cerebrais.

Baravalle *et al.* (2018c) no artigo "Rhythmic activities of the brain: Quantifying the high complexity of beta and gamma oscillations during visuomotor tasks", descrevem a atividade elétrica que ocorre na superfície do cérebro e fornecem uma ferramenta importante para a compreensão de uma variedade de processos cognitivos. O EEG é o produto da atividade sincronizada do cérebro, e as variações nos padrões de oscilação do EEG refletem as mudanças subjacentes na sincronia neuronal.

Hirekhan *et al.* (2019) no manuscrito "The Detrended Fluctuation Analysis of EEG Signals: A Meditation-Based Study", estuda sinais de EEG na intervenção pré e pós-meditação.

Mais detalhes do função de flutuação *rms* aplicada em sinais de EEG, pode ser visto no artigo intitulado "Auto-correlation in the motor/imaginary human EEG signals: A vision about the FDFA fluctuations"(ZEBENDE *et al.*, 2017).

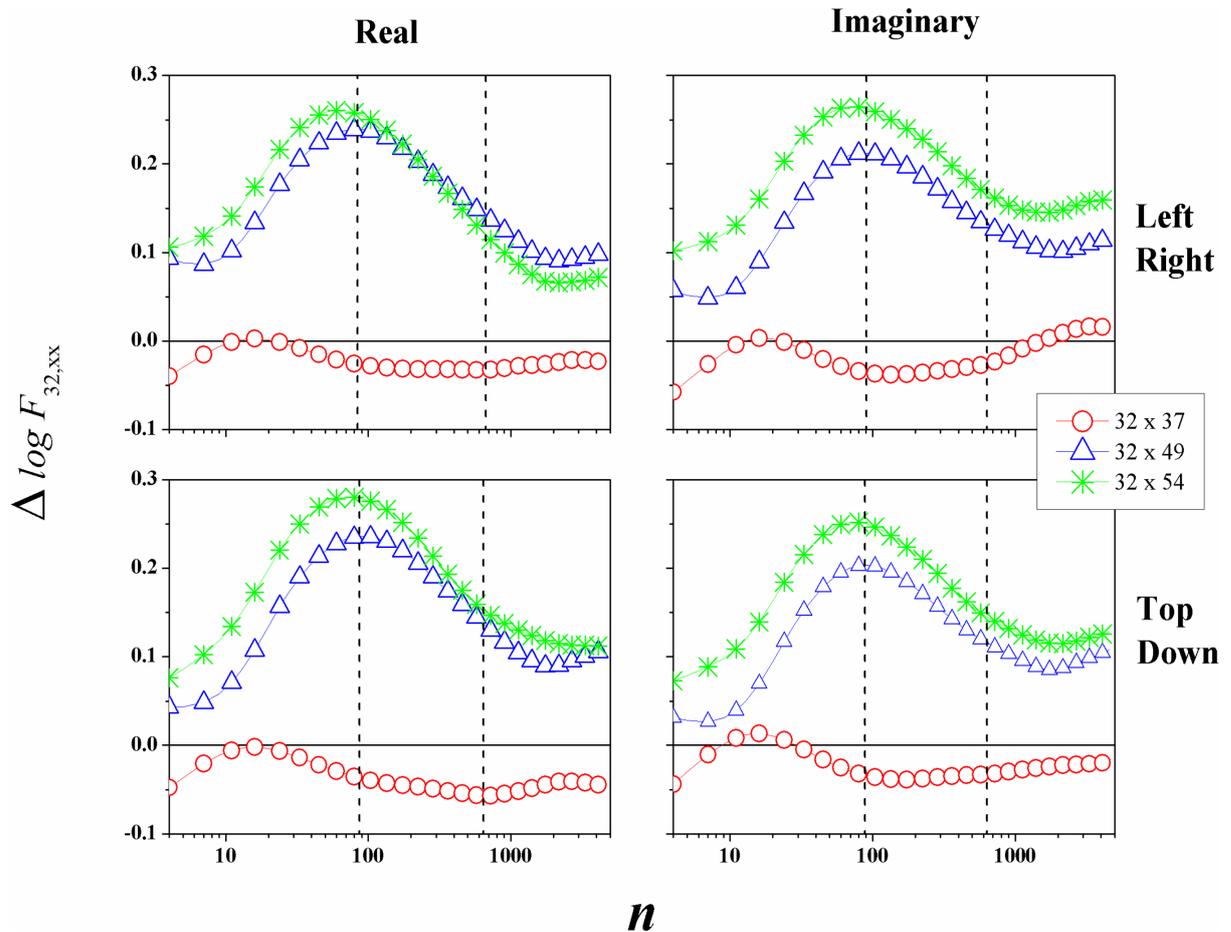


Figura 3.11: Valor médio do $\Delta \log F_{32:xx}$ entre o canal F_{32} e outros três. Cada curva representa a diferença entre F_{32} , F_{637} , P_{349} e P_{654} .

Com relação aos gráficos da figura 3.11, percebemos a maior prevalência em amplitude dos canais frontais em relação aos canais parietais, para esta tarefa motora. O máximo de $\Delta \log F_{32:xx}$, $\Delta \log F_{32:54}$ é encontrado em $n \sim 90$ ($t = 0,56s$), e a Figura 3.11 apresenta a média global da função de flutuação rms de 10 indivíduos. O protocolo deste teste encontra-se disponível na página da phisionet <<https://physionet.org/physiobank/database/#neuro>>. Para o teste todos os indivíduos realizaram tarefas motoras de imagens diferentes, enquanto os EEG de 64 canais foram registrados usando o sistema *BCI2000*, disponível no endereço: <<http://www.bci2000.org>>.

3.2.3 Detrended Cross-Correlation Analysis - DCCA

Proposto por [Podobnik & Stanley \(2008\)](#), o método Detrended Cross-Correlation Analysis (DCCA) é uma generalização do método Detrended Fluctuation Analysis (DFA), que se propõem a estimar o expoente que caracteriza a correlação cruzada de longo alcance entre duas séries temporais não estacionárias de mesmo tamanho n . Uma das vantagens do DCCA em relação a outros métodos de detecção de correlação cruzada como, por exemplo, o coeficiente de correlação de Pearson, é a possibilidade de identificação e mensuração de correlação entre dois sinais em diferentes escalas de tempo n .

Para compreender a interpretação matemática do método DCCA, considere duas séries temporais não estacionária Y_i e Y'_i , em que $i = 1, \dots, N_{max}$ e N_{max} o número total de pontos na série temporal. Assim como no método DFA, estas séries serão integradas, em seguida representadas por $R_k = Y_1 + Y_2 + Y_3 + \dots + Y_k$ e $R'_K = Y'_1 + Y'_2 + Y'_3 + \dots + Y'_k$, sendo $K = 1, 2, 3, \dots, N$.

As séries integradas R_k e R'_K são divididas e $N_{max} - n$ boxes de tamanho n com superposição cada um contendo $n + 1$ valores. Ver figura 3.12

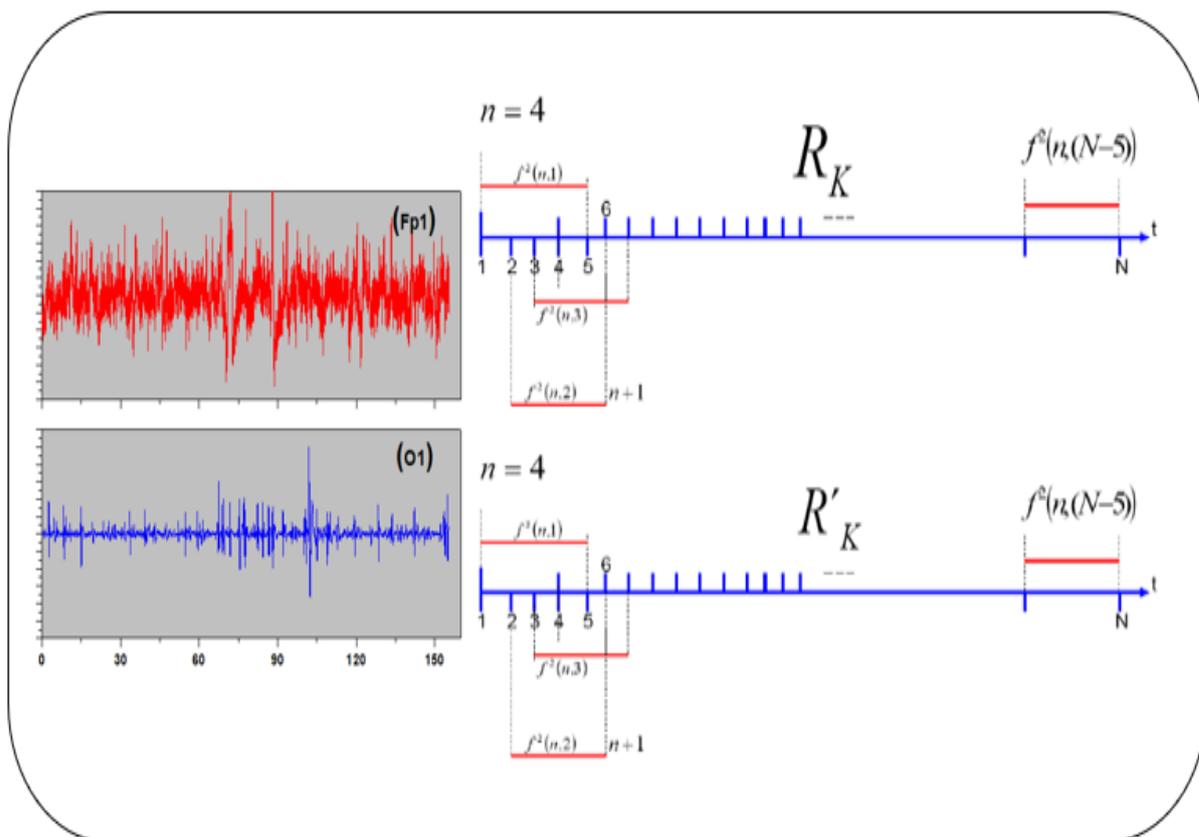


Figura 3.12: Divisão dos sinais integrados R_k e R'_K em $N-n$ boxes (com superposição) de tamanho 4. Cada um contendo $n + 1$ valores. Fonte: adaptado de FILHO (2014)

Em cada caixa caixa que inicia em i e termina e $i + n$ (ver figura 3.12), computa-se as tendências locais $\tilde{R}_{(K,i)}$ e $\tilde{R}'_{(K,i)}$ ($i \leq K \leq i + n$) como sendo a ordenada do ajuste linear obtida por Mínimos Quadrados (MQ) da série somada.

A partir do cálculo anterior, calcula-se a covariância dos resíduos em cada intervalo, isto é, ver equação 3.26.

$$f_{DCCA}^2 = \frac{1}{n + 1} \sum_{K=1}^{i+n} (R_K - \tilde{R}_{K,i})(R'_K - \tilde{R}'_{K,i}) \quad (3.26)$$

Determina-se a função de correlação (detrended covariance), definida pela equação 3.27.

$$F_{DCCA(n)}^2 = \frac{1}{N+n} \sum_{i=1}^{N-n} f_{DCCA(n,i)}^2 \quad (3.27)$$

O cálculo é repetido para diferentes tamanhos de n , isto é $4 \leq n \leq \frac{N}{4}$. Por seguinte, verifica-se a função $F_{DCCA(n)}^2$ apresenta um comportamento do tipo lei de potência. Ver equação 3.30.

$$F_{DCCA(n)}^2 \sim n^{\lambda_{DCCA}} \quad (3.28)$$

em que, λ_{DCCA} é o indicador de correlação de longo alcance. Este expoente é obtido por meio de uma relação linear entre o $\log(F_{DCCA(n)}^2)$ e o $\log(n)$, de tal forma que, o λ_{DCCA} seja o coeficiente de inclinação da reta.

O periódico que mostra a relação entre α e λ_{DCCA} pode ser consultado em (ZEBENDE *et al.*, 2013). A demonstração é simples e visa provar por meio de uma equação diferencial homogênea (EDO) que $\lambda = \frac{(\alpha_1 + \alpha_1)}{2}$. Essa relação será aplicada a duas séries temporais não-estacionárias com autocorrelações de lei de potência de longo alcance e com correlações cruzadas de lei de potência de longo alcance.

[Demonstração] - Considere:

$$F_{DFA_1} = K_1 n^{\alpha_1} \quad (3.29)$$

$$F_{DFA_2} = K_2 n^{\alpha_2} \quad (3.30)$$

$$F_{DCCA(n)}^2 = K_3 n^{2\lambda} \quad (3.31)$$

K_1 , K_2 e K_3 , constantes $\neq 0$

$$\rho_{DCCA}(n) = kn^{2\lambda - \alpha_1 - \alpha_2} \quad (3.32)$$

Com $k \equiv \frac{K_3}{K_1 K_2}$, $y \equiv \log_{10} \rho_{DCCA}(n)$ e $x \equiv \log_{10}(n)$, temos que:

$$\frac{dy}{dx} = 2\lambda - \alpha_1 - \alpha_2 \quad (3.33)$$

Com a condição de que:

$$\lambda = \frac{(\alpha_1 + \alpha_1)}{2} \quad (3.34)$$

$$\lambda < \frac{(\alpha_1 + \alpha_1)}{2} \quad (3.35)$$

$$\lambda > \frac{(\alpha_1 + \alpha_1)}{2} \quad (3.36)$$

Verificando, temos:

(a) $\frac{dy}{dx} = 0 \rightarrow \lambda = \frac{(\alpha_1 + \alpha_1)}{2}$, uma "solução homogênea"

(b) $\frac{dy}{dx} = \xi(\xi \in R)$, nesta situação $\frac{dy}{dx} = 0 \rightarrow \lambda = \frac{(\xi + \alpha_1 + \alpha_1)}{2}$ ou $\frac{dy}{dx} = 0 \rightarrow \lambda \neq \frac{(\xi + \alpha_1 + \alpha_1)}{2}$

3.2.4 Coeficiente de Correlação Cruzada - ρ_{DCCA}

Como visto em 3.2.3, o expoente λ_{DCCA} possibilita identificar e mensurar correlação de longo alcance entre dois sinais em diferentes escalas de tempo n , mas não quantifica o

nível de correlação cruzada. Assim, em função dessa possibilidade, Zebende (2011) propôs o coeficiente de correlação cruzada $\rho DCCA(n)$ com o objetivo de quantificar o nível de correlação cruzada entre duas séries temporais não estacionárias de mesmo comprimento n . O coeficiente é obtido com sendo a razão entre a função de covariância sem tendência $F_{DCCA(n)}^2$ do método Detrended Cross - Correlation Analysis (DCCA), ver 3.2.3 e a função sem tendência do método Detrended Fluctuation Analysis (DFA), ver 3.2.1, conforme 3.37.

$$\rho DCCA(n) = \frac{F_{DCCA(n)}^2}{F_{DFA[Y_i](n)} F_{DFA[Y'_i](n)}} \quad (3.37)$$

O coeficiente é adimensional e possui intervalo de variação entre $-1 \leq \rho DCCA \leq 1$.

- $\rho DCCA(n) = -1 \rightarrow$ anti correlação cruzada perfeita;
- $\rho DCCA(n) = 0 \rightarrow$ inexistência de correlação cruzada;
- $\rho DCCA(n) = 1 \rightarrow$ correlação cruzada perfeita.

Apesar de Silva *et al.* (2015) apresentar em um contexto econômico ("Quantificação do efeito contágio da crise financeira de 2008 entre os países do G7 (por PIB nominal)), níveis de correlação (fraco, médio e forte), em termos de sinais eletrofisiológicos para escala de n não foi encontrado para citar nesse projeto um manuscrito.

As Figuras 3.14, 3.15, 3.16 e 3.17, foram geradas com base no protocolo disponível no endereço <<https://www.physionet.org/>>. O protocolo mostra que indivíduos realizaram diferentes tarefas motoras / de imagens, enquanto os EEG de 64 canais foram registrados usando o sistema BCI2000 (<http://www.bci2000.org>). Cada participante realizou 14 corridas experimentais: duas corridas de base de um minuto (uma com os olhos abertos, outra com os olhos fechados) e três corridas de dois minutos de cada uma das quatro tarefas. Os gráficos demonstrados nesta seção, refere-se apenas a interpretação das três corridas de dois minutos de cada uma das quatro tarefas. A figura 3.13 ilustra a relação aqui definida como vizinhos próximos ($F_{332} - FC_{302}$, $F_{332} - A_F26$, $F_{332} - F_{331}$, $F_{332} - F_{133}$) e vizinhos distantes ($F_{332} - F_{637}$, $F_{332} - F_{654}$, $F_{332} - F_{349}$).

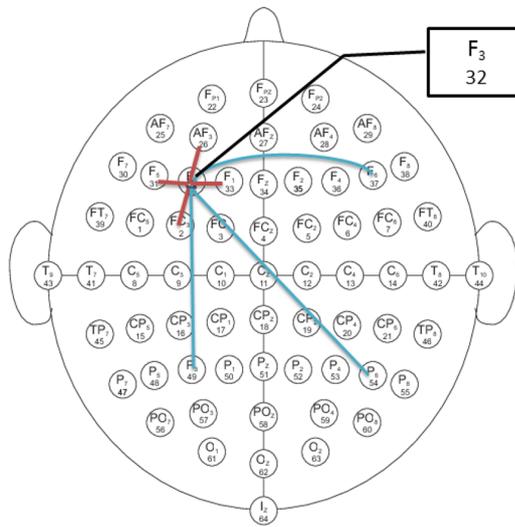


Figura 3.13: Vizinhos próximos x Vizinhos distantes.

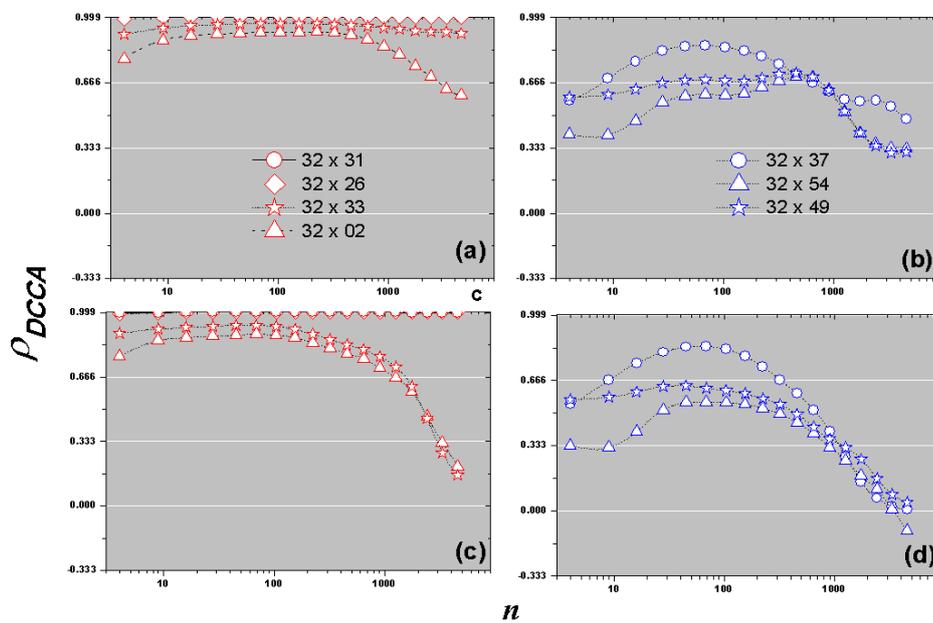


Figura 3.14: Tarefa real.

Para a Figura 3.14, tarefa real, verificamos o sincronismo entre canais por meio do coeficiente de correlação ρ_{DCCA} . Em (a), verifica-se correlação cruzada forte (0.666 – 0.999)

para todos os canais. Apenas o canal 32x02 mostrou tendência de decrescimento para $n > 500$. Em (b) verifica-se variabilidade no sincronismo para ρ_{DCCA} entre (0.333–0.999). Em (c), verifica-se correlação cruzada forte 0.666–0.999) para todos os canais, sobretudo, um decrescimento nos canais 32x02 e 32x33 a partir de $n > 100$. Já em (d), verifica-se variabilidade no sincronismo e um decrescimento a partir de $n < 300$.

Em (a) e (b) da figura 3.14, temos uma tarefa real representado pelos vizinhos próximos ($F_{332} - FC_{302}$, $F_{332} - A_F26$, $F_{332} - F_{331}$, $F_{332} - F_{133}$) e vizinhos mais distantes, ($F_{332} - F_{637}$, $F_{332} - F_{654}$, $F_{332} - F_{349}$). Nesta tarefa, um alvo aparece em ambos os lados esquerdo ou direito da tela. O sujeito abre e fecha o punho correspondente até que o alvo desapareça. Em (c) e (d), temos também uma tarefa Real com os mesmos pontos, e está relacionado a um alvo que aparece na parte superior ou inferior da tela. O sujeito abre e fecha, quer os dois punhos (se o alvo está no topo) ou ambos os pés (se o destino for na parte inferior) até que o alvo desapareça.

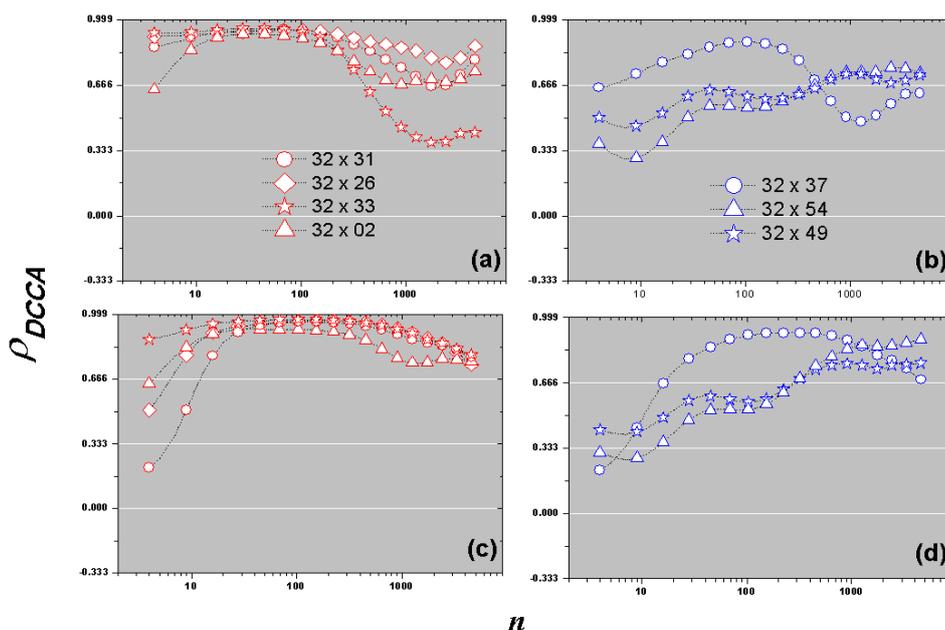


Figura 3.15: Tarefa imaginária.

Em (a) e (b) da figura 3.15, temos uma tarefa imaginária representado pelos vizinhos próximos ($F_{332} - FC_{302}$, $F_{332} - A_F26$, $F_{332} - F_{331}$, $F_{332} - F_{133}$) e vizinhos mais distantes, ($F_{332} - F_{637}$, $F_{332} - F_{654}$, $F_{332} - F_{349}$). Nesta tarefa um alvo aparece em ambos os lados esquerdo ou direito da tela. O sujeito imagina abrindo e fechando o punho correspondente até que o alvo desapareça. Em (c) e (d), temos também uma tarefa imaginária com os mesmos pontos, um alvo aparece na parte superior ou inferior da tela. O sujeito imagina abrindo e fechando os punhos quer (se o alvo está no topo) ou ambos

os pés (se o destino for na parte inferior) até que o alvo desapareça.

Para a Figura 3.15, tarefa imaginária, verificamos o sincronismo entre canais por meio do coeficiente de correlação ρ_{DCCA} . Em (a), verifica-se correlação cruzada forte (0.666 – 0.999) em todos os canais. Para $n > 300$, 32X33 apresentou decréscimo em $n > 300$. Em (b) verifica-se variabilidade no sincronismo para ρ_{DCCA} entre (0.333 – 0.999). Em (c), verifica-se correlação cruzada variada com tendência de crescimento para $n < 40$, em seguida de forte correlação (0.666 – 0.999). Já em (d), verifica-se variabilidade no sincronismo acompanhado de crescimento para todas as escalas de n .

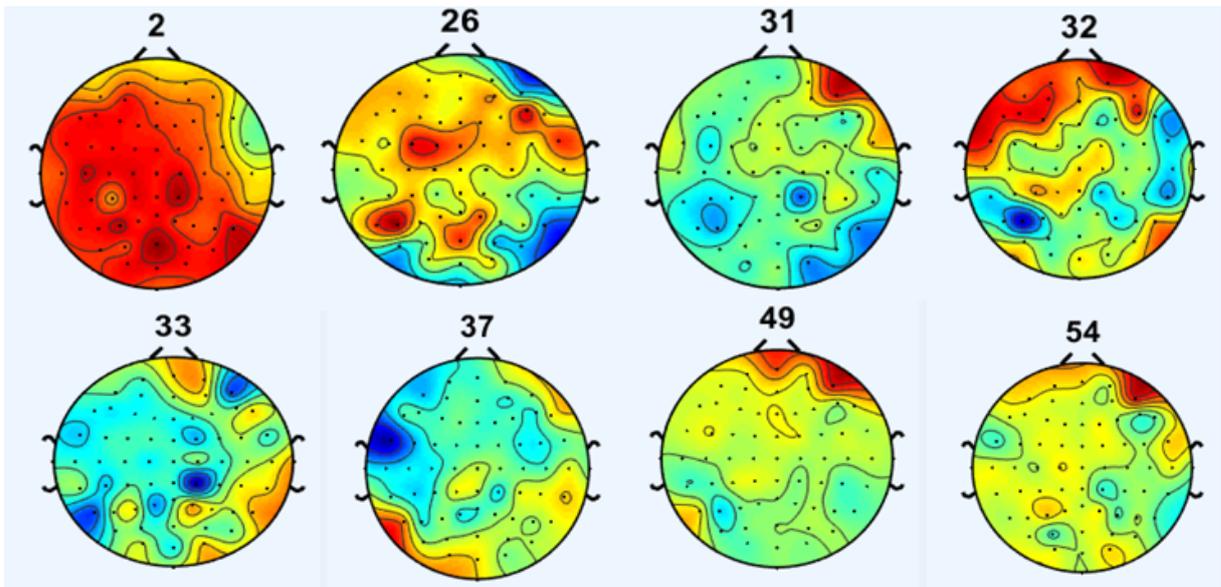


Figura 3.16: Áreas ativas do encéfalo: tarefa real.

As imagens geradas dos pontos específicos do encéfalo para a atividade real / imaginária ilustradas nas Figuras 3.16 e 3.17, revelam que podemos identificar áreas ativas específicas com mesma frequência (coerência cerebral). Sobretudo, não temos como mensurar o nível de correlação entre regiões específicas. As imagens geradas mostram padrões típicos da atividade cerebral associado a processos motores. Os eventos são mais forte nas regiões em vermelho e diminui pouco a pouco passando pelas outras cores do arco-íris de amarelo a azul violeta.

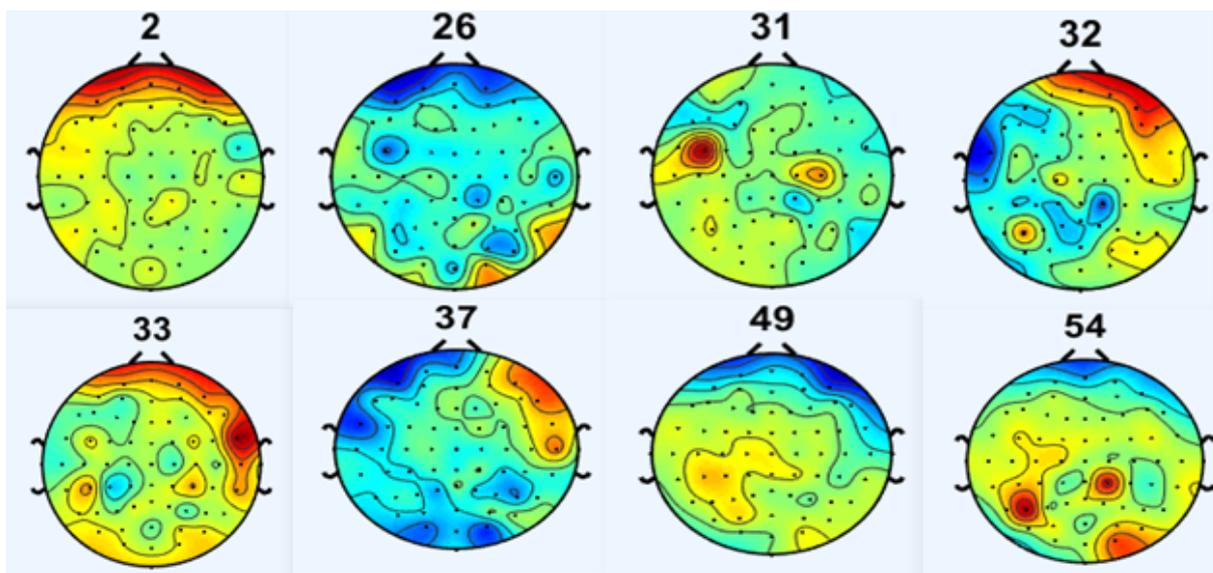


Figura 3.17: Áreas ativas do encéfalo: tarefa imaginária.

Resultados

Neste capítulo, apresentamos os resultados desta tese de doutorado, os quais estão relacionados com os objetivos específicos listados na subseção 1.2 do Capítulo 1. Por opção metodológica, expomos os resultados no formato de publicações e ferramentas desenvolvidas.

4.1 Auto-correlação nos sinais de EEG humanos motores / imaginários: Uma visão sobre as flutuações da F_{DFA}

Uma forma de olhar para o encéfalo através dos biosinais sempre teve prevalência por técnicas que pudessem comparar regiões do cérebro que se correlacionassem com a mesma frequência - coerência cerebral. Essas ferramentas são baseadas em técnicas integráveis, tomando como operador um kernel específico e com um olhar mais voltado para a flutuação do sinal no domínio da frequência. Essas ferramentas são conhecidas com transformadas e as mais conhecidas são: Laplace (1749–1827), Fourier(1768–1830), Hilbert(1862–1943), Wavelet, Mellin e Z (desempenha para os sinais discretos o mesmo papel que a Transformada de Laplace para os sinais contínuos). Para tratamento com sinais fisiológicos, um destaque para Fourier e Hilbert. E para resposta a sistemas dinâmicos por meio de equações algébricas, Laplace (1749 – 1827).

Neste manuscrito mostramos que o olhar para o encéfalo poderia ter uma vertente mais voltada para a coerência temporal por meio das amplitudes nas flutuações. Essa vertente significativa permite olhar para reabilitações motoras complexas através de comportamentos, tendências e sincronismos.

Propomos então olhar para regiões distintas sobre a mesma escala por meio da Função de Flutuação (*rms*). Aqui estudamos como a amplitude da função de flutuação *rms*, comporta-se em um EEG de 64 canais, tomado por 10 sujeitos em diferentes tarefas (motor / imaginário). Nesse sentido, de uma maneira lógica, analisamos como os hemisférios cerebrais esquerdo / direito (frontal) e esquerdo / direito (parietal) estão relacionados.

A proposta aqui adotada neste trabalho, vem despertar um olhar para a coerência temporal por meio da função de flutuação (*rms*) e da auto-afinidade que regiões específicas do encéfalo podem estarem evidenciando quando estimulados por processos motores. A abordagem do manuscrito foi pioneira e está sendo replicada por outros trabalhos, conforme

descrito em 3.2.2.

Desafios superados:

Para atender algumas perguntas dos árbitros, o manuscrito passou por alguns testes:

(i) acrescentar mais três canais considerados importantes para a análise. Canais estudados (F_{32} , F_{37} , P_{39} , P_{54}) / canais complementares (C_{39} , C_{z11} e C_{413}). A ilustração dos pontos pode ser visto na figura 4.1.

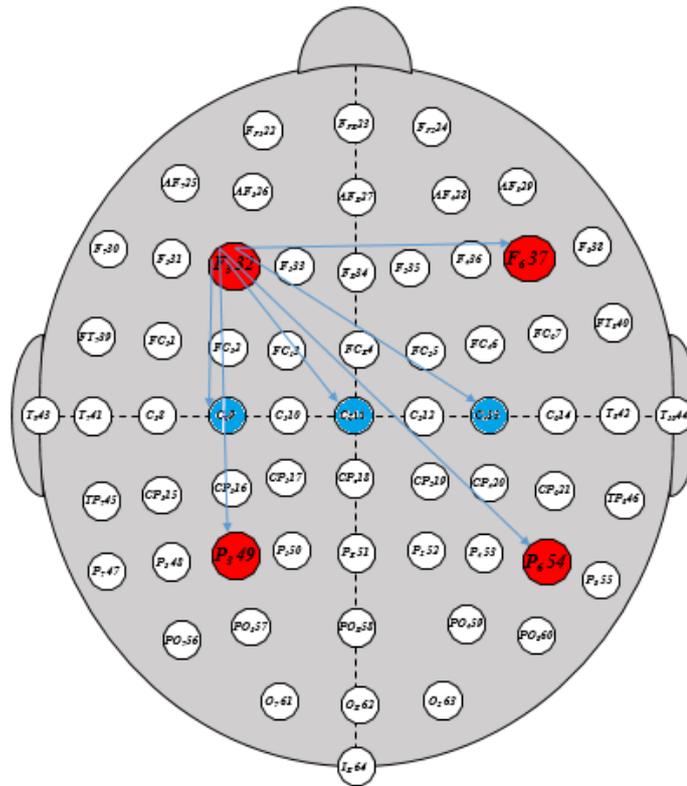


Figura 4.1: Canais Complementares: C_{39} , C_{z11} e C_{413} .

Neste item também acrescentamos os gráfico para os árbitros da estatística proposta pelo método DFA e a função de Flutuação - rms - ($\Delta \log_{DFA}$) de todos os indivíduos selecionados no banco do Physionet ($S020$, $S029$, $S043$, $S046$, $S050$, $S051$, $S060$, $S071$, $S076$ e $S099$). Exemplo dos gráficos postado em anexo complementar para a revista, 4.2, 4.3 e 4.4.

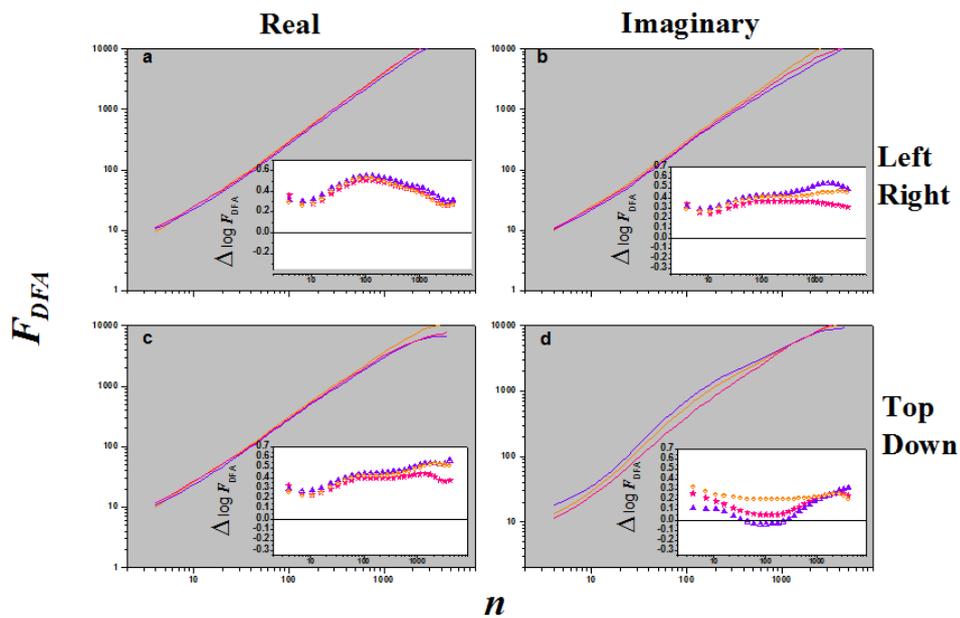


Figura 4.2: Indivíduo S060.

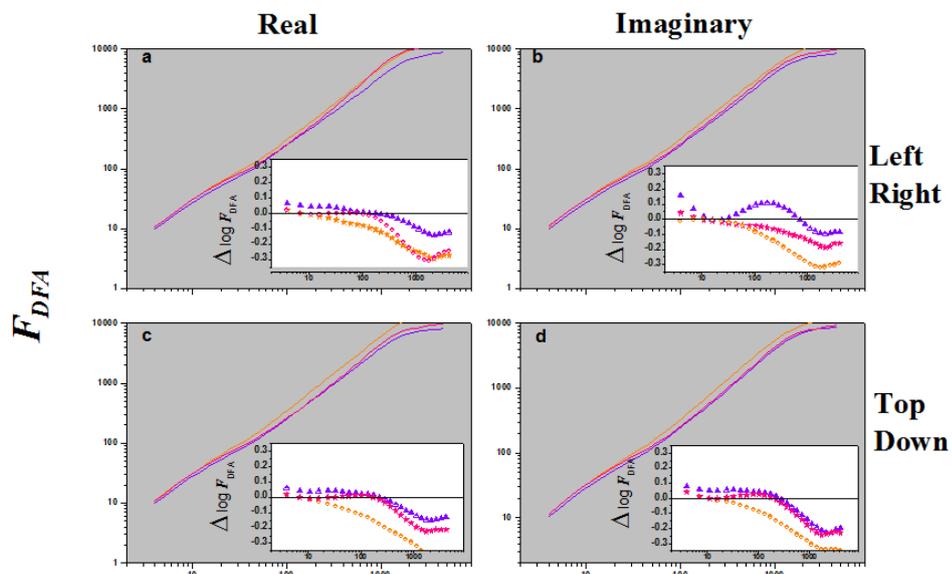


Figura 4.3: Indivíduo S071.

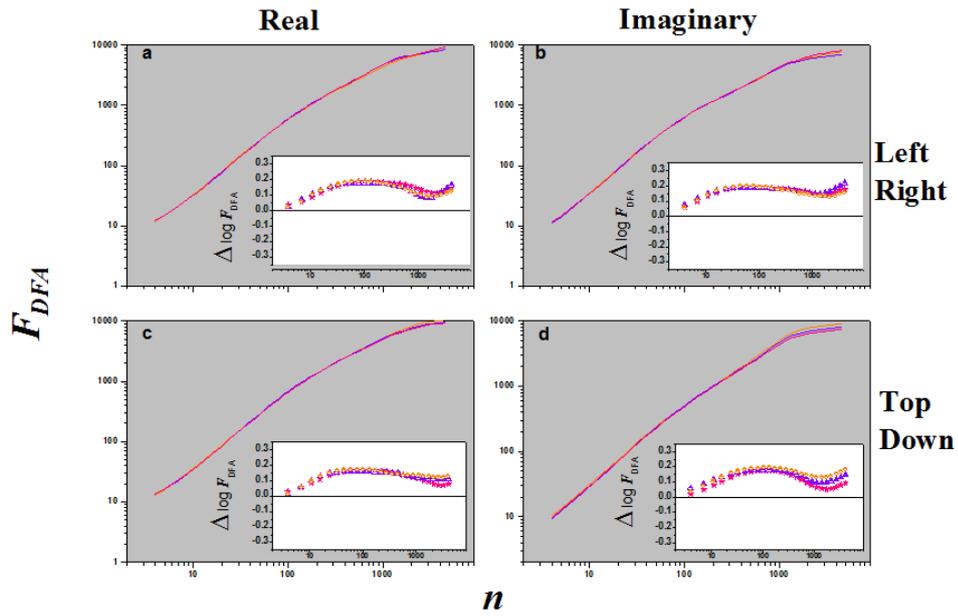


Figura 4.4: Indivíduo S086.

Em conformidade com os participantes do artigo, o material construído para atender a solicitação dos avaliadores foi postado como arquivo complementar e não acrescentado ao artigo original.

(ii) a fim de tornar os dados brutos mais próximos da verdade, foi solicitado redefinir a referência por meio do software REST (Reference Electrode Standardization Technique). Trata-se de um método para padronizar referência de gravações do EEG do couro cabeludo a um ponto no infinito.

(iii) acrescentamos também no anexo para os árbitros, uma tabela com todos os α_{DFA} dos canais complementares (C_{39} , C_{z11} e C_{413}) e média. Ver tabelas 4.1 e 4.2.

Tabela 4.1: α_{DFA} dos canais complementares (C_{39} , C_{z11} e C_{413})

Canais		3			4			11		
		Tarefas	1	2	3	1	2	3	1	2
20	Real (L/R)	1.18	0.96	0.46	1.16	0.97	0.43	1.18	0.97	0.44
	Imag (L/R)	1.44	0.96	0.54	1.12	0.95	0.53	1.13	0.98	0.47
	Real (T/D)	1.44	0.96	0.54	1.12	0.95	0.53	1.13	0.98	0.47
	Imag (T/D)	1.40	0.96	0.52	1.13	0.97	0.49	0.98	0.97	0.59
29	Real (L/R)	1.07	1.26	0.29	1.07	1.26	0.29	1.07	1.26	0.29
	Imag (L/R)	0.93	1.27	0.28	0.93	1.27	0.28	0.93	1.27	0.28
	Real (T/D)	0.93	1.27	0.28	0.93	1.27	0.28	0.93	1.27	0.28
	Imag (T/D)	1.07	1.26	0.29	1.07	1.26	0.29	1.07	1.26	0.29
43	Real (L/R)	1.07	0.98	0.60	1.07	0.98	0.52	1.07	0.98	0.52
	Imag (L/R)	0.96	1.02	0.54	1.14	1.09	0.47	1.14	0.98	0.52
	Real (T/D)	1.05	1.07	0.56	1.09	1.08	0.58	1.05	1.07	0.56
	Imag (T/D)	0.96	1.02	0.54	1.14	1.09	0.47	1.14	0.98	0.52
46	Real (L/R)	1.14	0.99	0.51	1.29	0.92	0.48	1.16	0.99	0.44
	Imag (L/R)	0.89	1.02	0.40	1.03	0.99	0.24	1.03	1.00	0.29
	Real (T/D)	0.89	0.85	0.49	1.17	0.86	0.45	1.17	0.86	0.45
	Imag (T/D)	0.90	1.00	0.45	1.04	0.96	0.36	1.04	0.96	0.36
50	Real (L/R)	1.03	0.88	0.50	1.03	0.88	0.50	1.03	0.88	0.57
	Imag (L/R)	0.89	0.97	0.48	0.95	0.89	0.49	0.92	1.04	0.54
	Real (T/D)	0.87	0.91	0.45	0.87	0.91	0.45	0.87	0.91	0.45
	Imag (T/D)	0.88	0.91	0.47	1.02	0.89	0.51	0.94	0.90	0.57
51	Real (L/R)	1.02	0.94	0.54	1.01	0.92	0.53	1.01	0.95	0.54
	Imag (L/R)	0.89	0.94	0.48	1.01	0.89	0.52	1.00	0.99	0.58
	Real (T/D)	0.90	0.88	0.50	0.90	0.89	0.51	0.90	0.88	0.51
	Imag (T/D)	0.90	0.88	0.48	0.90	0.89	0.50	0.90	0.89	0.49
60	Real (L/R)	1.05	1.12	0.90	1.05	1.12	0.88	1.03	1.12	0.88
	Imag (L/R)	1.08	1.09	1.08	1.08	1.01	0.88	1.08	1.07	0.82
	Real (T/D)	1.03	1.07	0.80	1.02	1.03	0.64	1.00	1.04	0.64
	Imag (T/D)	0.99	0.85	0.67	1.20	0.77	0.54	1.15	0.99	0.76
71	Real (L/R)	0.99	1.21	0.70	1.21	0.92	0.72	0.92	1.29	0.63
	Imag (L/R)	1.07	1.22	0.70	0.95	1.18	0.60	0.93	1.23	0.58
	Real (T/D)	1.10	1.24	0.72	0.95	1.18	0.59	0.93	1.24	0.60
	Imag (T/D)	1.06	1.23	0.63	0.93	1.20	0.63	0.91	1.21	0.60
86	Real (L/R)	1.24	0.86	0.50	1.26	0.88	0.48	1.24	0.90	0.47
	Imag (L/R)	1.28	0.78	0.46	1.30	0.78	0.39	1.28	0.81	0.47
	Real (T/D)	1.24	0.86	0.50	1.26	0.88	0.48	1.24	0.90	0.47
	Imag (T/D)	1.28	0.81	0.47	1.27	0.94	0.43	1.24	0.93	0.43
99	Real (L/R)	0.80	0.92	0.20	0.82	1.03	0.18	0.78	0.93	0.18
	Imag (L/R)	0.72	0.90	0.13	0.84	0.99	0.14	0.78	0.96	0.21
	Real (T/D)	0.69	0.78	0.14	0.87	0.87	0.18	0.81	0.82	0.17
	Imag (T/D)	0.67	0.78	0.17	0.83	0.90	0.19	0.80	0.83	0.20

Tabela 4.2: Média com os α_{DFA} dos canais complementares (C_{39} , C_{z11} e C_{413})

Canais Tarefas	3			4			11		
	1	2	3	1	2	3	1	2	3
Real(L/R)	1.06	1.01	0.52	1.10	0.99	0.50	1.05	1.03	0.50
Imag(L/R)	1.02	1.02	0.51	1.04	1.00	0.45	1.02	1.03	0.48
Real(T/D)	1.01	0.99	0.50	1.02	0.99	0.47	1.00	1.00	0.46
Imag(T/D)	1.01	0.97	0.47	1.05	0.99	0.44	1.02	0.99	0.48

Para as tabelas 4.1 e 4.2, leia:

(L/R) = esquerda / direita

(T/D) = acima / embaixo.

RESEARCH ARTICLE

Auto-correlation in the motor/imaginary human EEG signals: A vision about the F_{DFA} fluctuations

Gilney Figueira Zebende^{1*}, Florêncio Mendes Oliveira Filho^{2,3}, Juan Alberto Leyva Cruz¹

1 Department of Physics, State University of Feira de Santana, Bahia, Brazil, **2** Gilberto Gil Campus, Estácio de Sá University, Bahia, Brazil, **3** Computational Modeling Program, SENAI CIMATEC, Bahia, Brazil

* gfzebende@hotmail.com

Abstract

In this paper we analyzed, by the F_{DFA} root mean square fluctuation (rms) function, the motor/imaginary human activity produced by a 64-channel electroencephalography (EEG). We utilized the Physionet on-line databank, a publicly available database of human EEG signals, as a standardized reference database for this study. Herein, we report the use of detrended fluctuation analysis (DFA) method for EEG analysis. We show that the complex time series of the EEG exhibits characteristic fluctuations depending on the analyzed channel in the scalp-recorded EEG. In order to demonstrate the effectiveness of the proposed technique, we analyzed four distinct channels represented here by F_{332} , F_{637} (frontal region of the head) and P_{349} , P_{654} (parietal region of the head). We verified that the amplitude of the F_{DFA} rms function is greater for the frontal channels than for the parietal. To tabulate this information in a better way, we define and calculate the difference between F_{DFA} (in *log* scale) for the channels, thus defining a new path for analysis of EEG signals. Finally, related to the studied EEG signals, we obtain the auto-correlation exponent, α_{DFA} by DFA method, that reveals self-affinity at specific time scale. Our results shows that this strategy can be applied to study the human brain activity in EEG processing.



OPEN ACCESS

Citation: Zebende GF, Oliveira Filho FM, Leyva Cruz JA (2017) Auto-correlation in the motor/imaginary human EEG signals: A vision about the F_{DFA} fluctuations. PLoS ONE 12(9): e0183121. <https://doi.org/10.1371/journal.pone.0183121>

Editor: Dezhong Yao, University of Electronic Science and Technology of China, CHINA

Received: March 18, 2017

Accepted: July 31, 2017

Published: September 14, 2017

Copyright: © 2017 Zebende et al. This is an open access article distributed under the terms of the [Creative Commons Attribution License](https://creativecommons.org/licenses/by/4.0/), which permits unrestricted use, distribution, and reproduction in any medium, provided the original author and source are credited.

Data Availability Statement: Data are available from: <https://physionet.org/pn4/eegmmidb/>.

Funding: This work was supported by Conselho Nacional de Desenvolvimento Científico e Tecnológico, grant 309288/2013-4, GfZ.

Competing interests: The authors have declared that no competing interests exist.

Introduction

The electroencephalogram (EEG) is generally an noninvasive method to record electrical activity of the brain. EEG machine is composed of electrodes, which are placed on the scalp to detect the brain waves [1]. Most EEG machines amplify the signals and records on computer by European Data Format (EDF) file. The EEG measurement is the voltage fluctuations, and with this measure it is possible to diagnose tumors, stroke, epilepsy, and other brain disorders which leads to some abnormalities in EEG readings. Despite the spatial resolution limitations, EEG remains a valuable tool for research and diagnosis, especially when a time resolution interval of milliseconds is required (which is not possible with computed tomography or magnetic resonance imaging) [2, 3]. See [4] for history of EEG. Therefore, in the last two decades, emerges the field of Brain-Computer Interface (BCI) [5], providing communication and

control capabilities to people with severe motor inability. Hence, the typical BCI system is built for one particular method and is not adjusted to others. In view of this limitation [6, 7] implemented a platform called BCI2000 [8], a general-purpose software system for BCI research. Thus, from BCI2000 system and the full documentation presented in [9], we download and analyzed, as we will see below, data of subjects performed different motor/imagery Tasks in 64-channel EEG, Fig 1.

Here, each subject performed 14 experimental runs: two one-minute baseline (one with eyes open, one with eyes closed), and three two-minute of the following Tasks [9]:

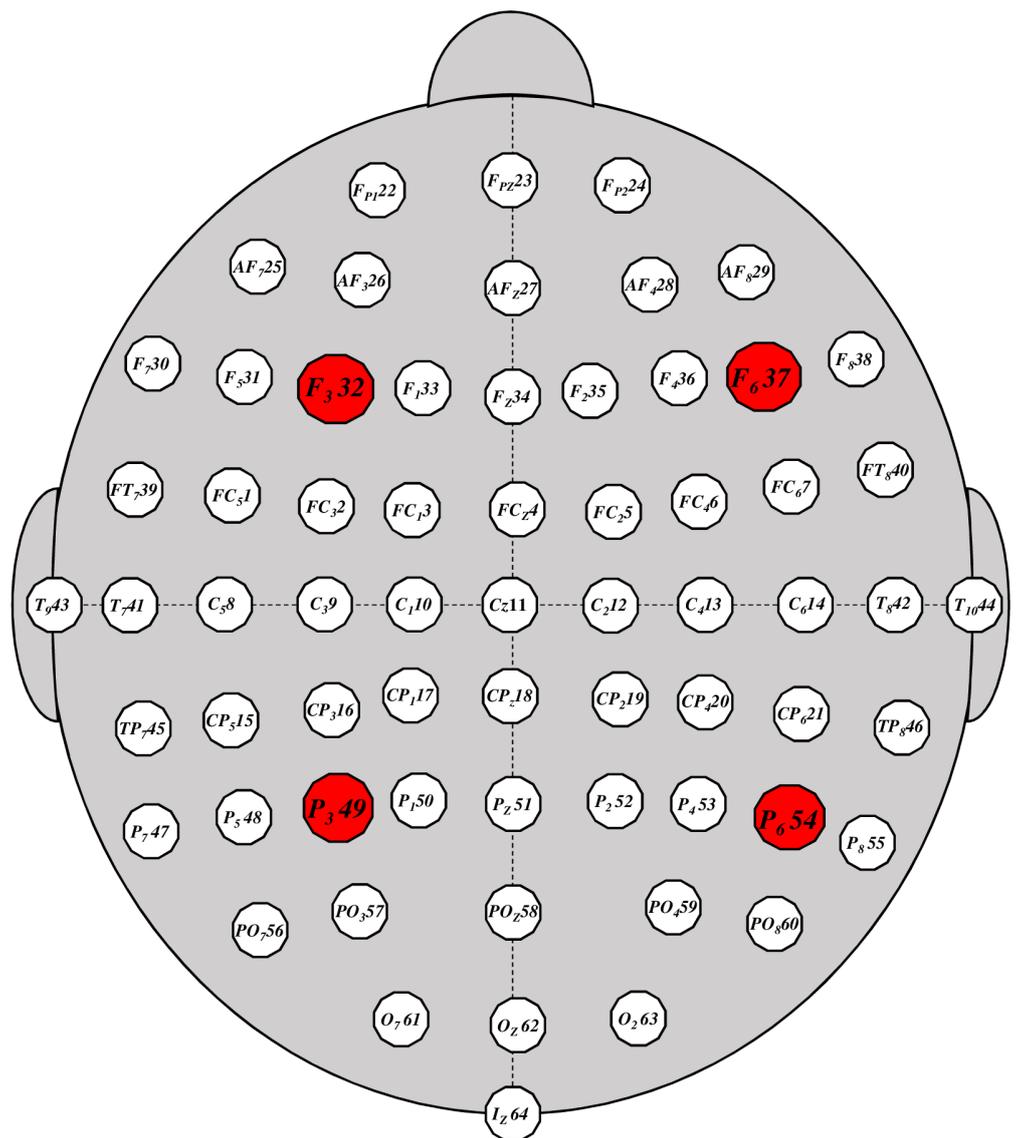


Fig 1. (Color on-line) Setup for EEG channels: 64 electrodes as per the international 10-20 system (excluding electrodes Nz, F9, F10, FT9, FT10, A1, A2, TP9, TP10, P9, and P10). The specific points (full circle in red) ($F_{3,32}$, $F_{6,37}$, $P_{3,49}$, $P_{6,54}$) identify the channels used in this paper.

<https://doi.org/10.1371/journal.pone.0183121.g001>

Table 1. 14 experimental runs for each subject: Two one-minute baseline (eyes open/closed) and three two-minute of four Tasks.

1 eyes open	2 eyes closed	-	-
3 Task 1	4 Task 2	5 Task 3	6 Task 4
7 Task 1	8 Task 2	9 Task 3	10 Task 4
11 Task 1	12 Task 2	13 Task 3	14 Task 4

<https://doi.org/10.1371/journal.pone.0183121.t001>

- **Task 1** a target appears on either the left or the right side of the screen. The subject opens and closes the corresponding fist until the target disappears. Then the subject relaxes. (Real (L/R));
- **Task 2** a target appears on either the left or the right side of the screen. The subject imagines opening and closing the corresponding fist until the target disappears. Then the subject relaxes. (Imag (L/R));
- **Task 3** a target appears on either the top or the bottom of the screen. The subject opens and closes either both fists (if the target is on top) or both feet (if the target is on the bottom) until the target disappears. Then the subject relaxes. (Real (T/D));
- **Task 4** a target appears on either the top or the bottom of the screen. The subject imagines opening and closing either both fists (if the target is on top) or both feet (if the target is on the bottom) until the target disappears. Then the subject relaxes. (Imag (T/D)).

In summary, see [Table 1](#):

Based on these Tasks and given that usually the diagnostic of EEG focus on the spectral content, like a Fourier analysis, we analyzed the brain activity of 10 subjects in three experiments, by DFA method, randomly chosen in [9]. Our focus was only in four channels, represented in the [Fig 1](#), by specific points (full circle in red) in the brain: (i) F_{332} located in the frontal region, left hemisphere; (ii) F_{637} located in the frontal region, right hemisphere; (iii) P_{349} located in the parietal region, left hemisphere; (iv) P_{654} located in the parietal region, right hemisphere. These points were selected because, as you know, the left side of the brain is responsible for controlling the right side of the body, and performs tasks that have to do with logic. On the other hand, the right hemisphere coordinates the left side of the body, and performs tasks that have do with creativity. Already the parietal lobe, integrates sensory information, including spacial sense and navigation [10, 11]. Thus, we can cross the four channels (hemispheres) in attempt to analyze the EEG, by F_{DFA} rms function and the α_{DFA} exponent. This is a new methodology of EEG analysis, where interesting results can be seen and easily applicable in subsequent studies, as we will see below.

Materials and methods

0.1 Database

The time series were analyzed by DFA method from the database available in <https://physionet.org/pn4/eegmdb/>. We selected randomly ten subjects in this database, that are: S020, S029, S043, S046, S050, S051, S060, S071, S086, and S099. Each subject performed three experiments for a defined Task (see [Table 1](#)). The data are provided in EDF+ format (containing 64 EEG signals, at 160 samples per second, and an annotation channel). The variable measured by the EEG device is the electrical voltage on scalp, with amplitude quite small in units of microvolts (μV). [Fig 2](#) presents an example of these time series for the channels F_{332} , F_{637} , P_{349} , and P_{654} .

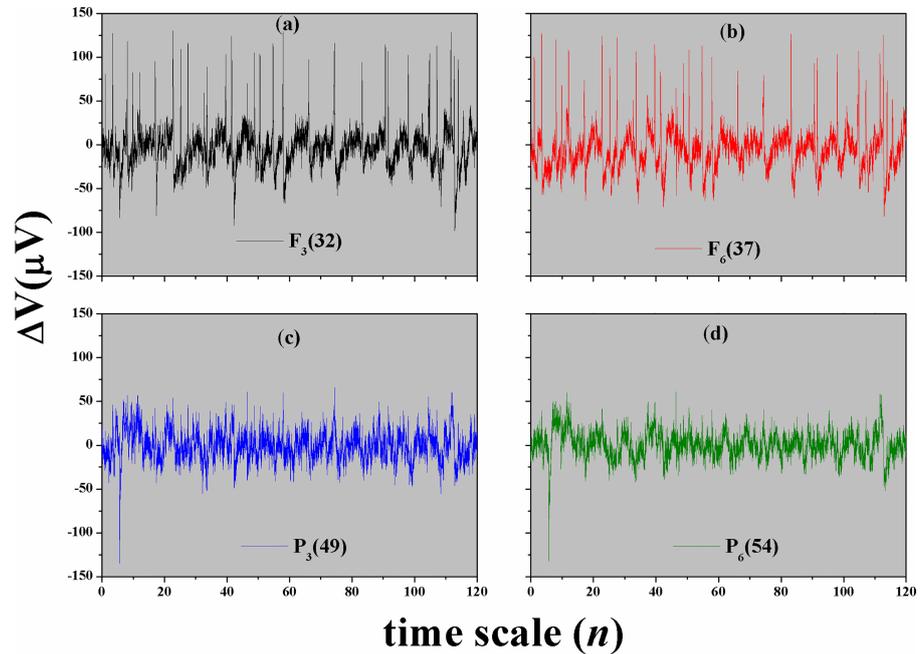


Fig 2. (Color on-line) Original time series of the EEG signal. Channels (a) $F_3(32)$ and (b) $F_6(37)$ represent the frontal region of the brain, and (c) $P_3(49)$ and (d) $P_6(54)$ represent the parietal region. These time series correspond to the subject S020 at the Task 1 (open and close left or right fist).

<https://doi.org/10.1371/journal.pone.0183121.g002>

0.2 DFA method

In order to analyze the EEG time series, we briefly present the DFA method [12], which involves the following steps:

1. Consider a correlated signal intensity, $u(i)$ (EEG signal), where $i = 1, \dots, N_{max}$, and N_{max} is the total number of points in the time series. We integrate the signal $u(i)$ and obtain $y(k) = \sum_{i=1}^k [u(i) - \langle u \rangle]$, where $\langle u \rangle$ is the average of u ;
2. The integrated signal $y(k)$ is divided into boxes of equal length n (time scale);
3. For each n -size box, we fit $y(k)$, using a polynomial function of order l , which represents the trend in the box. The y coordinate of the fitting line in each box is denoted by $y_n(k)$, since we use a polynomial fitting of order l , we denote the algorithm as DFA- l ;
4. The integrated signal $y(k)$ is detrended by subtracting the local trend $y_n(k)$ in each box (of length n);
5. For a given n -size box, the $F_{DFA}(n)$ root mean square fluctuation (rms) function for this integrated and detrended signal is given by

$$F_{DFA}(n) = \sqrt{\frac{1}{N_{max}} \sum_{k=1}^{N_{max}} [y(k) - y_n(k)]^2}; \quad (1)$$

6. The above computation is repeated for a broad range of scales (n -sizes box) to provide a relationship between $F_{DFA}(n)$ and the box size n , characterized by a power-law

Table 2. Information about DFA exponent.

exponent	type of signal
$\alpha_{DFA} < 0.5$	anti-persistent
$\alpha_{DFA} \simeq 0.5$	uncorrelated, white noise
$\alpha_{DFA} > 0.5$	long-range correlated persistent
$\alpha_{DFA} \simeq 1$	1/f noise
$\alpha_{DFA} > 1$	non-stationary
$\alpha_{DFA} \simeq 3/2$	Brownian noise

<https://doi.org/10.1371/journal.pone.0183121.t002>

$F(n) \sim n^{\alpha_{DFA}}$. In this way, α_{DFA} is the scaling exponent, a self-affinity parameter representing the long-range power-law correlation properties of the signal, such as [13], see Table 2:

The advantages of DFA over many others methods are that it permits the detection of long-range correlations embedded in seemingly non-stationary time series, and also avoids the spurious detection of apparent long-range correlations, that are an artifact of non-stationarity [14, 15]. The obtained exponent is similar to the Hurst exponent [16], except that DFA may also be applied to signals whose underlying statistics (such as mean and variance) or dynamics are non-stationary [17–20]. See the papers [19, 21–24], for which DFA and EEG were applied.

One motivation for estimating α_{DFA} , or the root mean square fluctuation $F_{DFA}(n)$, lies in the fact that these measures may potentially be used to classify or discriminate between different types of EEG signals, like we can see in Fig 2. Thus, characterized by the fact that at specific time scales the signal have the same type of behavior (self-affinity, see Figs 3 and 4), we can define (crossing these behaviors) the limit of the variability transition in the EEG signals [25]. Anyway, $F_{DFA}(n)$ was conceived as a method for detrending local variability in a sequence of events, and hence providing insight into long-term variations in the data sets. With the DFA method it is possible to remove trends that often exist in the EEG, and estimate the scaling from a wider range.

Results

Every time series of EEG motor/imaginary experience has approximately 2min ($N \cong 20,000$ points) with $\Delta t = 0.00625s$, for Task {1, 2, 3, 4} and three times repeated, see Table 1. Fig 2 presents an example of the original EEG signal in the Task 1 (a target appears on either the left or the right side of the screen. The subject opens and closes the corresponding fist until the target disappears. Then the subject relaxes. (Real (L/R))). In this figure, we can not see clearly which channels are the ones with the greatest amplitude, but with F_{DFA} it is simple and possible, as will see below.

For our analysis we selected randomly ten subjects from the Physionet on-line database: S020, S029, S043, S046, S050, S051, S060, S071, S086, and S099. After, we calculated F_{DFA} for every specific Task. Fig 3 (Real/Imaginary (L/R)) and Fig 4 (Real/Imaginary (T/D)) shows $F_{DFA} \times n$ (a and b) for all four Tasks and for S020, as an example.

In the Figs 3 and 4 (c and d) we present a new function, defined as the difference $\log F_{DFA}$ between the channel F_{32} with the others:

$$\Delta \log F_{32:xx} \equiv \log F_{DFA-32} - \log F_{DFA-xx} \tag{2}$$

Therefore, $\Delta \log F_{32:xx}$ give us information about the relative intensity of the rms fluctuation function, that is, if:

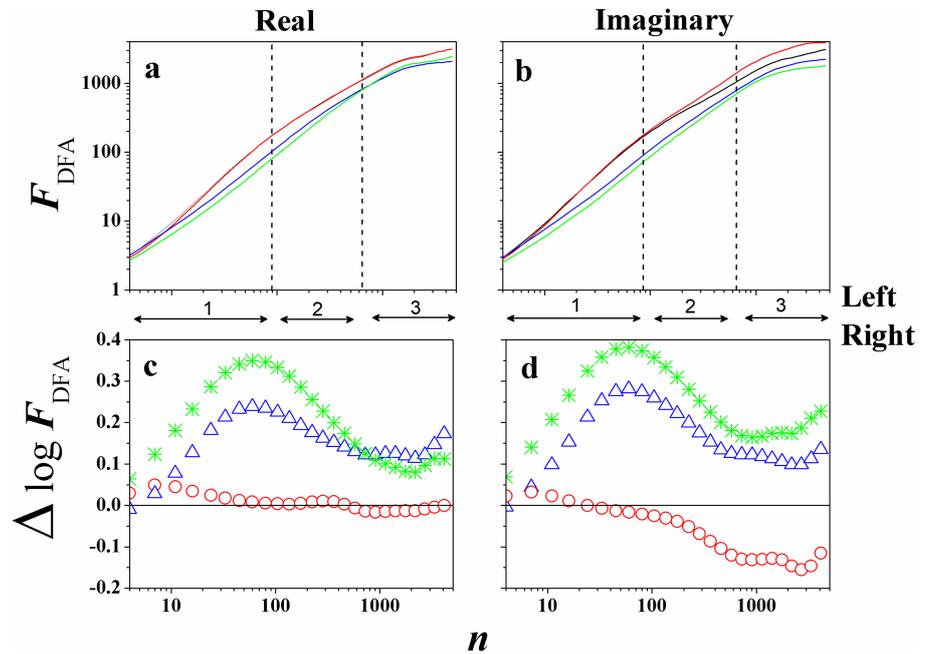


Fig 3. (Color on-line) F_{DFA} in function of n for S020 experiment 1 for (Left/Right): (a) Real and (b) Imaginary case. Black line represents F_{32} , red line F_{637} , blue line P_{349} , and green line P_{654} . Also, the figures below show the difference $\Delta \log F_{32;xx}$, defined by Eq 2, between the channels for the above function F_{DFA} : (c) Real and (d) Imaginary case. Here, $\Delta \log F_{32;37}$ (\circ), $\Delta \log F_{32;49}$ (Δ), and $\Delta \log F_{32;54}$ ($*$).

<https://doi.org/10.1371/journal.pone.0183121.g003>

- $\Delta \log F_{32;xx} > 0$, the amplitude of the rms fluctuation function about the channel F_{32} , in relation of the channel xx , is larger;
- $\Delta \log F_{32;xx} = 0$, the amplitude of the rms fluctuation function about the channel F_{32} , in relation of the channel xx , is zero;
- $\Delta \log F_{32;xx} < 0$, the amplitude of the rms fluctuation function about the channel F_{32} , in relation of the channel xx , is smaller.

Now, taking into account all experiments, tasks, and subjects, initially as a result we calculated the F_{DFA} , observing if there is or not a power-law $F(n) \sim n^{\alpha_{DFA}}$ for these EEG time series. We observe that $F_{DFA}(n)$ does not appear as a single power-law (see [25]), but we can identify three behaviors (slope in the time scale range), like $F_{DFA}(n) \propto n^{\alpha^{(i)}}$, with $i = 1, 2, 3$ (see Figs 3 and 4 vertical lines), where:

- $i = 1, 4 \leq n \leq 90$, with α_1 ;
- $i = 2, 91 \leq n \leq 655$, with α_2 ;
- $i = 3, n > 655$, with α_3 .

For example, one visible transition is around $n = 656$ ($t = 4.1s$), corresponding here to a time between two rests in the experiments.

In possession of this information for every subject in their four Tasks, in all three experiments, we calculated the mean value of α 's (in a specific time scale) for the channels F_{32} , F_{637} , P_{349} , and P_{654} , and we place these values at the Table 3.

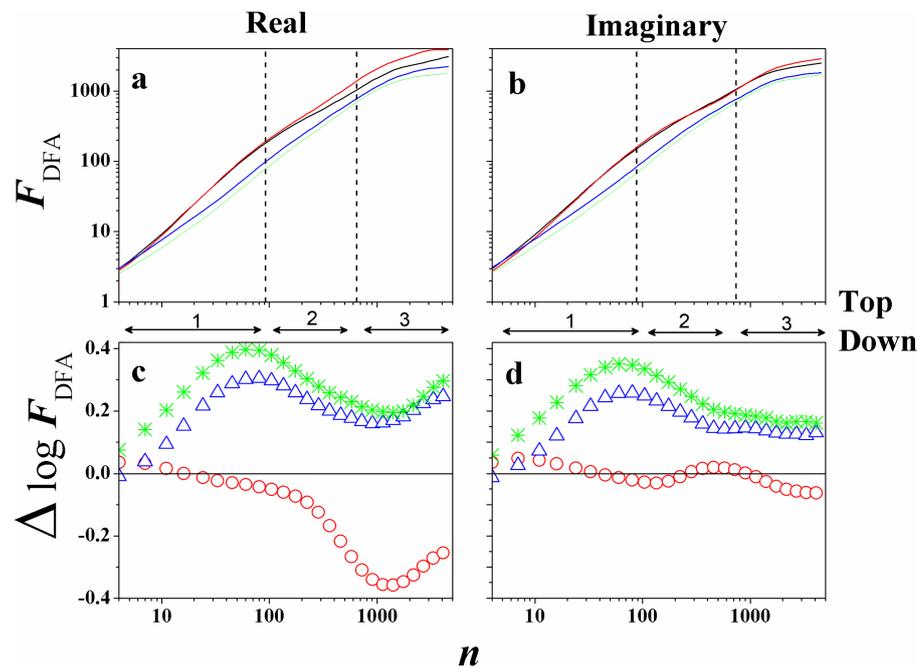


Fig 4. (Color on-line) F_{DFA} in function of n for S020 in the experiment 1 for (Top/Down): (a) Real and (b) Imaginary case. Black line represents F_{32} , red line F_{637} , blue line P_{349} , and green line P_{654} . Also, the figures below show the difference $\Delta \log F_{32:xx}$ defined by Eq 2, between the channels for the above function F_{DFA} : (c) Real and (d) Imaginary case. Here, $\Delta \log F_{32:37}$ (\circ), $\Delta \log F_{32:49}$ (Δ), and $\Delta \log F_{32:54}$ (*).

<https://doi.org/10.1371/journal.pone.0183121.g004>

At the end of the Table 3 we present the global average value of α_{DFA} for the following Task: (Real (Left/Right)), (Imag (Left/Right)), (Real (Top/Down)), and (Imag (Top/Down)). These exponents clearly are time dependent, with specific value. For example:

- time scale 1 has $\alpha_{DFA} > 1$ (representing a non-stationary case);
- time scale 2 has $\alpha_{DFA} \simeq 1$ (representing a $1/f$ noise) and;
- time scale 3 has $\alpha_{DFA} \simeq 0.5$ (representing a random case).

We noticed that, α_{DFA} is independent of the Task performed by the subject, see Fig 5 for better visualization.

However, our main objective was to measure the $\Delta \log F_{32:xx}$ to compare the brain activities between the hemispheres (left/right and frontal/parietal). Figs 3 and 4 showed preliminary results of this study, with $\Delta \log F_{32:xx}$ in function of n , and interesting things can be observed. We can identify that:

$$\begin{aligned} \Delta \log F_{32:49} &> 0, \\ \Delta \log F_{32:54} &> 0, \text{ and} \\ \Delta \log F_{32:37} &\simeq 0. \end{aligned}$$

This analysis shows the greater prevalence in amplitude of the frontal channels in relation to the parietal channels, for this Task. The maximum of $\Delta \log F_{32:49}$, $\Delta \log F_{32:54}$ is found in $n \simeq 90$ ($t = 0.56s$), and the Fig 6 presents the global average of the rms fluctuation function.

Table 3. Mean values of α_{DFA} for all experiments (three). First column represents the subjects, and their respective Task. The remaining columns represents the analyzed channels. Time scale represent the range for DFA analysis of $\alpha_{DFA}(n)$ (slope): α_1 in time scale 1, α_2 in time scale 2, and α_3 in time scale 3. Last line show the mean value of the columns for: Real (L/R), Imag (L/R), Real (T/D), Imag (T/D).

Channel		32			37			49			54		
Time scale		1	2	3	1	2	3	1	2	3	1	2	3
20	Real (L/R)	1.36	0.90	0.45	1.40	0.97	0.49	1.12	1.02	0.41	1.14	1.21	0.47
	Imag (L/R)	1.00	0.87	0.50	1.35	0.87	0.50	1.08	1.10	0.52	1.10	1.09	0.43
	Real (T/D)	1.33	1.16	0.43	1.39	1.18	0.46	1.15	1.29	0.48	1.18	1.35	0.49
	Imag (T/D)	1.35	1.01	0.54	1.40	1.27	0.51	1.08	1.04	0.46	1.08	1.22	0.59
29	Real (L/R)	0.97	1.31	0.31	1.33	1.31	0.33	0.97	1.31	0.31	1.14	1.31	0.31
	Imag (L/R)	1.13	1.19	0.33	0.97	0.97	0.40	0.97	1.19	0.40	0.89	1.19	0.40
	Real (T/D)	1.18	1.14	0.24	1.07	1.19	0.45	1.02	1.37	0.32	0.95	1.39	0.29
	Imag (T/D)	0.95	1.30	0.24	0.95	0.99	0.24	0.95	1.39	0.24	0.95	1.39	0.24
43	Real (L/R)	1.09	1.08	0.65	0.96	0.93	0.96	1.09	1.17	0.65	1.07	1.08	0.56
	Imag (L/R)	1.29	0.94	0.44	1.29	0.94	0.44	0.96	1.12	0.60	0.87	1.08	0.58
	Real (T/D)	1.29	0.99	0.48	1.21	0.99	0.45	1.05	1.12	0.48	1.05	1.11	0.49
	Imag (T/D)	1.11	0.97	0.49	0.98	0.97	0.41	1.11	1.17	0.49	1.06	1.06	0.46
46	Real (L/R)	1.18	0.97	0.56	1.18	1.01	0.56	1.18	1.01	0.56	0.93	1.01	0.56
	Imag (L/R)	1.14	0.91	0.35	1.14	0.91	0.35	1.09	1.04	0.32	1.01	1.01	0.56
	Real (T/D)	1.26	0.90	0.40	1.26	0.90	0.40	1.01	1.02	0.39	1.01	1.02	0.39
	Imag (T/D)	1.29	0.74	0.43	1.29	0.74	0.43	1.17	0.88	0.49	1.17	0.88	0.49
50	Real (L/R)	1.10	0.81	0.48	0.97	0.81	0.43	0.94	1.01	0.51	0.95	0.88	0.50
	Imag (L/R)	0.98	0.99	0.55	0.86	0.94	0.45	0.90	1.01	0.55	0.92	0.84	0.52
	Real (T/D)	1.01	0.89	0.43	0.90	0.91	0.48	0.89	0.94	0.49	0.90	0.81	0.52
	Imag (T/D)	1.08	0.85	0.41	0.94	0.88	0.38	0.94	0.97	0.43	0.95	0.89	0.45
51	Real (L/R)	1.40	0.82	0.40	1.44	0.86	0.38	1.16	0.95	0.65	1.17	0.96	0.53
	Imag (L/R)	1.41	0.80	0.34	1.46	0.80	0.38	1.19	0.97	0.57	1.20	1.01	0.55
	Real (T/D)	1.44	0.81	0.37	1.47	0.79	0.36	1.21	0.95	0.60	1.21	0.96	0.59
	Imag (T/D)	1.45	0.77	0.58	1.49	0.76	0.54	1.25	0.99	0.82	1.23	1.01	0.91
60	Real (L/R)	1.22	1.01	0.69	1.19	0.92	0.68	0.99	1.18	0.85	1.01	1.21	0.90
	Imag (L/R)	1.12	1.08	0.86	1.09	0.96	0.76	0.92	1.26	0.89	0.94	1.32	0.91
	Real (T/D)	1.06	1.01	0.75	1.08	0.92	0.73	0.86	1.22	0.80	0.85	1.30	0.85
	Imag (T/D)	1.16	1.08	0.70	1.16	0.96	0.70	0.90	1.21	0.79	0.94	1.25	0.85
71	Real (L/R)	0.94	1.05	0.54	0.94	1.08	0.51	0.88	1.06	0.55	0.93	1.07	0.57
	Imag (L/R)	0.94	1.13	0.65	0.93	1.07	0.51	0.89	1.03	0.55	0.93	1.04	0.59
	Real (T/D)	0.87	1.08	0.61	0.93	1.07	0.52	0.92	1.03	0.52	0.92	1.08	0.58
	Imag (T/D)	0.93	1.05	0.94	0.94	1.07	0.50	0.88	1.06	0.55	0.93	1.06	0.56
86	Real (L/R)	1.36	0.88	0.50	1.39	0.81	0.53	1.15	0.98	0.57	1.15	1.03	0.49
	Imag (L/R)	1.38	0.75	0.49	1.39	0.77	0.48	1.19	0.87	0.48	1.21	0.91	0.44
	Real (T/D)	1.36	0.87	0.48	1.39	0.88	0.53	1.14	1.04	0.49	1.17	1.06	0.48
	Imag (T/D)	1.36	0.85	0.46	1.37	0.84	0.50	1.17	0.96	0.49	1.18	0.96	0.51
99	Real (L/R)	0.82	0.87	0.18	0.92	0.87	0.18	0.79	1.12	0.21	0.82	1.30	0.18
	Imag (L/R)	0.84	0.88	0.21	0.99	0.86	0.19	0.79	1.08	0.18	0.82	1.27	0.15
	Real (T/D)	0.84	0.80	0.25	0.98	0.85	0.17	0.81	0.96	0.22	0.81	1.19	0.19
	Imag (T/D)	0.90	0.78	0.18	1.04	0.77	0.25	0.82	0.97	0.23	0.85	1.21	0.17
mean	Real (L/R)	1.14	0.97	0.48	1.17	0.96	0.51	1.03	1.08	0.53	1.03	1.11	0.51
	Imag (L/R)	1.12	0.95	0.47	1.15	0.91	0.45	1.00	1.07	0.51	0.99	1.08	0.51
	Real (T/D)	1.16	0.97	0.44	1.17	0.97	0.46	1.01	1.09	0.48	1.01	1.13	0.49
	Imag (T/D)	1.16	0.94	0.50	1.16	0.93	0.45	1.03	1.06	0.50	1.03	1.09	0.52

<https://doi.org/10.1371/journal.pone.0183121.t003>

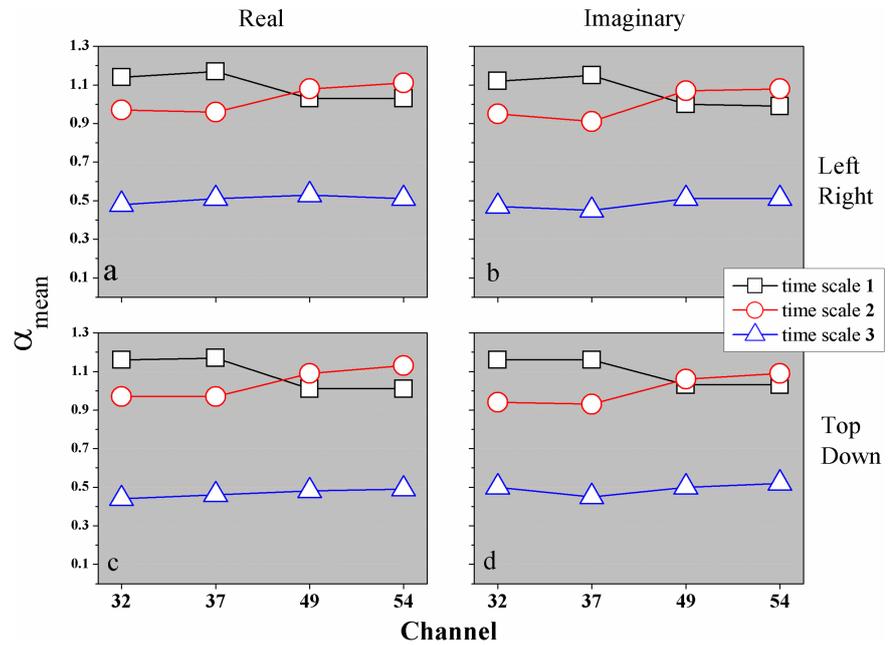


Fig 5. (Color on-line) Mean values of α_{DFA} for all subjects in all Tasks: (a) Real (L/R), (b) Imag (L/R), (c) Real (T/D), and (d) Imag (T/D) Tasks. The symbol (\square) represents time scale 1, (\circ) time scale 2, and (\triangle) time scale 3.

<https://doi.org/10.1371/journal.pone.0183121.g005>

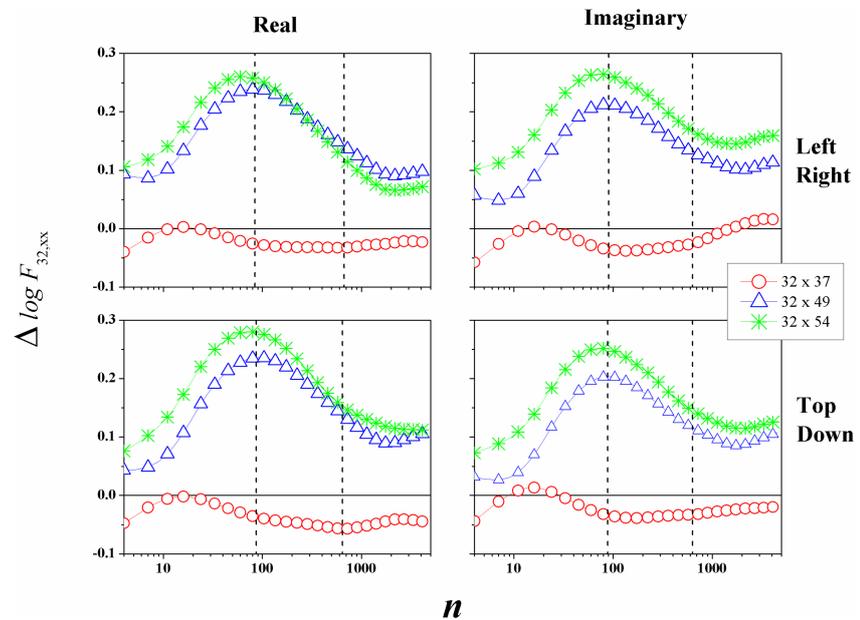


Fig 6. (Color on-line) Mean value of $\Delta \log F_{32,xx}$ between the channel F_{32} and others three. Every curve represent the difference between F_{32} and: (\circ) F_{37} , (\triangle) P_{349} , and ($*$) P_{654} .

<https://doi.org/10.1371/journal.pone.0183121.g006>

If we remember what means $\Delta \log F_{32,xxx}$ Eq 2, then we clearly see that the channels P_{349} and P_{654} have a smaller fluctuation if we compare with channel F_{332} , and the maximum of this difference is around $n = 90$ ($t = 0.56s$). The difference between F_{332} and F_{637} is approximately zero, but with a slight negative level. This result shows that the channel F_{637} has a higher value for F_{DFA} rms function. But, for $n \simeq 15$ the amplitude in relation to channel F_{332} had the same magnitude, because $\Delta \log F_{32,37} \simeq 0$.

Discussion

In this paper we studied how the amplitude of the rms fluctuation function, F_{DFA} , behaves in a 64 channels EEG, taken for 10 subject in different tasks (motor/imaginary). In this sense, in a logical way, we analyzed how the cerebral hemispheres left/right (frontal) and left/right (parietal) are related. As you know, the left side of the brain is responsible for controlling the right side of the body. It also performs tasks that have to do with logic. On the other hand, the right hemisphere coordinates the left side of the body, and performs tasks that have to do with creativity. Already the parietal lobe, integrates sensory information, including spacial sense and navigation. The major sensory inputs from the skin (touch, temperature, and pain receptors), relay through the thalamus to the parietal lobe. Also, areas of the parietal lobe are important in language processing.

Thus, by the motor/imaginary experience presented here, where the subjects perform activities that are not related with the parietal lobe, we expect to find a greater activity in the frontal channels. And even more, how does this happen in time scale? In this sense we chose the central channels in each hemisphere (frontal and parietal), present here by F_{332} (left frontal), F_{637} (right frontal), P_{349} (left parietal), and P_{654} (right parietal). Hence, applying the DFA method in first hand, we found three time scales with three values of α_{DFA} exponents, see Table 3 and Fig 5. This figure shows that the channels F_{332} and F_{637} behave in a similar way, in other words, for time scale 1 the tendency is to find $\alpha_{DFA} > 1$ (non-stationary) and for time scale 2 the value of $\alpha_{DFA} \simeq 1$ ($1/f$ noise). For time scale 3 $\alpha_{DFA} \simeq 0.5$ (uncorrelated). However, this situation changes for the channels P_{349} and P_{654} , because time scales 1 and 2 tend to a same value for α_{DFA} , mainly the channel P_{349} .

We provide that the current manuscript advances on previous work, because the EEG signal is mostly analyzed in the frequency domain and here, with DFA method, we are analyzing the EEG signal in the time domain, which allows us to see directly the time scale. Thus, with the auto-correlation exponent (α_{DFA}), we could identify three time scales for the rms fluctuation function, that are: i) Time scale 1, with $4 \leq n \leq 90$; ii) Time scale 2, with $91 \leq n \leq 655$; iii) Time scale 3, with $n > 655$. Also, we can compare the EEG channels by rms function, and infer which channel has the greatest (or not) amplitude (brain activity). This goal was reached when we defined Eq 2 and obtained the results of EEG time series. In our analysis, the frontal channels are the ones that present greater fluctuation in the Motor/Imaginary activities, if we compared to the parietal channels. This is a new way to analyze the EEG signals, because it has not yet been implemented, and that may help in the future assist EEG analysis of people with some type of brain disorder.

We can see in these results that the proposed method can be used to interpret the functioning of the brain from the point of view of the DFA functional mapping, during motor activation in real/imaginary situation.

Conclusion

In this paper we propose a new methodology to analyze EEG signals, which are generally treated in the frequency spectrum, by Fourier for example. We study the F_{DFA} rms function.

Therefore, analyzing the channels F_{32} , F_{37} (frontal region of the head), P_{39} , and P_{54} (parietal region of the head), we found that the amplitude of fluctuation tends to be larger in the frontal channels (F_{32} and F_{37}), if we compare with the channels located in the parietal region of the brain (P_{39} and P_{54}).

We start this paper by calculating the auto-correlation exponent α_{DFA} , that show three values α_1 (time scale 1), α_2 (time scale 2), and α_3 (time scale 3). For F_{32} and F_{37} the auto-correlation exponent $\alpha_1 > \alpha_2$. But, for P_{39} and P_{54} , $\alpha_1 < \alpha_2$. For large time scales, $n > 656$ or $t > 4.1s$ (which corresponds to the interval between two rests) the time series of EEG human motor/imaginary has a same type of behavior for all Tasks. In this time scale 3 $\alpha_3 \simeq 0.5$ (uncorrelated time series), for all Tasks (real/imaginary, left/right, top/down) and channels (see Fig 5).

Our goal was that, from F_{DFA} and the information about the EEG channels amplitude, we define $\Delta \log F_{32;xx}$ and we applied this new function for human EEG motor/imaginary analysis. In this sense, we did not identify in this analysis large differences between motor/imaginary activity, except for the small difference between real/imaginary and left/right Tasks at the channels P_{39} and P_{54} , because $\Delta \log F_{32;49} < \Delta \log F_{32;54}$ Fig 6. Likewise, we identify a peak in $\Delta \log F_{32;xx}$ located at $n \simeq 90$ ($t = 0.56s$). For $n > 656$ ($t > 4.1s$), $\Delta \log F_{32;xx}$ tends to a constant value.

In order to improve the statistics, we also calculated the difference, $\Delta \log F_{32;xx}$ between the channel 32 and the channel 09, 11, and 13 (center of the brain, see Fig 1). The results (not shown here) are very similar to those found between the channel 32 and those below (parietal region). Also, for test the reference channel in our raw data, we considered as a reference electrode standardization technique (REST) [26, 27]. The results of $\Delta \log F_{32;xx}(rest)$ are qualitatively similar for the original time series, changing only in the amplitude, smaller in the REST.

Finally, this analysis could be done taking into account a single individual (such as S020 explained above). In this case, $\Delta \log F_{yy;xx}$ analysis can be very useful for comparing channels ($yy;xx$) in individuals with some type of anomaly, such as seizures, epilepsy, head injuries, dizziness, headaches, brain tumors and sleeping problems, amongst others. This is a novel strategy to study brain activity in EEG.

Supporting information

S1 Table. Values of α_{DFA} for all subjects. First column represents the subjects, and their respective Task. The remaining columns represents the analyzed channels. Results for Channels C_{39} , C_{z11} , and C_{413} (central part of the brain).
(PDF)

S1 Fig. Mean values of α_{DFA} exponents for all subjects in all Tasks. (a) Real (L/R), (b) Imag (L/R), (c) Real (T/D), and (d) Imag (T/D). Results for Channels C_{39} , C_{z11} , and C_{413} (central part of the brain).
(PDF)

S2 Fig. F_{DFA} in function of n for S020 in the experiment 1, the below figure show the difference defined by Eq 2. Here we have a Left/Right case. Results for Channels C_{39} , C_{z11} , and C_{413} (central part of the brain).
(PDF)

S3 Fig. F_{DFA} in function of n for S020 in the experiment 1, the below figure show the difference defined by Eq 2. Here we have a Top/Down case. Results for Channels C_{39} , C_{z11} , and C_{413} (central part of the brain).
(PDF)

Acknowledgments

Gilney F. Zebende thanks the CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) (Grant 309288/2013-4), Brazilian agency.

Author Contributions

Conceptualization: Gilney Figueira Zebende, Florêncio Mendes Oliveira Filho.

Data curation: Gilney Figueira Zebende, Florêncio Mendes Oliveira Filho, Juan Alberto Leyva Cruz.

Formal analysis: Gilney Figueira Zebende, Florêncio Mendes Oliveira Filho, Juan Alberto Leyva Cruz.

Funding acquisition: Gilney Figueira Zebende.

Investigation: Gilney Figueira Zebende, Florêncio Mendes Oliveira Filho.

Methodology: Gilney Figueira Zebende.

Project administration: Gilney Figueira Zebende, Florêncio Mendes Oliveira Filho.

Resources: Gilney Figueira Zebende, Florêncio Mendes Oliveira Filho, Juan Alberto Leyva Cruz.

Software: Gilney Figueira Zebende, Juan Alberto Leyva Cruz.

Supervision: Gilney Figueira Zebende.

Validation: Gilney Figueira Zebende.

Visualization: Gilney Figueira Zebende, Florêncio Mendes Oliveira Filho, Juan Alberto Leyva Cruz.

Writing – original draft: Gilney Figueira Zebende, Florêncio Mendes Oliveira Filho, Juan Alberto Leyva Cruz.

Writing – review & editing: Gilney Figueira Zebende, Florêncio Mendes Oliveira Filho, Juan Alberto Leyva Cruz.

References

1. Wikiwand: Available from: <http://www.wikiwand.com/en/Electroencephalography>.
2. William O. Tatum IV. Handbook of EEG interpretation. Second edition ed. ISBN: 978-1-62070-016-7. Demos Medical Publishing; 2014.
3. Yang S. The use of EEG signals for biometric person recognition. University of Kent; 2015. Available from: [https://kar.kent.ac.uk/53681/1/235Thesis%20\(Su%20Yang\).pdf](https://kar.kent.ac.uk/53681/1/235Thesis%20(Su%20Yang).pdf).
4. Swartz BE. The advantages of digital over analog recording techniques. *Electroencephalography and Clinical Neurophysiology*. 1998; 106(2):113–117. [https://doi.org/10.1016/S0013-4694\(97\)00113-2](https://doi.org/10.1016/S0013-4694(97)00113-2) PMID: 9741771
5. Wolpaw JR, Wolpaw EW. *Brain-Computer Interfaces: Principles and Practice*. Oxford University Press, New York; 2012.
6. Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PC, Mark RG, et al. PhysioBank, Physio-Toolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation*. 2000; 101(23):e215–e220. <https://doi.org/10.1161/01.CIR.101.23.e215> PMID: 10851218
7. Schalk G, McFarland DJ, Hinterberger T, Birbaumer N, Wolpaw JR. BCI2000: a general-purpose brain-computer interface (BCI) system. *IEEE Transactions on Biomedical Engineering*. 2004; 51(6): 1034–1043. <https://doi.org/10.1109/TBME.2004.827072> PMID: 15188875

8. BCI2000: a general-purpose brain-computer interface (BCI) system; 2004. Available from: <http://www.schalklab.org/publications/2004/bci2000-general-purpose-brain-computer-interface-bci-system>.
9. EEG Motor Movement/Imagery Dataset; Available from: <http://physionet.fri.uni-lj.si/physiobank/database/eegmmidb/HEADER.shtml>.
10. Curtis CE, D'Esposito M. Persistent activity in the prefrontal cortex during working memory. *Trends Cogn Sci*. 2003; 7(9):415–423. [https://doi.org/10.1016/S1364-6613\(03\)00197-9](https://doi.org/10.1016/S1364-6613(03)00197-9) PMID: 12963473
11. Romine CB, Reynolds CR. Sequential memory: a developmental perspective on its relation to frontal lobe functioning. *Neuropsychol Rev*. 2004; 14(1):43–64. <https://doi.org/10.1023/B:NERV.0000026648.94811.32> PMID: 15260138
12. Peng CK, Buldyrev SV, Havlin S, Simons M, Stanley HE, Goldberger AL. Mosaic organization of DNA nucleotides. *Phys Rev E*. 1994; 49:1685–1689. <https://doi.org/10.1103/PhysRevE.49.1685>
13. Walleczek J. *Self-organized Biological Dynamics and Nonlinear Control*. Cambridge University Press, UK; 2000.
14. Heneghan C, McDarby G. Establishing the relation between detrended fluctuation analysis and power spectral density analysis for stochastic processes. *Phys Rev E*. 2000; 62(5):6103–6110. <https://doi.org/10.1103/PhysRevE.62.6103>
15. Mirzayof D, Ashkenazy Y. Preservation of long range temporal correlations under extreme random dilution. *Physica A*. 2010; 389:5573–5580. <https://doi.org/10.1016/j.physa.2010.08.035>
16. Hurst H. Long Term Storage Capacity of Reservoirs. *Transactions of the American Society of Civil Engineers*. 1951; 116:770–799.
17. Chen Z, Ivanov PC, Hu K, Stanley HE. Effect of nonstationarities on detrended fluctuation analysis. *Phys Rev E*. 2002; 65:041107. <https://doi.org/10.1103/PhysRevE.65.041107>
18. Hu K, Ivanov PC, Chen Z, Carpena P, Eugene Stanley H. Effect of trends on detrended fluctuation analysis. *Phys Rev E*. 2001; 64:011114. <https://doi.org/10.1103/PhysRevE.64.011114>
19. Márton LF, Brassai ST, Bakó L, Losonczi L. Detrended Fluctuation Analysis of EEG Signals. *Procedia Technology*. 2014; 12:125–132. <https://doi.org/10.1016/j.protcy.2013.12.465>
20. Lee JS, Yang BH, Lee JH, Choi JH, Choi IG, Kim SB. Detrended fluctuation analysis of resting EEG in depressed outpatients and healthy controls. *Clinical Neurophysiology*. 2017; 118(11):2489–2496. <https://doi.org/10.1016/j.clinph.2007.08.001>
21. Hardstone R, Poil SS, Schiavone G, Jansen R, Nikulin V, Mansvelder H, et al. Detrended Fluctuation Analysis: A Scale-Free View on Neuronal Oscillations. *Frontiers in Physiology*. 2012; 3:450. <https://doi.org/10.3389/fphys.2012.00450> PMID: 23226132
22. Lee JM, AU Kim DJ, AU Kim IY, AU Park KS, AU Kim SI. Detrended fluctuation analysis of EEG in sleep apnea using MIT/BIH polysomnography data. *Computers in Biology and Medicine*. 2002; 32(1): 37–47. [https://doi.org/10.1016/S0010-4825\(01\)00031-2](https://doi.org/10.1016/S0010-4825(01)00031-2) PMID: 11738639
23. Kantelhardt JW, Zschiegner SA, Koscielny-Bunde E, Havlin S, Bunde A, Stanley HE. Multifractal detrended fluctuation analysis of nonstationary time series. *Physica A: Statistical Mechanics and its Applications*. 2002; 316(1–4):87–114. [https://doi.org/10.1016/S0378-4371\(02\)01383-3](https://doi.org/10.1016/S0378-4371(02)01383-3)
24. Galaska R, Makowiec D, Dudkowska A, Koprowski A, Fijałkowski M, Wdowczyk-Szulc J, et al. Multifractal properties of heart rate by multifractal detrended fluctuation analysis and wavelet transform modulus maxima analysis—are both approaches equivalent? *Journal of Electrocardiology*. 2007; 40(4): S41. <https://doi.org/10.1016/j.jelectrocard.2007.03.404>
25. Zebende GF, Fernandez BF, Pereira MG. Analysis of the variability in the sdB star KIC 10670103: DFA approach. *Mon Not R Astron Soc*. 2017; 464(3):2638–2642. <https://doi.org/10.1093/mnras/stw2611>
26. Yao D. A method to standardize a reference of scalp EEG recordings to a point at infinity. *Physiol Meas*. 2001; 22(4):693–711. <https://doi.org/10.1088/0967-3334/22/4/305> PMID: 11761077
27. Yao D. Reference Electrode Standardization Technique; Available from: <http://www.neuro.uestc.edu.cn/rest/>.

4.2 Análise dos bio-sinais do EEG durante a tarefa de leitura pelo método DFA

Diversos manuscritos mostram uma série de estudos relacionados a cognição [Aston-Jones & Cohen \(2005\)](#), [Kahneman & Beatty \(1966\)](#), [Hess & Polt \(1964\)](#), [Nassar *et al.* \(2012\)](#), [Colizoli *et al.* \(2018b\)](#), [Colizoli *et al.* \(2018a\)](#). Parte desses estudos mostram interesse em entender como processos complexos relacionados por estímulos pode ser interpretado por áreas específicas do encéfalo, sobretudo entender como essas respostas se relacionam com a cognição. Embora essas conclusões sugiram um marcador promissor de vários processos e estados associados ao aprendizado, ainda não está claro sobre a prevalência de qual região do encéfalo respondera pelo estímulo ([MANOHAR; HUSAIN, 2015](#); [MUHAMMED *et al.*, 2016](#)).

A Figura 4.5 mostra que o mesmo estímulo, neste caso a leitura de um pequeno texto, pode evidenciar em escala de cores, regiões completamente diferentes entre indivíduos submetidos a mesmas condição. As duas figuras acompanhadas do traçado eletroencefalográfico faz parte do material construído para o artigo aqui discutido neste item da tese. O traçado eletroencefalográfico corresponde ao intervalo entre 20 e 25 segundos da leitura.

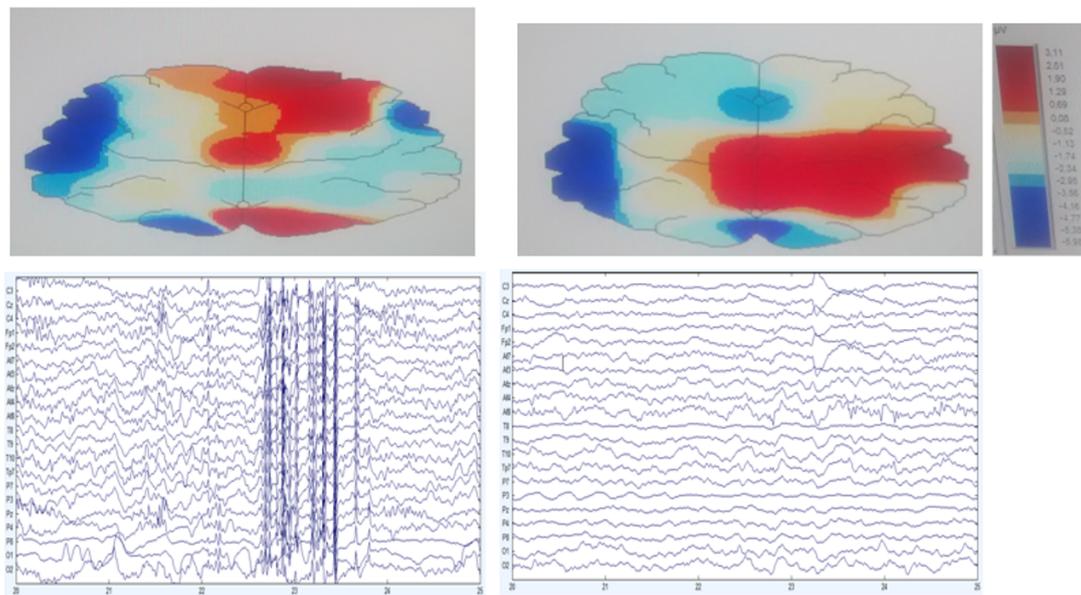


Figura 4.5: Imagens do encéfalo e traçado eletroencefalográfico.

No artigo propomos mostrar que o estímulo cerebral gerado pela leitura de um texto é considerado bastante complexo, visto que envolve visão, memória, controle motor, aprendizagem, entre outros. A abordagem é nova e possibilita explorar a análise do eletroencefalograma (EEG) funcional, assim como propor aditivos metodológicos baseado no

método estatístico, como a função "Função de Flutuação"(subseção:(3.2.2) proposta aqui nesta tese.

O experimento consiste em analisar a atividade cerebral na tarefa de leitura, realizada por dois indivíduos usando 22 canais. O aparelho usado foi o Neuromap *EQSA260* de 26 canais. Com filtro totalmente configurável e com um sistema de medição de impedância por software.

Para testar nosso modelo proposto no artigo, dois sujeitos adultos foram testados. Estes sujeitos foram dispostos em uma cadeira de frente para um painel com o texto específico a ser lido. A posição dos participantes na cadeira, tinha como objetivo excluir movimento involuntários que ativassem regiões do crebro que não estava sendo estimulado pela leitura. Para uma participante o texto foi apresentado previamente para compreensão e memorização. Para o outro participante o texto foi apresentado no momento da tarefa.

Para o processamento de sinais, escolhemos 11 bioeletrodos localizado nas regiões frontal, parietal, temporal e occipital regiões do cérebro. Os biosinais não estacionários foram tratados pelo método DFA aplicado para a função $F_{DFA}(n)$, especificamente a diferença do seu logaritmo, ou seja, $\Delta \log F_{DFA}(n)$.

Os resultados mostram que o uso desta nova função pode ser útil para estudos com atividades cerebrais, a importância dos resultados e abertura de uma nova possibilidade na área da neurociência.

Desafios superados:

O artigo foi aprovada para publicação no periódico *Physica A: Statistical Mechanics and its Applications* em 05 de Abril de 2019. Disponível online pelo endereço: <<https://doi.org/10.1016/j.physa.2019.04.035>>.

Convite do Periódico *Physica A: Statistical Mechanics and its Applications* (opcional):

Convite para publicação dos dados no periódico **Data in Brief** / <<https://www.journals.elsevier.com/data-in-brief>>.

Convite para publicação dos dados no periódico **MethodsX** / <<https://www.journals.elsevier.com/methodsx>>.



Analysis of the EEG bio-signals during the reading task by DFA method



F.M. Oliveira Filho^{a,b}, J.A. Leyva Cruz^c, G.F. Zebende^{c,*}

^a Gilberto Gil Campus, Estácio de Sá University, Salvador, Bahia, Brazil

^b Federal Institute of Bahia, Salvador, Brazil

^c State University of Feira de Santana, Bahia, Brazil

HIGHLIGHTS

- A model to analyze the brain activity (EEG signal) in the reading task is proposed.
- In order to test our model, two adults subjects (graduate) were tested.
- DFA method was applied in order to analyze the $F_{DFA}(n)$ fluctuation function.
- For brain activities studies, new possibilities in the area of neuroscience is now open.

ARTICLE INFO

Article history:

Received 26 September 2018

Received in revised form 7 January 2019

Available online 5 April 2019

Keywords:

Brain

Reading task

EEG bio-signals

DFA method

ABSTRACT

The process of reading a specific text is considered complex and little known in neuroscience, since it involves the vision, memory, motor control, learning, among others. In this sense, an excellent possibility to study the brain activity in the reading task can be achieved by the analysis of the multi-channel Electroencephalogram (EEG) and also with new statistical methods, like the detrended fluctuation analysis method (DFA). In this paper it will be proposed a model to analyze the brain activity in the reading task, performed by two subjects using a 22-channels EEG (NEUROMAP[®] model EQSA260). In order to test our model, two adults subjects (graduates) were tested here. These subjects were arranged in a chair facing a panel with the specific text, excluding involuntary movements that activated regions of the brain that were not being stimulated by reading. For the first subject, chosen at random, the text was presented before the task for understanding and some memorization. For the other subject the text was presented at the time of task. For the signal processing we chose 11 bio-electrodes located at the frontal, parietal, temporal and occipital regions of the brain. Therefore, to treat these non-stationary bio-signals we must apply robust and modern statistical techniques. With this objective, DFA method was applied in order to analyze the $F_{DFA}(n)$ fluctuation function in multi-channel EEG bio-sensors, more specifically the difference of its logarithm, i.e., $\Delta \log F_{DFA}$. The results show that the use of this new function can be useful for brain activities. This paper, as we shall see here, is an initial contribution for EEG data analyze, that would be of medical interest, mainly in neuroscience area.

© 2019 Elsevier B.V. All rights reserved.

* Corresponding author.

E-mail address: gfzebende@hotmail.com (G.F. Zebende).

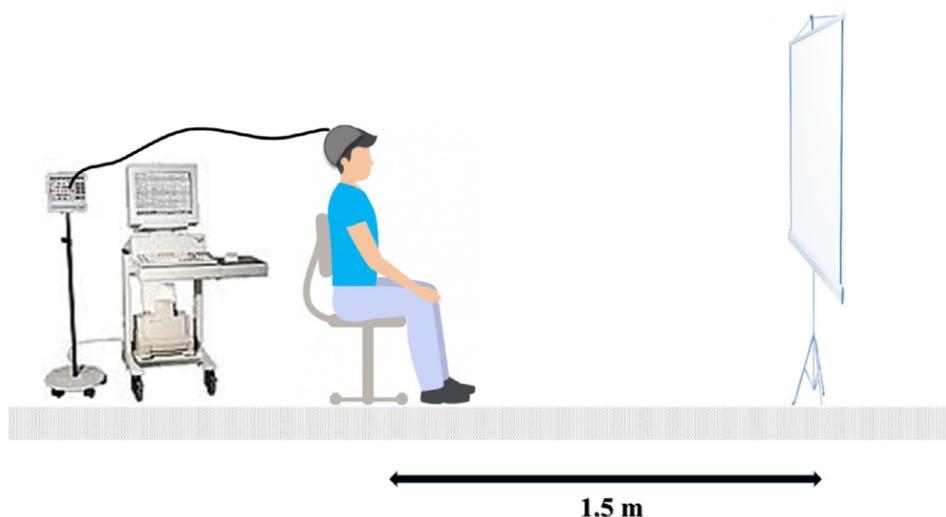


Fig. 1. Illustration: The experimental protocol for reading task.

1. Introduction

To decode brain changes produced by the process of reading is not a simple task. This process is considered complex and is little known in the view of brain activity, because it involves ocular vision, brain functions such as memory, motor control, learning, among others [1–3]. Research in this area has advanced mainly related to the neuroimaging tools. For example, it is possible to visualize patterns in the brain and compare different individuals, normal or with brain damage [4,5]. Significant contributions from neuroimaging have been used to investigate factors that affect the reading performance. Cohen et al. studied the ability of the subject to transform orthographic (sequences of words and letters) and phonological (sound and speech) information, in order to investigate the contributions of the first readings in the brain hemispheres (left and right), especially the ability of reading aloud [6]. Also, neuroimaging studies are used to create implicit recognition, in which repeated words reveal new topographies [7] or to analyze visual forms [8]. In this paper we propose a new way to study EEG signals with focus on text reading.

Here, we propose to analyze the amplitude of fluctuation of the EEG signals in temporal domain, by the DFA method, produced by 11 electrodes in the process of reading. For a better understanding of this paper, the text was divided in sections, as we will see below: 2 (materials and method), 3 (results and discussion), 4 (conclusions), and acknowledgments–references.

2. Materials and method

2.1. Experimental protocol

- i **The experiment:** Guided by the registration of the EEG bio-signals of 22 channels by two adult subjects (with a higher education level), during the reading task. The text used was suggested by a linguistic professional.
- ii **The experimental setup:** Fig. 1 shows this experimental setup. The subject was sitting in the chair located at approximately 1.5 m from the panel of 60 × 80 cm, that contained a specific text with characters of 72 pixels in the Times New Roman font. The recording of the bio-signals were performed by the NEUROMAP[®] EQSA226, in the international protocol 10–20 [9].
- iii **The experimental procedure:** First, the text was randomly delivered to one of the subjects (a) allowing 24 h for the trained reading. According to item (ii) above, without any training, the subject (b) did the reading on the panel. The bio-signals were stored on a personal computer. Afterwards, the subject (a) performed the same reading procedure. Data analysis will be described in Section 2.2.

2.2. Methodology

The Detrended Fluctuation Analysis (DFA) method was proposed by Peng et al. [10]. DFA is a method for determining the auto-correlation of the non-stationary time series, and has been cited over 2000 times. (see¹) To apply the DFA method, the following steps must be implemented:

¹ <https://www.physionet.org/physiotools/dfa/citations.shtml>.

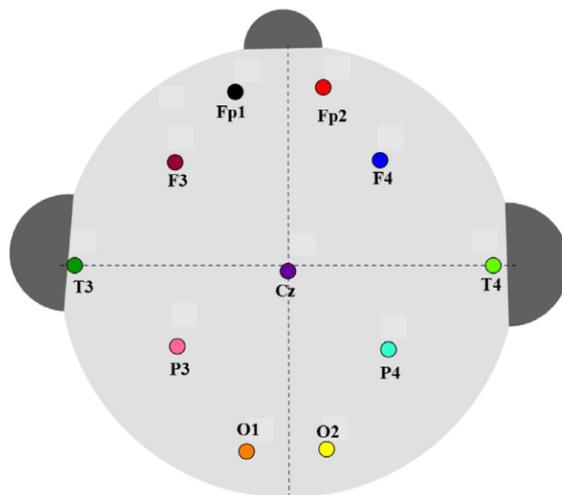


Fig. 2. Description of the electrodes position on the scalp according to the international 10–20 protocol: Fp₁ (black), Fp₂ (red), F3 (wine), F4 (blue), T3 (olive), Cz (purple), T4 (green), P3 (pink), P4 (magenta), O1 (orange), O2 (yellow).

Step 1: Consider $u(i)$ (such as the EEG signal), with $i = 1, \dots, N$, and N the length of the time series. From this variable is obtained the integrated series, $y(k) = \sum_{i=1}^k [u(i) - \langle u \rangle]$, where $\langle u \rangle$ is the mean value and $k = 1, \dots, N$;

Step 2: The signal $y(k)$ is divided into boxes of the same size n (time scale). We fit $y(k)$ using a polynomial function of order l , which represents the trend in the box. The y coordinate of the fitting line in each box is denoted by $y_n(k)$;

Step 3: $y(k)$ is detrended by subtracting the local trend $y_n(k)$ in each box (of length n);

Step 4: Now it is calculated the root-mean-square fluctuation, $F(n)$, for this new signal, that is,

$$F(n) = \sqrt{\frac{1}{N_{max}} \sum_{k=1}^{N_{max}} [y(k) - y_n(k)]^2}; \tag{1}$$

Step 5: The process above is repeated for different time scales (n), and we store the values of n and $F(n)$. If, $F(n)$, behaves as a power law, than

$$F(n) \sim n^\alpha \tag{2}$$

with α being the long-range auto-correlation exponent. DFA is applied in wide array of areas, where other techniques do not address the issue of heteroskedasticity and nonlinearity (econometric for example, [11]). However, as our intention here is to analyze via DFA method bio-signals produced by an EEG multi-channels machine. In this configuration we choose 11, as shown in Fig. 2. These electrodes were chosen in this configuration because this symmetry covers the entire hemisphere. In this sense, (Fp₁/Fp₂) and (F3/F4) are the left/right frontal lobes, (T3/Cz/T4) represent the centerline, (P3/P4) are the left/right parietal lobes, and (O1/O2) are the left/right occipital lobes of the scalp.

In order to give greater robustness to the objective of this manuscript, we implemented in data analysis the $\Delta \log F_{DFA}$ function, proposed by Zebende [3]. This function measures the log-amplitude of the F_{DFA} between two channels (here in relation to the channel Fp₁). The function is defined by:

$$\Delta \log F_{DFA} \equiv \log F_{Fp_1} - \log F_{xx} \tag{3}$$

For $\Delta \log F_{DFA}$ we can have the following conditions:

- i If $\log F_{Fp_1} - \log F_{xx} > 0$, the log-amplitude of the electrode Fp₁ in relation of the electrode xx is **larger**;
- ii If $\log F_{Fp_1} - \log F_{xx} = 0$, the log-amplitude of the electrode Fp₁ in relation of the electrode xx is **zero**;
- iii If $\log F_{Fp_1} - \log F_{xx} < 0$, the log-amplitude of the electrode Fp₁ in relation of the electrode xx , is **smaller**.

Therefore, with $\Delta \log F_{DFA}$ it is possible to compare the brain activities between the hemispheres (left/right and frontal/parietal) robustly, as we will see amongst other results in Section 3.

3. Results and discussion

For a visualization of the brain activity we initially show the results for the EEG signals in the reading task, taking into account the brain trained Fig. 3 and the brain non-trained Fig. 4. The data are untreated with a sampling rate of $\Delta t = 7.81$ ms. In both cases the total recording time of the experiment will be $N \Delta t$.

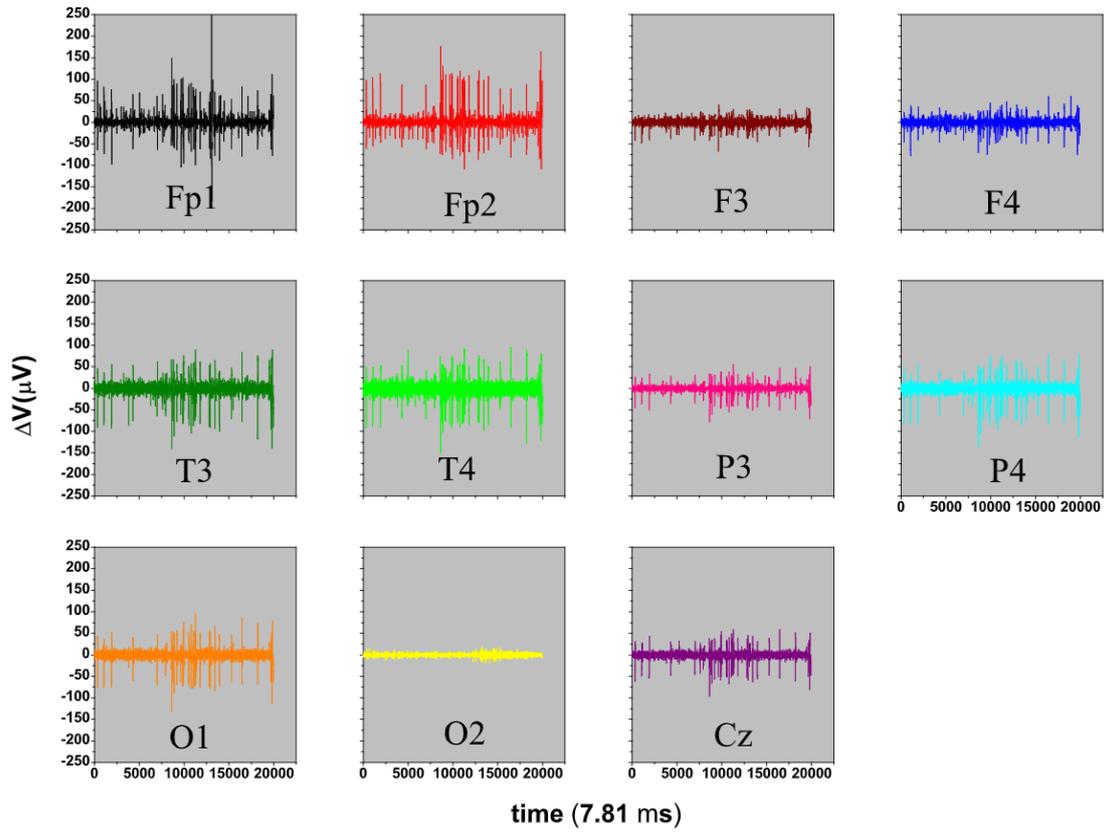


Fig. 3. Raw data for the EEG signal. The task was produced by a subject that knew the text. Here $N = 19968$ points.

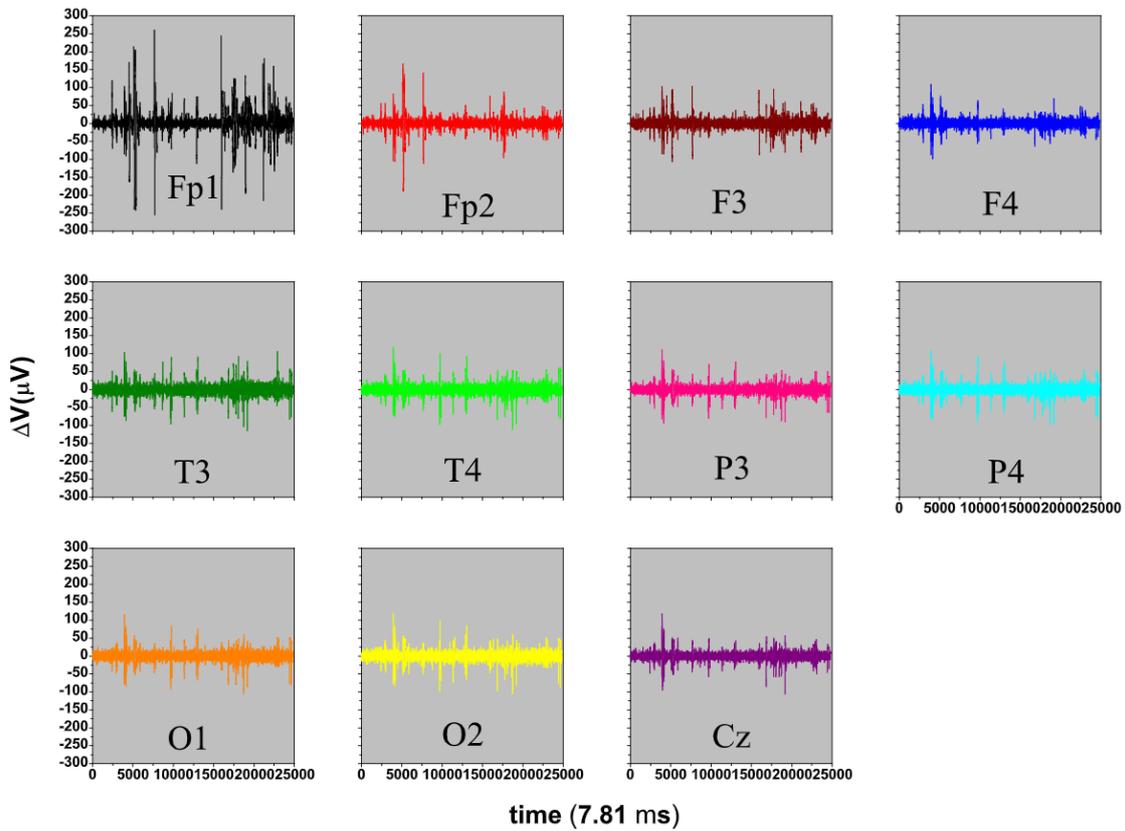


Fig. 4. Raw data for the EEG signal: The task was produced by an subject that did not know the text. Here $N = 24833$ points.

Table 1
EEG frequency bands.

Type	Frequency band (Hz)	Condition
δ -wave	< 3.5	Deep sleep
θ -wave	4 to 7	Sleeping
α -wave	8 to 13	Awake and resting
β -wave	14 to 30	Awake with mental activity

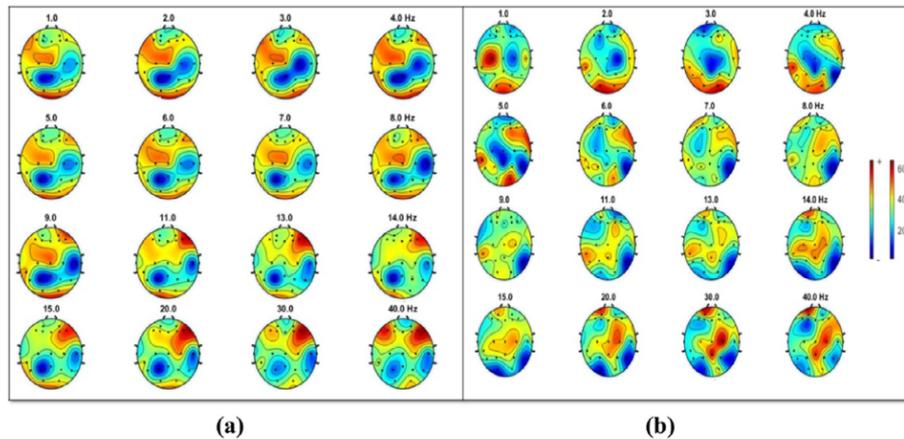


Fig. 5. EEG-Lab picture of the brain for a range of frequencies: from 1 to 40 Hz. In this figure (a) is the subject with the brain trained and (b) is the subject with the brain non-trained.

Now, the statistical analysis can be done. First of all, it is known that there are frequency bands in EEG signals. EEG waveforms are generally classified according to their frequency, amplitude and shape, as well as, the location on the scalp at which they are recorded [12,13] (see Table 1).

In order to visualize these waves and for curiosity we applied the EEG-LAB software (see Fig. 5). EEG-LAB is an Open Source Matlab Toolbox for Physiological Research distributed under the free GNU GPL license for processing data from EEG, magnetoencephalography (MEG), and other electrophysiological signals. EEG-LAB also allows users to group data from several subjects, and to cluster their independent components, see.² Fig. 5 shows the results for the subject with the brain trained (a) and for the subject with the brain non-trained (b). The EEG-LAB shows images with good definition and great detail of the whole scalp, and allows structural evaluation of the brain as a function of the stimulus to be analyzed, for an example see Fig. 5. This figure shows that the frequency band varied in a large range, in such a way to highlight the possible “ α ”-waves, defined in Table 1 with its presumed activities during the reading task. We can see the brain activities exerted during the experiment by these two subject, with the brain trained Fig. 5(a) and with the brain non-trained Fig. 5(b), and these images requires initially a refined descriptive statistical analysis (see Section 3.1). Afterwards, in Section 3.2, we present a new DFA statistical approach for these signals.

3.1. Descriptive statistical of the signals

The results of the descriptive statistical are presented in Fig. 6. In general the results obtained by mean, sd, Skewness, and Kurtosis did not show great difference between the subject with the brain trained (white circle) and the subject with the brain non-trained (black circle). But, most of the EEG had a negative asymmetry (mean < median), and Fp₁ is the channel with the highest value for sd. Concerning the Kurtosis, all channels had excess of Kurtosis and the distributions are leptokurtic (peaked distributions). With the descriptive statistics it was possible to differentiate the time elapsed for performing the reading task. (a) Subject with the brain trained, approximately 3.00 min ($N = 19968$ points) and (b) subject with the brain non-trained, approximately 3.23 min ($N = 24832$ points) (see association between time/frequency in Table 2). Table 2 makes an association between n , time scale (seconds), and frequency (Hz). Nevertheless, new methodologies for signal analysis are always welcome [14–18]. Therefore, we propose a new methodology to analyze brain activities during the reading process and here we choose the DFA method. The amplitude of fluctuation for each channels will be analyzed via DFA, as we shall see in Section 3.2.

² <https://sccn.ucsd.edu/eeglab/index.php>.

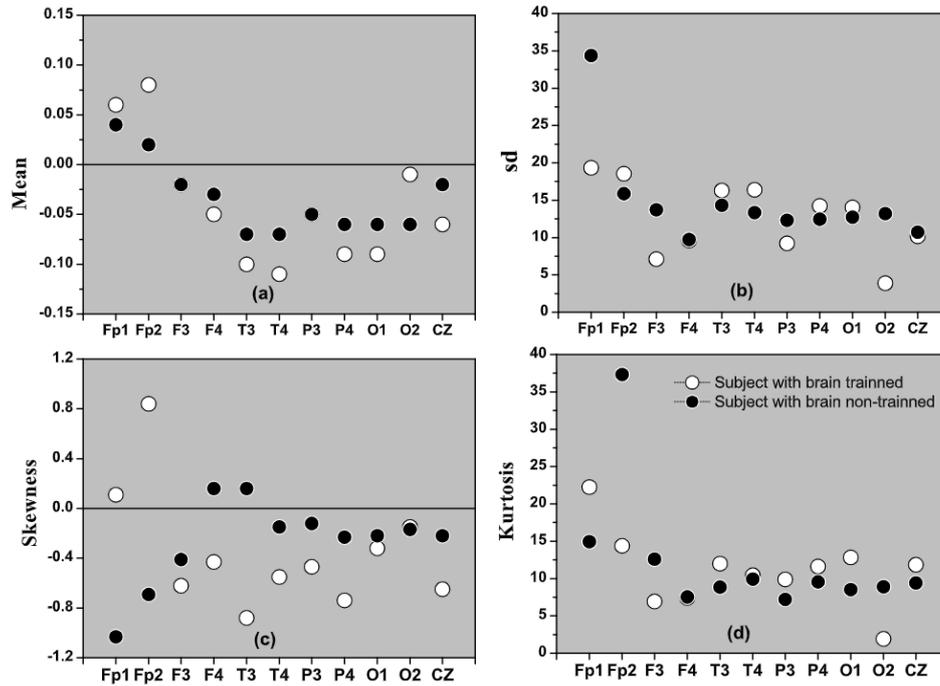


Fig. 6. Descriptive Statistical for the EEG bio-signals with: (a) Mean, (b) Standard deviation (sd), (c) Skewness, and (d) Kurtosis. In this figure the subject with the brain trained has $N = 19968$ and with the brain non-trained has $N = 24832$ points.

Table 2

Association between n , time scale, and the frequency. The Sampling rate is $\Delta t = 7.81$ ms.

n (size box)	$n\Delta t$ (s)	f (Hz)
4	0.031	32.01
9	0.070	14.23
16	0.125	8.000
32	0.250	4.000
128	1.000	1.000

3.2. The DFA analysis

Here we present the results of the DFA method in the reading task experiment. Initially we show F_{DFA} as a function of n in Fig. 7. For this figure we can see some interesting properties: (a) This figure informs the total amplitude of the fluctuation (brain activity) for all channels for these two subjects in the reading task; (b) We do not see a power-law with a single exponent α (DFA method); (c) For the two cases listed here, large time scale $n > 128$ (small frequencies, $f < 1$ Hz, vertical dashed) the behavior of fluctuation are similar, prevailing Fp₁ channel (black circle) as that of greater amplitude; (d) If we look at a small time scale (great frequencies), we see a clear differentiation between the experiments, that is, F_{DFA} is more concentrated for the subject that did not have the brain-trained with Fp₁ channel higher; (e) For the subject that had the brain-trained, there is a clear separation between the data on this time scale. We note that, because of the results in Fig. 7(b) (subject with the brain non-trained) are more concentrated and generally with a greater amplitude, if compared with Fig. 7(a), we imagine that there is more brain activity for the subject with the brain non-trained. To infer this fact more effectively, we measure the difference in the amplitudes compared to the Fp₁ channel (apparently the most active for this type of brain activity). The result for this measurement can be seen in Fig. 8.

The great difference between the subject with the brain trained Fig. 8(a) and the subject with the brain non-trained Fig. 8(b) appear for time scales $n < 128$ ($f > 1$ Hz). Even if, there is a prevalence of Fp₁ channel ($\Delta \log F_{DFA} > 0$), for subject with the brain trained there is less effort to do the reading task, given that the values are more scattered in relation to Fig. 8(b) (brain non-trained).

Looking at Fig. 8(a), if the time scale $n < 30$ ($f > 4$ Hz), the Fp₁ competes with T4, Fp₂, and T3 as the most active channel. Thus, in this case O2 (the least active), F3, P3, Cz, F4, and O1 have positive values for $\Delta \log F_{DFA}$. For $n < 10$ ($f > 14$ Hz) Fp₁ is not the most active channel, because $\Delta \log F_{DFA} < 0$, if compares with T4, Fp₂, and T3, the most active channels in this condition.

For Fig. 8(b) we can see that in general there is a greater cerebral activity between the channels, because the values are closer, with predominance of the Fp₁ channel ($\Delta \log F_{DFA} > 0$) for all time scales (frequencies).

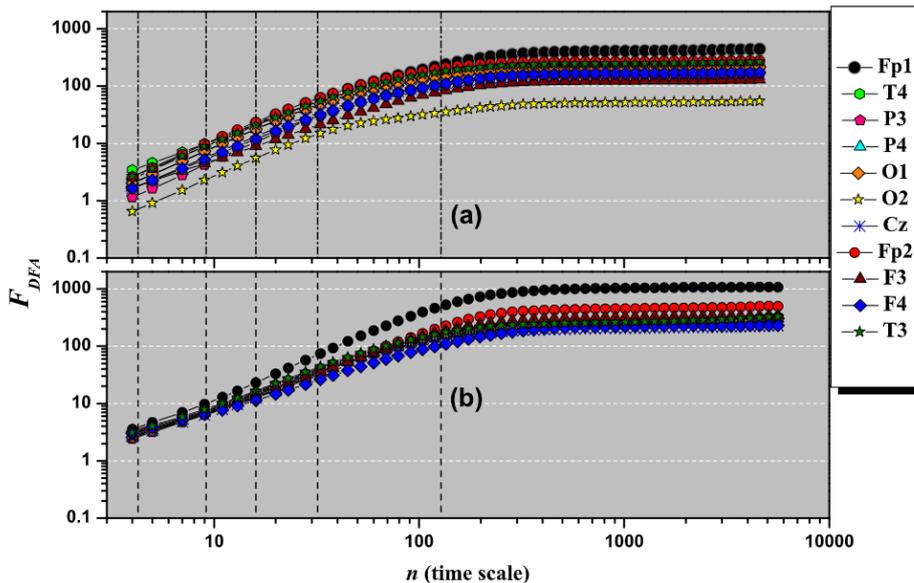


Fig. 7. F_{DFA} as a function of n : (a) Represents the experiment of a subject with brain trained and (b) Represents the experiment of a subject with brain non-trained. Here, vertical dashed lines corresponding the frequencies of 30, 14, 8, 4 and 1 Hz respectively.

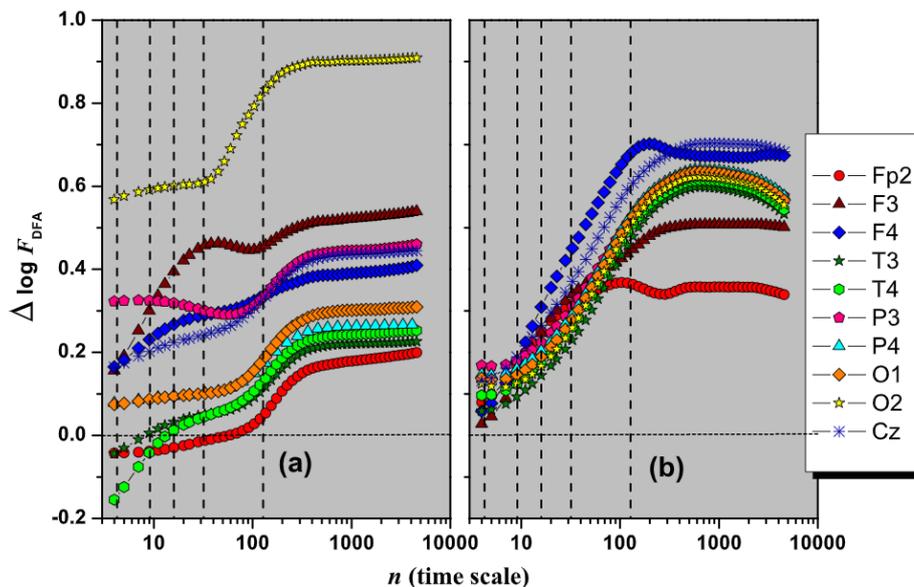


Fig. 8. $\Delta \log F_{DFA}$ as a function of n . Every curve represent the log difference between F_{p1} and others channels. Vertical dashed lines corresponding the frequencies of 30, 14, 8, 4 and 1 Hz respectively.

4. Conclusions

In this paper we analyzed the brain activity in the reading task performed by two subjects using a 22-channels EEG. To treat these non-stationary bio-signals we applied the DFA method in order to analyze the $F_{DFA}(n)$ fluctuation function, more specifically the difference of its logarithm, i.e., $\Delta \log F_{DFA}$. Of these two subjects, one had the brain trained in the reading process and the other did not. In this context the subject with the brain trained took approximately 3.00 min and the subject with brain non-trained took approximately 3.23 min to perform the experiment. The results show that there are clear differentiation between the experiments, F_{DFA} is more concentrated for the subject that did not have the brain-trained, while there is a clear separation between the data for the subject with the brain trained. Knowing that there are frequency bands in EEG signals, then the great difference between the subject with the brain trained and the subject with the brain non-trained appear for time scales $n < 128$ ($f > 1$ Hz). We can show that for the subject with brain trained there is less effort to do the reading task. However, individual characteristics may be important in this process, and to resolve this question a more number of subjects would be welcome (in development). Finally, this paper is an

initial contribution for EEG data analyze, mainly in neuroscience area. This approach can be useful for brain activities study, such as in neuronal disorders (Parkinson, Alzheimer, etc.), and future studies can be conducted in this direction.

Acknowledgment

G.F. Zebende thanks CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), Brazil (Grant 304362/2017-4), Brazilian agency.

References

- [1] J. Munzert, B. Lorey, K. Zentgraf, Cognitive motor processes: The role of motor imagery in the study of motor representations, *Brain Res. Rev.* 60 (2) (2009) 306.
- [2] J. Faller, R. Scherer, U. Costa, E. Opisso, J. Medina, G.R. Müller-Putz, A co-adaptive brain-computer interface for end users with severe motor impairment, *PLoS ONE* 7 (e101168) (2014) 9.
- [3] G.F. Zebende, F.M. Oliveira Filho, J.A. Leyva Cruz, Auto-correlation in the motor/imaginary human eeg signals: A vision about the fdFA fluctuations, *PLoS ONE* 12 (9) (2017) 1–3.
- [4] J.A. Fiez, S.E. Petersen, Neuroimaging studies of word reading, *Proc. Natl. Acad. Sci. USA* 95 (3) (1998) 914–921.
- [5] J.A. Fiez, D.A. Balota, M.E. Raichle, P.S. E, Effects of lexicality, frequency, and spelling-to-sound consistency on the functional anatomy of reading, *Neuron* 24 (1) (1999) 205–2017.
- [6] L. Cohen, S. Dehaene, L. Naccache, S. Lehéricy, G. Dehaene-Lambertz, M.-A. Hénaff, F. Michel, The visual word form areaspatial and temporal characterization of an initial stage of reading in normal subjects and posterior split-brain patients, *Brain* 123 (2) (2000) 291–307.
- [7] D.M. Schnyer, J.J. Allen, K.I. Forster, Event-related brain potential examination of implicit memory processes: masked and unmasked repetition priming, *Neuropsychology* 11 (1997) 243–260.
- [8] C.J. Marsolek, Abstract visual-form representations in the left cerebral hemisphere, *J. Exp. Psychol.* 21 (1995) 375–386.
- [9] F. Sharbrough, G. Chatrian, R. Lesser, H. Luders, M. Nuwer, T. Picton, American electroencephalographic society guidelines for standard electrode position nomenclature, *Clinical Neurophysiol.* 8 (2) (1991) 200–202.
- [10] C.-K. Peng, S.V. Buldyrev, S. Havlin, M. Simons, H.E. Stanley, A.L. Goldberger, Mosaic organization of dna nucleotides, *Phys. Rev. E* 49 (1994) 1685–1689.
- [11] U. Bashir, G.F. Zebende, Y. Yu, M. Hussain, A. Ali, G. Abbas, Differential market reactions to pre and post brexit referendum, *Physica A* 515 (2019) 151–158.
- [12] D.L. Schomer, F.L. da Silva, *Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*, sixth ed., Oxford University Press, 2011.
- [13] A.A. Ioannides, V. Poghosyan, J. Dammers, M. Streit, Real-time neural activity and connectivity in healthy individuals and schizophrenia patients, *NeuroImage* 23 (2) (2004) 473–482.
- [14] G.F. Zebende, Dcca cross-correlation coefficient: quantifying level of cross-correlation, *Physica A* 390 (4) (2011) 614–618.
- [15] R.T. Vassoler, G.F. Zebende, Dcca cross-correlation coefficient apply in time series of air temperature and air relative humidity, *Physica A* 391 (7) (2012) 2438–2443.
- [16] L. Kristoufek, Detrending moving-average cross-correlation coefficient: Measuring cross-correlations between non-stationary series, *Physica A* 406 (2014) 169–175.
- [17] P. Talkner, R. Weber, Power spectrum and detrended fluctuation analysis: Application to daily temperatures, *Phys. Rev. E* 62 (2000) 150–160.
- [18] G.F. Zebende, B.F. Fernandez, M.G. Pereira, Analysis of the variability in the sdb star KIC 10670103: Dfa approach, *Mon. Not. R. Astron. Soc.* 464 (3) (2017) 2638–2642.

4.3 Ferramentas Desenvolvidas

Arquivos gerados pela máquinas de EEG possui extensão .EDF. Esse tipo de formato precisar ser transformado em uma extensão compatível com o formato aceito pelo programa **Monta Matriz**. Já o **ρ DCCA Desenho**, interpreta os dados gerados pelo Monta Matriz. Ambos desenvolvidos para atender ao objetivo da Tese.

A proposta do programa Monta Matriz é reconhecer e ler o arquivo "rhoDCCA.txt" e converter em um planilha do excel. O algoritmo que define o arquivo "rhoDCCA" está baseado no método ρ DCCA, disponível na seção 3.2.4.

O programa gera uma matriz quadrada, imprimindo apenas a matriz triangular superior com diagonal principal igual a 1. A diagonal principal igual a 1 implica dizer que estamos correlacionando um canal de EEG com ele mesmo. O programa tem a opção de escolher o intervalo entre os box (4 até 4564) e também o critério para as correlações. Um critério adotado para a análise foram os intervalos: correlação fraca ($0.000 \leq \text{fraca} < 0.333$), correlação média ($0.333 \leq \text{média} < 0.666$), e acima de 0.666 até 1.000, correlação forte.

Um exemplo da funcionalidade do programa é converter um arquivo .EDF de 22 ou 64 canais. Ao fazermos esse procedimento, será gerada uma matriz de 22 x 22 ou 64 x 64, depende do tipo de EDF disponível para a entrada. Neste trabalho usamos arquivos de 22 canais e 64 canais.

Em função da combinação dos canais serem comutativos (Exemplo: canal 32 x canal 35 = canal 35 x canal 32), o programa gera apenas um arquivo em excel com forma de uma matricial triangular superior de diagonal 1 (correlação cruzada perfeita entre dois canais de EEG). A parte visual do programa pode ser visto na figura 4.6.

A matriz gerada será montada a partir da combinação dos canais ($C_{n,p} = \binom{n}{p} = \frac{n!}{p!(n-p)!}$). Aqui n é o número de canais e p a permutação entre canais. Ver modelo estrutural na Figura 4.7.

Tratando-se da primeira versão do programa Monta Matriz, espera-se, futuramente, algumas melhorias e implementações. Isso irá acontecer naturalmente em função do próprio tipo de arquivo gerado e do número de canais disponível pelo aparelho de EEG. Esta variação de canais acontece em função do tipo de teste que se pretende fazer.

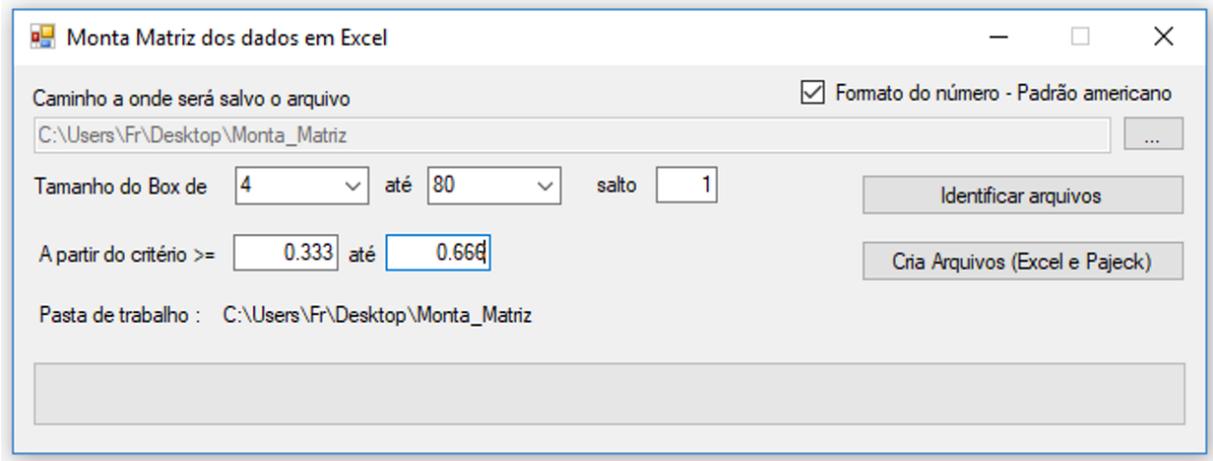


Figura 4.6: Programa Monta Matriz

$$M_{64 \times 64} = \begin{bmatrix} C_{1,1} & C_{1,2} & \cdot & \cdot & \cdot & C_{1,64} \\ & C_{2,2} & & & & \cdot \\ & & C_{3,3} & & & \cdot \\ & & & C_{4,4} & & \cdot \\ & & & & C_{5,5} & C_{59,64} \\ & & & & & C_{64,64} \end{bmatrix} = \begin{bmatrix} 1 & \rho_{1,2} & \cdot & \cdot & \cdot & \rho_{1,64} \\ & 1 & & & & \cdot \\ & & 1 & & & \cdot \\ & & & 1 & & \cdot \\ & & & & 1 & \rho_{59,64} \\ & & & & & 1 \end{bmatrix}$$

Figura 4.7: Modelo estrutural gerado pelo programa Monta Matriz

O programa ρ DCCA **Desenho** é um programa simples, criado para ler todas as correlações geradas pelos arquivos do Monta Matriz. A priori o programa foi criado para interpretar a base do physionet, disponível no endereço: <<https://www.physionet.org/>>.

Especificação do ρ DCCA **Desenho**:

Linguagem	Microsoft C #
Ambiente	Desktop
Arquitetura	Desenvolvido em 3 camadas / arquivos XLS
Modelagem de desenvolvimento	UML (Unified Modeling Language)
Saída de interface gráfica	Gerador automático de imagens / arquivos XLS

A interface do programa ρ DCCA **Desenho** tem essa estrutura em função de um protocolo experimental que foi desenvolvido para atender diferentes tarefas motoras / imagens, enquanto 64 canais foram registrados usando o sistema *BCI2000* (<<http://www.bci2000.org/>>).

A base <<https://www.physionet.org/>> disponibiliza 109 indivíduos, sendo que cada participante executou 14 corridas experimentais. Duas corridas de um minuto (uma com os olhos abertos, outra com os olhos fechados) e três corridas de dois minutos de cada uma

```

1  9  -90  0.203  C3..
2  11  0  0  Cz..
3  13  90  0.203  C4..
4  22  -18  0.406  Fp1.
5  24  18  0.406  Fp2.
6  25  -36  0.406  Af7.
7  26  -23  0.343  Af3.
8  27  0  0.304  Afz.
9  28  23  0.343  Af4.
10 29  36  0.406  Af8.
11 42  90  0.406  T8..
12 43  -90  0.499  T9..
13 44  90  0.499  T10.
14 45  -108  0.406  Tp7.
15 47  -126  0.406  P7..
16 49  -145  0.275  P3..
17 51  180  0.181  Pz..
18 53  145  0.275  P4..
19 55  126  0.406  P8..
20 61  -162  0.406  O1..
21 63  162  0.406  O2..

```

Figura 4.8: Arquivo .loc para Matlab / eeglab.

das quatro tarefas seguintes:

1 - Um alvo aparece no lado esquerdo ou direito da tela. O sujeito abre e fecha o punho correspondente até que o alvo desapareça. 2 - Um alvo aparece no lado esquerdo ou direito da tela. O sujeito imagina abrir e fechar o punho correspondente até que o alvo desapareça. 3 - Um alvo aparece na parte superior ou inferior da tela. O sujeito abre e fecha os dois punhos (se o alvo estiver em cima) ou ambos os pés (se o alvo estiver embaixo) até que o alvo desapareça. 4 - Um alvo aparece na parte superior ou inferior da tela. O sujeito imagina abrir e fechar os dois punhos (se o alvo estiver em cima) ou ambos os pés (se o alvo estiver embaixo) até que o alvo desapareça.

Para esse estudo não interpretamos com o programa ρ DCCA Desenho os testes com os arquivos que foram disponibilizados para resposta a estímulos com os olhos. O motivo estava associado ao tamanho das séries que seria um empecilho para trabalhar o método DFA.

Para executar o programa basta criar uma pasta para guardar os arquivos impressos, importar os arquivos gerados pelo Monta Matriz (*R011E04B00007C0333ATE0666.XLS*) para cada ilustração (DE/Real - DE/Imaginário - CB/Real - CB/Imaginário), em seguida clicar em em "Iniciar o Processo". O programa de maneira dinâmica mostrar todas as correlações existente entre os canais.

Tratando-se de uma primeira versão, futuramente, o programa passara por melhorias para atender arquivos com uma quantidade especifica de canais.

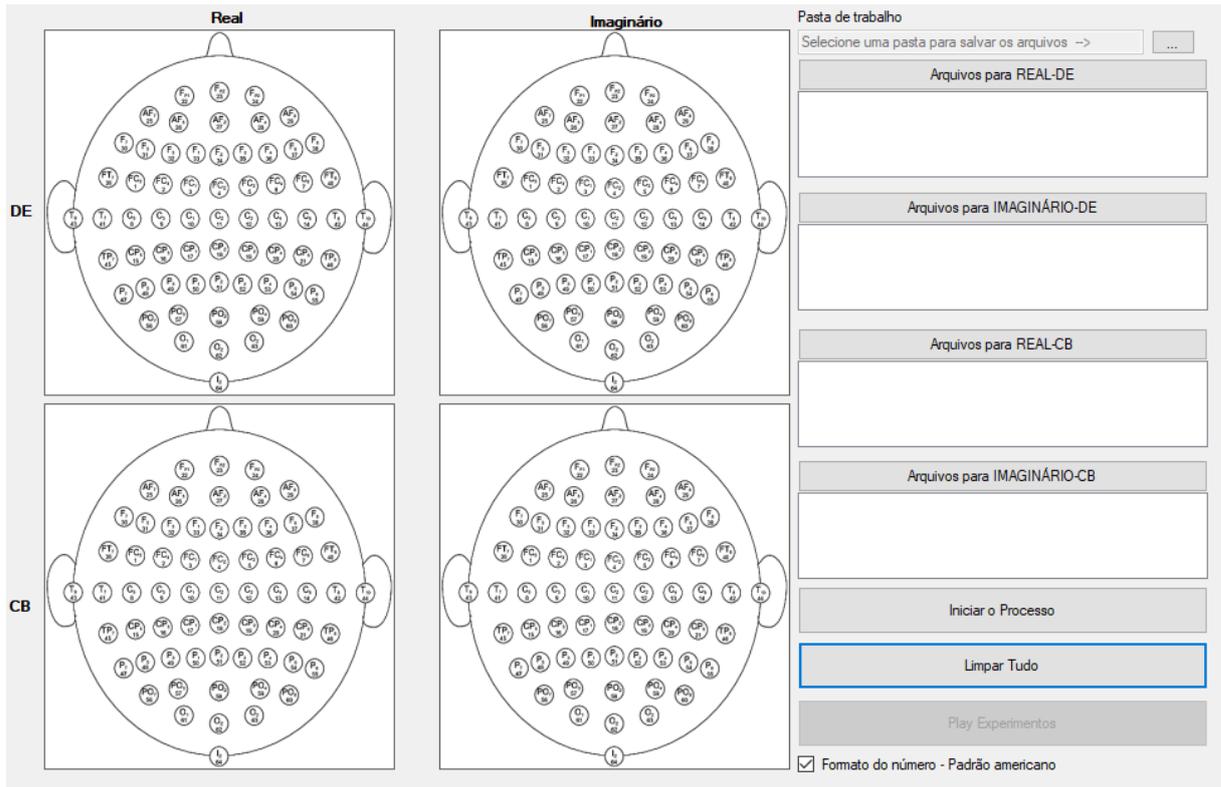


Figura 4.9: Programa ρ DCCA Desenho

A figura 4.8, refere-se a imagem de um arquivo de programa criado para gerar imagens a parti do EDF (arquivo gerado da máquinas de EEG) de 21 canais.

O eeglab é uma caixa de ferramenta do software matlab interativa para processar EEGs, MEGs contínuos e relacionados a eventos e outros dados eletrofisiologicos incorporados a análise independente (ICA), análise de tempo / frequência, rejeição de artefatos e vários modos úteis de visualização da média e dados de avaliação única. Mais detalhes do software pode ser visto no endereço: (<<https://scn.ucsd.edu/eeglab/index.php>>).

Essa ferramenta do eeglab disponibiliza para aplicação um arquivo .loc de 64 canais. Para aplicar nos arquivos EDF de 21 canais do experimento realizado para o artigo "**Análise dos bio-sinais do EEG durante a tarefa de leitura pelo método DFA**" e submetido, fizemos modificações nos canais e coordenadas dos eletrodos no encéfalo. Trata-se de um arquivo simples (.txt) e em breve estará disponível a convite no Data in Brief ou MethodsX.

O arquivo na Figura 4.8 continua sendo muito útil para gerar várias imagens. Aqui podemos ver duas figuras disponíveis, figura: 4.5, retratando o traçado eletroencefalográfico e a figura 5 do artigo "**Análise dos bio-sinais do EEG durante a tarefa de leitura pelo método DFA**", retratando a imagem da atividade cerebral para diversas frequências.

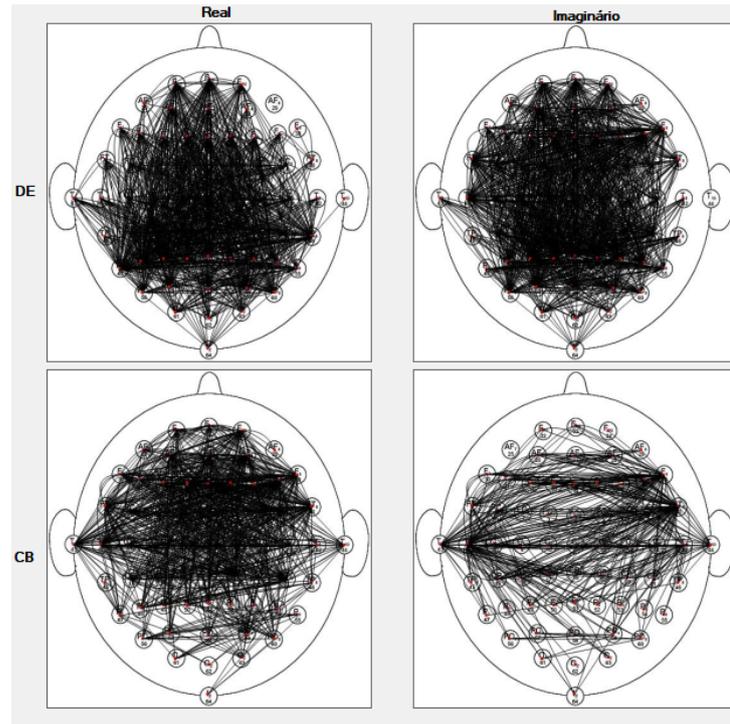


Figura 4.10: ρ DCCA Desenho - Forte correlação (ρ DCCA > 0.666).

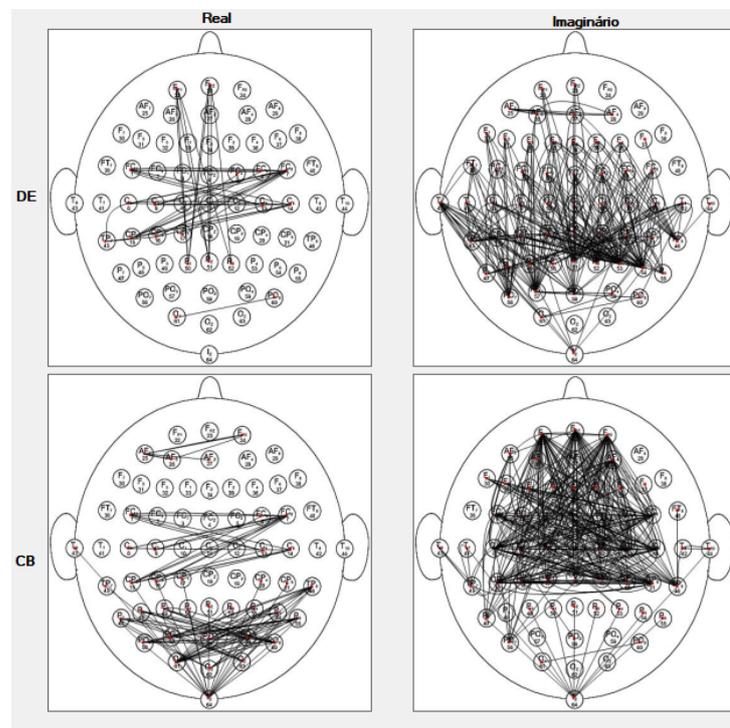


Figura 4.11: ρ DCCA Desenho - Fraca correlação (ρ DCCA < 0.333).

As Figuras 4.10 e 4.11 mostram uma simulação para níveis do ρ DCCA rodado no programa ρ DCCA Desenho.

Na Figura 4.10 temos um teste motor, arquivo *S056* da base de dados do PhysioNet, disponível em <<https://www.physionet.org/>> para ρ DCCA Desenho > 0.666). Verifica-se maior ligação entre os canais para as tarefas: direito / esquerdo (DE) real e direito / esquerdo (DE) imaginário. Para a tarefa acima / embaixo (CB) real, verifica-se uma menor atividade correlacionada na região occipital do encéfalo, em específico com o canal I_z64 . Para a tarefa acima / embaixo (CD) imaginário, verifica-se uma menor ligação entre os canais para todas as áreas do encéfalo.

Para a Figura 4.10 temos um teste motor, arquivo *S056* da base de dados do PhysioNet, disponível em <<https://www.physionet.org/>> para ρ DCCA Desenho . Para as tarefas: real direita / esquerda (DE) e acima / embaixo (CB) Imaginário, verifica-se poucas ligações entre os canais quando comparado com a Figura 4.10. Para as tarefas: direita / esquerda (DE) imaginário e acima / embaixo (CB) Imaginário, verifica-se uma menor quantidade de ligações mais com um centralizado número de ligações por região.

Considerações Finais

Conhecer instrumentos, algoritmos computacionais, funções que representam modelos associados a sistemas dinâmicos, conectividade, coerência cerebral, passa-se a representar muito bem nossas redes neurais com a capacidade neural que nos temos. Em termos de instrumentos, podemos citar: ressonância magnética, tomografia computadorizada e o EEG. Já funções que modelam sistemas dinâmicos, podemos citar: as transformadas de Laplace, Fourier, Wavelet e Hilbert.

A saúde por exemplo, é uma das áreas que adota com mais parcimônia e imediatamente as inovações por razões simples, decisões tomadas a priori, não pode ter margem para erro. A economia também é outra área que absorve muito bem ferramentas que auxilia tomadas de decisões, interpretações rápidas sobre mercado financeiro exige ferramentas e algoritmos precisos.

Ainda no contexto da saúde, podemos relacionar distúrbios degenerativos(Alzheimer), distúrbio neurodegenerativo progressivo(Parkinson), distúrbio relacionados a respostas motoras, com a necessidade de investigar e mensurar as correlações entre áreas do cérebro humano. Uma hipótese mais provável é associar o nível de correlação ao sincronismo para entender um pouco mais sobre a formação e controle por área do encéfalo.

Neste cenário bastante atual, essa tese formulou hipóteses do contexto e desenvolveu um modelo matemático e computacional dinâmico, baseado na flutuação e amplitude da flutuação, de canais de EEG, para mensurar regiões distintas do encéfalo e interpretar de maneira auto-afim sua correlação cruzada.

Para entender o modelo matemático, propomos derivar o método DFA, que está associado a autocorrelação de uma série temporal, com a eletroencefalografia de sinais, a leitura de um canal em uma área específica do encéfalo e correlacionar a outro ponto de outra região diferente. A função proposta foi a raiz quadrática média, rms, $F_{DFA}(n)$. O objetivo com a função (rms) foi medir a diferença da amplitude da flutuação entre dois canais de EEG ativos. O processo de estímulo foi motor e a base de teste foi de um repositório público disponível na página do Physionet. Os resultados deste estudo, atende ao primeiro objetivo específico da tese e foi publicado no periódico PlosOne (ZEBENDE *et al.*, 2017).

Para uma segunda aplicação da função rms, $F_{DFA}(n)$, fizemos um teste cognitivo para analisar a atividade cerebral quando estimulado pela leitura. Foi usado para registro dos arquivos de EDF o aparelho Meuromap EQS A260 com 22 canais. O teste foi realizado na

cidade de Itaberaba, na clínica Cardio Vida. O resultado deste estudo, atende ao segundo objetivo específico da tese e foi submetido ao periódico *Physica A: Statistical Mechanics and its Applications*. O manuscrito em 03 de abril de 2019 foi aprovado para publicação.

Por fim, o terceiro objetivo específico da tese, foi a construção de um ambiente dinâmico que a partir dos método $\rho DCCA(n)$ aplicado nos canais de EEG, consegue-se mostrar a dinâmica temporal de todas as correlações cruzadas por níveis. O software $\rho DCCA$ Desenho está na segunda versão e foi desenvolvido em linguagem C com arquitetura em 3 camadas, com modelagem UML.

5.1 *Trabalhos futuros*

Em termos de trabalhos futuros, algumas atividade já foram iniciadas e outras serão encaminhadas para o próximo semestre. São essas:

- ◆ Melhorias no programa $\rho DCCA$ Desenho. Proposta submetido como projeto de extensão no "Programa de Pesquisa e Produtividade 2019 / 2020" do Centro Universitário Estácio Fib, unidade Gilberto Gil. **Trabalho em andamento.**
- ◆ Explorar a base de dados do Physionet, que já se encontra com os métodos DFA, DCCA e $\rho DCCA$ rodados. **Trabalho em andamento.**
- ◆ Aplicar a Função de Flutuação $rmsF_{DFA}(n)$ para arquivos de EEG de indivíduos que possui desordens ocasionadas pela atividade elétrica do cérebro, tais como: distúrbio progressivo do sistema neural - Parkinson, distúrbio degenerativo - Alzheimer, Epilepsia, distúrbio relacionados a resposta motora, processos cognitivos, entre outros.

5.2 *Produção Acadêmica*

Produção acadêmica desenvolvida ao longo do doutorado, período: Janeiro 2015 - Abril 2019. Artigos completos.

1 - Zebende, G. F., **Oliveira Filho, F. M.**, and Cruz, J. A. L. (2017). Auto-correlation in the motor/imaginary human EEG signals: A vision about the FDFA fluctuations. *PloS one*, 12(9), e0183121.

2 - **Oliveira Filho, F. M.**, JA Leyva Cruz, and G. F. Zebende. "Analysis of the EEG bio-signals during the reading task by DFA method." *Physica A: Statistical Mechanics and*

its Applications (2019).

3 - Guedes, E. F., Brito, A. A., **Oliveira Filho, F. M.**, Fernandez, B. F., de Castro, A. P. N., da Silva Filho, A. M., and Zebende, G. F. (2018). Statistical test for ??DCCA cross-correlation coefficient. *Physica A: Statistical Mechanics and its Applications*, 501, 134-140.

4 - Guedes, E. F., Brito, A. A., **Oliveira Filho, F. M.**, Fernandez, B. F., de Castro, A. P. N., da Silva Filho, A. M., and Zebende, G. F. (2018). Statistical test for ??DCCA: Methods and data. *Data in brief*, 18, 795-798.

5 - **Oliveira, F. M.**, Soares, D. S., e Guedes, E. F. (2017). ANÁLISE DO COMPORTAMENTO DA PRODUÇÃO INDUSTRIAL DE ALIMENTOS NO BRASIL. *Ciência (In) Cena Bahia*, 1(5), 199-212.

6 - Santos Dias, J. M., César, S. F., Marques, L. S., **Oliveira Filho, F. M.**, Cunha, R. D. A., e Reis, M. C. (2018). MANUTENÇÃO DE ESTRUTURAS DE AÇO DE OBRAS PÚBLICAS EM SALVADOR: O CASO DA CONCHA ACÚSTICA. *Ciência (In) Cena Bahia*, 1(6), 114-124.

Trabalhos completos publicados em anais de congressos:

1 - Dias, J. M. S.; **Oliveira Filho, F. M.**; Araujo, A. Y. F.; Cesar, F.; Cunha, R. D. A. Avaliação Comparativa entre Métodos de Aferição do Teor de Umidade em Peças de Madeira de Dimensões Reduzidas. In: XXII Encontro Latino Americano de Iniciação Científica, XVIII Encontro Latino Americano de Pós-Graduação, XII INIC Jr da UNIVAP, VIII INID, 2018, São José dos Campos - SP. Patrimônio e Cultura Desafios da Ciência Frente a Identidades Plurais, 2018.

2 - Soares, D. S. C.; Guedes, E. F.; **Oliveira Filho, F. M.**; Silva Filho, A. M.; Zebende, G. F. Análise Temporal do Comportamento da Produção da Indústria de Alimentos no Brasil: Uma Abordagem Estatística. In: XX ENMC e VIII ECTM Encontro Nacional de Modelagem Computacional, 2017, Nova Friburgo.

3 - **Oliveira Filho, F. M.**; Zebende, G. F. Avaliação da Leitura por meio de Sinais de Áudio: um estudo com séries temporais. In: Encontro Nacional de Modelagem Computacional, 2015, Salvador. Anais do Encontro Nacional de Modelagem Computacional, 2015.

Capítulo de livro publicado: Dias, João Miguel Santos; **Filho, Florêncio Mendes Oliveira**; Araújo, Alberto Ygor Ferreira de; César, Sandro Fábio; Cunha, Rita Dione

Araújo. Avaliação Comparativa Entre Métodos de Aferição do Teor de Umidade em Peças de Madeira de Dimensões Reduzidas. Impactos das Tecnologias nas Engenharias 3. 1ed.: Antonella Carvalho de Oliveira, 2019, v.3, p. 171-179.

Resumos expandidos publicados em anais de congressos:

1 - **Oliveira Filho, F. M.**; Zebende, G. F.; Cruz, J. A. L. Correlação Cruzada na Aprendizagem Motora: Um Estudo com Sinais de EEG (Eletroencefalografia) Via Estatística de Sinais - ISBN / ISSN: 2447-9640. In: III Workshop de Gestão, Tecnologia Industrial e Modelagem Computacional. III Workshop de Gestão, Tecnologia Industrial e Modelagem Computacional, Salvador-Ba, 2017.

2 - **Oliveira Filho, F. M.**; Zebende, G. F.; CRUZ, J. A. L. Aprendizado de indivíduos pelo estudo de sinais de EEG (Eletroencefalografia) e de áudio via estatística de sinais - ISBN / ISSN: 2446-5372. In: Workshop de Gestão, Tecnologia Industrial e Modelagem Computacional. Workshop de Gestão, Tecnologia Industrial e Modelagem Computacional, Salvador-BA, 2016.

Apresentações de Trabalho:

CONGRAD - Congresso de Graduação do Centro Universitário Estácio da Bahia. Campus Gilberto Gil.

CONGRAD-2015: Avaliação do espectro vocal por meio de sinais de áudio: uma abordagem com séries temporais.

CONGRAD-2016: Correlação cruzada na aprendizagem motora: Uma abordagem com EEG (Eletroencefalografia) via estatística de sinais.

Referências Bibliográficas

- ALLEN, Bryce L. Cognitive research in information science: implications for design. *Annual review of information science and technology*, v. 26, p. 3–37, 1991. [2.4](#)
- ARGI, R. K. *ALS-Sense - Sistema de Aquisição e Processamento de Electromiogramas para Pacientes com ALS*. Tese (Doutorado) — INSTITUTO SUPERIOR DE ENGENHARIA DE LISBOA, 2015. [1](#)
- ASTON-JONES, Gary; COHEN, Jonathan D. An integrative theory of locus coeruleus-norepinephrine function: adaptive gain and optimal performance. *Annu. Rev. Neurosci.*, Annual Reviews, v. 28, p. 403–450, 2005. [4.2](#)
- BARAVALLE, Roman; A.ROSSO, Osvaldo; MONTANI., Fernando. Discriminating imagined and non-imagined tasks in the motor cortex area: Entropy-complexity plane with a wavelet decomposition. *Physica A*, v. 511, p. 27 – 39, 2018. [3.2.2](#)
- BARAVALLE, Roman; ROSSO, Osvaldo A.; MONTANI, Fernando. Causal shannonâ€šfisher characterization of motor/imagery movements in eeg. *Entropy*, v. 20, n. 9, 2018. ISSN 1099-4300. Disponível em: <<http://www.mdpi.com/1099-4300/20/9/660>>. [3.2.2](#)
- _____. Rhythmic activities of the brain: Quantifying the high complexity of beta and gamma oscillations during visuomotor tasks. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, v. 28, n. 075513, 2018. [3.2.2](#)
- BEAUCHAMP, M. S *et al.* The developmental trajectory of brain-scalp distance from birth through childhood: Implications for functional neuroimaging. *PLoS ONE*, v. 6, n. 9, p. e24981, 2011. [1](#)
- BIRD, Jordan J *et al.* Mental emotional sentiment classification with an eeg-based brain-machine interface. *St Hugh's College, University of Oxford, United Kingdom: The International Conference on Digital Image and Signal Processing (DISP'19)*, 2018. [2.3](#)
- _____. A study on mental state classification using eeg-based brain-machine interface. *Madeira Island, Portugal: 9th international Conference on Intelligent Systems 2018*, 2018. [2.3](#)
- BRONZINO, J. D. *The Biomedical Engineering Handbook*. 2th. ed. [S.l.]: Boca Raton, 2000. [1](#)
- CAHN, B Rael; POLICH, John. Meditation states and traits: Eeg, erp, and neuroimaging studies. Educational Publishing Foundation, 2013. [2.3](#), [2.3](#)
- CASSEL, Jean-Christophe. Experimental studies on the role (s) of serotonin in learning and memory functions. In: *Handbook of Behavioral Neuroscience*. [S.l.]: Elsevier, 2010. v. 21, p. 429–447. [2.3](#)
- CASTELLONE, P; RUTTEN, W. L. C; MARANI, E. Cross-interval histogram analysis of neuronal activity on multielectrode array. *PROCEEDINGS OF THE INTERNATIONAL IEEE EMBS CONFERENCE ON NEURAL ENGINEERING*, p. 301–305, 2003. [1](#)

- CHARNES, A.; FROME, E. L.; YU, P. L. The equivalence of generalized least squares and maximum likelihood estimates in the exponential family. *Journal of the American Statistical Association*, v. 71, n. 353, p. 169–171, 1976. [3.1.7](#)
- CHÁVEZ, Mario; MARTINERIE, Jacques; QUYEN, Michel Le Van. Statistical assessment of nonlinear causality: application to epileptic eeg signals. *Journal of neuroscience methods*, Elsevier, v. 124, n. 2, p. 113–128, 2003. [2.2](#)
- CHEN, Yingyuan *et al.* Dcca cross-correlation coefficients reveals the change of both synchronization and oscillation in eeg of alzheimer disease patients. *Physica A: Statistical Mechanics and its Applications*, v. 490, p. 171 – 184, 2018. ISSN 0378-4371. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0378437117307264>. [1](#), [1.3](#)
- CHERNECKY, Cynthia C; BERGER, Barbara J. *Laboratory tests and diagnostic procedures*. 6th ed. ed. [S.l.]: Elsevier, 2013. ISBN 9781455706945. [2.1](#)
- COLIZOLI, Olympia *et al.* Task-evoked pupil responses reflect internal belief states. *bioRxiv*, Cold Spring Harbor Laboratory, p. 275776, 2018. [2.4](#), [4.2](#)
- _____. Author correction: Task-evoked pupil responses reflect internal belief states. *Scientific reports*, Nature Publishing Group, v. 8, n. 1, p. 15904, 2018. [4.2](#)
- CUELLAR, M *et al.* Time–frequency analysis of the eeg mu rhythm as a measure of sensorimotor integration in the later stages of swallowing. *Clinical Neurophysiology*, Elsevier, v. 127, n. 7, p. 2625–2635, 2016. [2.4](#)
- DIGGLE, Peter J. *Time series; a biostatistical introduction*. [S.l.], 1990. [3.1.6](#)
- EADIE, Mervyn J. Shortcomings in the current treatment of epilepsy. *Expert review of neurotherapeutics*, Taylor & Francis, v. 12, n. 12, p. 1419–1427, 2012. [2.1](#)
- EHLERS, RS. Apostila análises de séries temporais. *UFPR, Curitiba, 94p*, v. 5th Edição, 2009. ([document](#)), [3.1](#), [3.1](#), [3.3](#), [3.1.3](#), [3.4](#), [3.1.4](#), [3.1.5](#), [3.1.5](#), [3.1.8](#)
- ESQUIVEL, Renata de Miranda; SENNA, Valter de; GOMES, Gecynalda Soares da Silva. Análise espectral singular: Comparação de previsões em séries temporais. *Revista ADM. MADE*, v. 16, n. 2, p. 87–101, 2013. [3.1](#)
- EVERITT, Brian S. *The Cambridge dictionary of statistics in the medical sciences*. [S.l.]: Cambridge University Press Cambridge, 1995. [3.1.6](#)
- FÁVERO, LPL; OLIVEIRA, MA de; ANGELO, CF de. Aplicação de métodos de ajustamento sazonal em séries temporais. *Seminários em Administração da Faculdade de Economia, Administração e Contabilidade da USP*, v. 6, 2003. [3.1.8](#)
- FEDER, J. Fractals plenum press new york 283 google scholar. 1988. ([document](#)), [3.7](#), [3.8](#)
- FEINBERG, I *et al.* Longitudinal sleep eeg trajectories indicate complex patterns of adolescent brain maturation. *AJP: Regulatory, Integrative and Comparative Physiology*, v. 304, n. 4, p. R296–303, 2012. [2.5](#)
- FILHO, A.S. *Correlação de longo alcance em demandas de passageiros e veículos*. 2005. [3.2.1](#)

- FILHO, A. M. da S. *Autocorrelação e Correlação Cruzada: Teorias e Aplicações*. Tese (Doutorado) — Programa de Pós-graduação em Modelagem Computacional e Tecnologia Industrial. Faculdade Senai Cimatec, 2014. ([document](#)), [3.12](#)
- FISHER, Robert S *et al.* Epileptic seizures and epilepsy: definitions proposed by the international league against epilepsy (ilae) and the international bureau for epilepsy (ibe). *Epilepsia*, Wiley Online Library, v. 46, n. 4, p. 470–472, 2005. [2.1](#)
- FONSECA, Jairo Simon da; MARTINS, Gilberto de Andrade; TOLEDO, Geraldo Luciano. *Estatística Aplicada*. [S.l.]: Editora Atlas SA, 2000. [3.1](#), [3.1.1](#)
- FREITAS, R.M. et al. *Análise de anisotropia de imagens utilizando o método DFA: um estudo de caso na área de exploração de petróleo*. Dissertação (Mestrado) — XIV Simpósio Brasileiro de Sensoriamento remoto São José dos Campos., 2009. [3.2.1](#)
- FROHLICH, Joel *et al.* A quantitative electrophysiological biomarker of duplication 15q11.2-q13.1 syndrome. *PLOS ONE*, Public Library of Science, v. 11, p. 1–18, 12 2016. Disponível em: <<https://doi.org/10.1371/journal.pone.0167179>>. [2.3](#)
- GERRARD, Paul; MALCOLM, Robert. Mechanisms of modafinil: a review of current research. *Neuropsychiatric disease and treatment*, Dove Press, v. 3, n. 3, p. 349, 2007. [2.3](#)
- GHOSH, Dipak *et al.* Chaos based nonlinear analysis to study cardiovascular responses to changes in posture. *Physica A: Statistical Mechanics and its Applications*, Elsevier, v. 512, p. 392–403, 2018. [3.2.2](#)
- GRAEFF, Frederico G. Serotonina, matéria cinzenta periaquedutal e transtorno do pânico serotonin, periaqueductal gray matter and panic disorder. *Rev Bras Psiquiatr*, SciELO Brasil, v. 25, n. Supl II, p. 42–5, 2003. [2.4](#)
- GUEDES, Djairo de Fiquereido. *Análise de Fourier e Equações Diferenciais Parciais*. Impa. [S.l.]: Projeto Euclides, 1977. [1](#)
- HALL, Peter; WOLFF, Rodney CL. On the strength of dependence of a time series generated by a chaotic map. *Journal of time series analysis*, Wiley Online Library, v. 16, n. 6, p. 571–583, 1995. [3.1.9](#), [3.1.9](#)
- HAMAINEN, Matti *et al.* Magnetoencephalography theory, instrumentation, and applications to noninvasive studies of the working human brain. *Reviews of modern Physics*, APS, v. 65, n. 2, p. 413, 1993. [2.5](#)
- HAYKIN, S. Adaptive filter theory. *NJ: Prentice-Hall Inc*, n. 476, 2000. [1](#)
- HESS, Eckhard H; POLT, James M. Pupil size in relation to mental activity during simple problem-solving. *Science*, American Association for the Advancement of Science, v. 143, n. 3611, p. 1190–1192, 1964. [4.2](#)
- HINTERBERGER, Thilo *et al.* A brain computer interface (bci) for the locked-in : Comparison of different eeg classifications for the thought translation device. *Clinical Neurophysiology*, v. 114, n. 3, 2003. [2.5](#)
- HIREKHAN, Sunil R; MANTHALKAR, Ramchandra; PHUTKE, Shruti. The detrended fluctuation analysis of eeg signals: A meditation-based study. In: *Computing, Communication and Signal Processing*. [S.l.]: Springer, 2019. p. 771–780. [3.2.2](#)

HURST, Harold Edwin. Long-term storage capacity of reservoirs. *Trans. Amer. Soc. Civil Eng.*, v. 116, p. 770–799, 1951. [3.1.9](#), [3.2.1](#)

IEVA, Antonio Di *et al.* Fractals in the neurosciences, part ii: clinical applications and future perspectives. *The Neuroscientist*, SAGE Publications Sage CA: Los Angeles, CA, v. 21, n. 1, p. 30–43, 2015. [4](#)

_____. Fractals in the neurosciences, part i: general principles and basic neurosciences. *The Neuroscientist*, SAGE Publications Sage CA: Los Angeles, CA, v. 20, n. 4, p. 403–417, 2014. [4](#)

JESTROVIĆ, Iva; COYLE, James L; SEJDIĆ, Ervin. Decoding human swallowing via electroencephalography: a state-of-the-art review. *Journal of neural engineering*, IOP Publishing, v. 12, n. 5, p. 051001, 2015. [2.4](#)

JÚNIOR, Amaro; EDSON; YAMASHITA, Helio. Aspectos básicos de tomografia computadorizada e ressonância magnética. *Revista Brasileira de Psiquiatria*, SciELO Brasil, v. 23, p. 2–3, 2001. [1.3](#)

KAHNEMAN, Daniel; BEATTY, Jackson. Pupil diameter and load on memory. *Science*, American Association for the Advancement of Science, v. 154, n. 3756, p. 1583–1585, 1966. [4.2](#)

KANASEWICH, E. R. *The Fast Fourier Transform: Time sequence Analysis in Geophysics*. Third edition. [S.l.]: The University of Alberta Press, 1974. ISBN 0-88864-074-9. [1](#)

KOZA, John R *et al.* Automated design of both the topology and sizing of analog electrical circuits using genetic programming. In: *Artificial Intelligence in Design*. [S.l.]: Springer, 1996. p. 151–170. [2.3](#)

KRAMIS, R_; VANDERWOLF, CH; BLAND, B Hi. Two types of hippocampal rhythmical slow activity in both the rabbit and the rat: relations to behavior and effects of atropine, diethyl ether, urethane, and pentobarbital. *Experimental neurology*, Elsevier, v. 49, n. 1, p. 58–85, 1975. [2.3](#)

KUTAS, Marta; HILLYARD, Steven A. Reading senseless sentences: Brain potentials reflect semantic incongruity. *Science*, American Association for the Advancement of Science, v. 207, n. 4427, p. 203–205, 1980. [2.4](#)

LINS, Otavio G *et al.* "ocular artifacts in eeg and event-related potentials i: Scalp topography". *Brain Topography*, v. 6, n. 1, p. 51–63, 1993. ISSN 1573-6792. [2](#), [3](#)

LITVAN, Irene *et al.* Diagnostic criteria for mild cognitive impairment in parkinson's disease: Movement disorder society task force guidelines. *Movement disorders*, Wiley Online Library, v. 27, n. 3, p. 349–356, 2012. [6](#)

MAGIORKINIS, Emmanouil; SIDIROPOULOU, Kalliopi; DIAMANTIS, Aristidis. Hallmarks in the history of epilepsy: epilepsy in antiquity. *Epilepsy & Behavior*, Elsevier, v. 17, n. 1, p. 103–108, 2010. [2.1](#)

MANDELBROT, Benoit B. *The fractal geometry of nature*. [S.l.]: WH freeman New York, 1982. v. 1. [3.1.9](#), [7](#), [3.1.9](#), [8](#)

MANOHAR, SG; HUSAIN, M. Reduced pupillary reward sensitivity in parkinson disease. *NPJ Parkinson's disease*, Nature Publishing Group, v. 1, p. 15026, 2015. [4.2](#)

- MICHELE, C De; MONTANARI, A; ROSSO, R. The effects of non-stationarity on the evaluation of critical design storms. *Water Science and Technology*, IWA Publishing, v. 37, n. 11, p. 187–193, 1998. [3.1.9](#)
- MORETTIN, P.A. *Análises de Séries Temporais*. [S.l.]: ABE- Projeto Fisher., 2004. [3.1](#), [3.1](#), [3.1.8](#)
- MORETTIN, P.A. *Econometria Financeira*. [S.l.: s.n.], 2008. [3.1.5](#), [3.1.7](#), [3.1.8](#)
- MORETTIN, Pedro Alberto; TOLOI, Clélia Maria de Castro. *Modelos para previsão de séries temporais*. [S.l.]: Instituto de matemática pura e aplicada, 1981. v. 1. ([document](#)), [3.2](#), [3.1.8](#)
- MUHAMMED, Kinan *et al.* Reward sensitivity deficits modulated by dopamine are associated with apathy in parkinson disease. *Brain*, Oxford University Press, v. 139, n. 10, p. 2706–2721, 2016. [4.2](#)
- MURPHY, Kieran J; BRUNBERG, James A. Adult claustrophobia, anxiety and sedation in mri. *Magnetic Resonance Imaging*, v. 15, n. 1, p. 51–54, 1997. [2.5](#)
- MYERS, David G. Explorando a psicologia. *Rio de Janeiro: LTC*, 2003. [2.4](#)
- NASSAR, Matthew R *et al.* Rational regulation of learning dynamics by pupil-linked arousal systems. *Nature neuroscience*, Nature Publishing Group, v. 15, n. 7, p. 1040, 2012. [4.2](#)
- NI, Huangjing *et al.* Exploring multifractal-based features for mild alzheimer’s disease classification. *Magnetic Resonance in Medicine*, v. 76, n. 1, p. 259–269, 2015. [1](#)
- NIEDERMEYER, Ernst. *Electroencephalography : basic principles, clinical applications, and related fields*. Philadelphia: Lippincott Williams & Wilkins, 2005. ISBN 9780781751261. [1](#), [2.1](#), [2.1](#), [2.3](#)
- NUNEZ, Paul L; SRINIVASAN, Ramesh *et al.* *Electric fields of the brain: the neurophysics of EEG*. [S.l.]: Oxford University Press, USA, 2006. [1.3](#)
- OBERMAN, Lindsay M *et al.* Eeg evidence for mirror neuron dysfunction in autism spectrum disorders. *Cognitive brain research*, Elsevier, v. 24, n. 2, p. 190–198, 2005. [2.3](#), [2.3](#)
- O’REGAN, S; FAUL, S; MARNANE, W. Automatic detection of eeg artifacts arising from head movements. *Annual International Conference of the IEEE Engineering in Medicine and Biology*, p. 6353–6, 2010. ISSN 978-1-4244-4123-5. [2.5](#)
- PEDRON, Isabel Tamara. Correlação em séries temporais de temperatura na região de cascavel, estado do paraná. *Acta Scientiarum. Technology*, Universidade Estadual de Maringá, v. 29, n. 2, 2007. [3.2.1](#)
- PENG, C.K. *et al.* Long-range correlations in nucleotide sequences. *Nature*, v. 356 , n.6365, p. 168–170, 1992. [3.2.1](#), [3.2.2](#)
- _____. On the mosaic organization of dna sequences. *Physicala Review E*, v. 49, p. 1685–1689, 1994. [3.2.1](#)
- _____. Scaling and univarsality in heart rate variability distribution. *Physica A*, v. 249, p. 241, 1998. [3.2.1](#)

- PENG, C. K. et al. Statistical properties of dna sequences. *Physica A*, v. 221, p. 180, 1995. 3.2.1
- PFURTSCHHELLER, Gert; SILVA, FH Lopes Da. Event-related eeg/meg synchronization and desynchronization: basic principles. *Clinical neurophysiology*, Elsevier, v. 110, n. 11, p. 1842–1857, 1999. 2.3
- PIERCE, David A. Seasonal adjustment when both deterministic and stochastic seasonality are present. In: *Seasonal analysis of economic time series*. [S.l.]: NBER, 1979. p. 242–280. 3.1.1
- PODOBNIK, Boris; STANLEY, H Eugene. Detrended cross-correlation analysis: a new method for analyzing two nonstationary time series. *Physical review letters*, APS, v. 100, n. 8, p. 084102, 2008. 3.2.3
- POLONNIKOV, RI; WASSERMAN, EL; KARTASHEV, NK. Regular developmental changes in eeg multifractal characteristics. *International journal of neuroscience*, Taylor & Francis, v. 113, n. 11, p. 1615–1639, 2003. 1
- RAMOS, David José Gonçalves Tierro. A imagem do cinema na construção dos conceitos científicos. *Belo Horizonte–CEFEGMG*, 2008. 2.4
- RUNDLE, John B et al. The statistical mechanics of earthquakes. *Tectonophysics*, Elsevier, v. 277, n. 1-3, p. 147–164, 1997. 3.1.9, 3.1.9
- SATO, João R et al. Analyzing the connectivity between regions of interest: an approach based on cluster granger causality for fmri data analysis. *Neuroimage*, Elsevier, v. 52, n. 4, p. 1444–1455, 2010. 1.3
- SCHENCK, John F. The role of magnetic susceptibility in magnetic resonance imaging: Mri magnetic compatibility of the first and second kinds. *Medical Physics*, v. 23, n. 6, p. 815–850, 1996. 2.5
- SCHLOGL, Alois; NEUPER, Christa; PFURTSCHHELLER, Gert. Estimating the mutual information of an eeg-based brain-computer interface. *Biomedizinische Technik/Biomedical Engineering*, Walter de Gruyter, Berlin/New York, v. 47, n. 1-2, p. 3–8, 2002. 2.5
- SCHMITZ, Bernd L et al. Advantages and pitfalls in 3t mr brain imaging: a pictorial review. *American journal of neuroradiology*, Am Soc Neuroradiology, v. 26, n. 9, p. 2229–2237, 2005. 1.3, 2.3
- SCHULTZ, Teal L. Technical tips: Mri compatible eeg electrodes: Advantages, disadvantages, and financial feasibility in a clinical setting. *Neurodiagnostic Journal*, v. 52, n. 1, p. 69–81, 2012. 2.5
- SEDGEWICK, Robert. *Algorithms in C*. [S.l.]: Princeton University, 1995. Cap.41 - The Fast Fourier Transform p.583. 1
- SERENO, SC; RAYNER, K; POSNER, MI. Establishing a time-line of word recognition: Evidence from eye movements and event-related potentials. *NeuroReport*, v. 9, n. 10, p. 2195–2200, 1998. 2.5
- SILVA, Marcus Fernandes da et al. Quantifying cross-correlation between ibovespa and brazilian blue-chips: The deca approach. *Physica A: Statistical Mechanics and its Applications*, v. 424, p. 124–129, 2015. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378437115000047>>. 3.1.9, 3.2.4

- SOUZA, Reinaldo Castro. Modelos estruturais para previsão de séries temporais: Abordagens clássica e bayesiana. 17 colóquio brasileiro de matemática. *Rio de Janeiro*, 1989. [3.1](#)
- SOUZA, Reinaldo Castro; CAMARGO, Maria E. Análise e previsão de séries temporais: os modelos arima. *IjuÁη: Sedigraf*, 2004. [3.1.4](#)
- SRINIVASAN, Ramesh. Methods to improve the spatial resolution of eeg. *International Journal*, v. 1, n. 1, p. 102–111, 1999. [2.5](#)
- STIGLER, Stephen M. Gauss and the invention of least squares. *The Annals of Statistics*, JSTOR, p. 465–474, 1981. [3.1.7](#)
- STILLINGS, Neil A; CHASE, Christopher H; FEINSTEIN, Mark H. *Cognitive science: An introduction*. [S.l.]: MIT press, 1995. [2.4](#)
- TALKNER P.; WEBER, R.O. Power spectrum and detrended fluctuation analysis: Application to daily temperatures. *Phys. Rev. E*, v. 62, p. 150–160, 2000. [3.2.1](#)
- TATUM, William O. Ellen r. grass lecture: Extraordinary eeg. *The Neurodiagnostic Journal*, Taylor & Francis, v. 54, n. 1, p. 3–21, 2014. [2.3](#), [2.3](#)
- _____. *Handbook of EEG interpretation*. [S.l.]: Demos Medical Publishing, 2014. ISBN 9781617051807. [2.1](#)
- TEPLAN, M. Fundamentals of eeg measurement. *Measurement Science Review*, 2002. ISSN 15353893. [1](#)
- VASSOLER, G.F. Zebendea. R.T. Dcca cross-correlation coefficient apply in time series of air temperature and air relative humidity. *Physica A*, v. 391, p. 2438–2443, 2012. [3.2.1](#)
- VECCHIET, Leonardo *et al.* Sensory characterization of somatic parietal tissues in humans with chronic fatigue syndrome. *Neuroscience letters*, Elsevier, v. 208, n. 2, p. 117–120, 1996. [3.1.9](#)
- VESPA, Paul M; NENOV, Val; NUWER, Marc R. Continuous eeg monitoring in the intensive care unit: Early findings and clinical efficacy. *Journal of Clinical Neurophysiology*, v. 16, n. 1, p. 1–13, 1999. [2.5](#)
- VLADIMIR, Matic *et al.* Objective differentiation of neonatal eeg background grades using detrended fluctuation analysis. *Front Hum Neurosci*, v. 9, n. 189, 2015. [1](#)
- WIENS, Elmer G. Egwald mathematics: References and links linear algebra, geometry, optimal control theory, operations research, statistics and econometrics, nonlinear dynamics. *Nova York: Schaum McGraw-Hill*, 1995. [3.1.7](#)
- WILSON, Margaret. The re-tooled mind: how culture re-engineers cognition. *Social cognitive and affective neuroscience*, Oxford University Press, v. 5, n. 2-3, p. 180–187, 2010. [1.3](#)
- YANG, H *et al.* Neural and cortical analysis of swallowing and detection of motor imagery of swallow for dysphagia rehabilitation—A review. In: *Progress in brain research*. [S.l.]: Elsevier, 2016. v. 228, p. 185–219. [2.4](#)
- ZEBENDE, G.F.; SILVA, M.F. da; FILHO, A. Machado. Diferenciação do coeficiente de correlação cruzada dcca: Abordagens teorias e práticas. *Physica A: Mecânica Estatística e suas Aplicações*, v. 392, n. 8, p. 1756–1761, 2013. [3.1.9](#), [3.2.3](#)

ZEBENDE, G. F. Dcca cross-correlation coecient: Quantifying level of cross-correlation. *Physica A: Statistical Mechanics and its Applications*, v. 390, n. 4, p. 614–618, 2011. [2.2](#), [3.2.4](#)

ZEBENDE, G. F; FERNANDEZ, B. F; PEREIRA, M. G. Analysis of the variability in the sdb star kic 10670103: Dfa approach. *ROYAL ASTRONOMICAL SOCIETY*, v. 464, p. 2638–2642, 2016. [3.2.1](#), [3.2.1](#)

ZEBENDE, Gilney Figueira; FM, Oliveira Filho; JA, Leyva Cruz. Auto-correlation in the motor/imaginary human eeg signals: A vision about the fdfa fluctuations. *PLoS ONE*, v. 12, n. 9, p. e0183121, 2017. Disponível em: <<http://journals.plos.org/plosone/article?id=10.1371/journal.pone.0183121#pone-0183121-t003>>. (document), [3.1.7](#), [3.2.1](#), [3.2.1](#), [3.2.2](#), [3.10](#), [3.2.2](#), [5](#)

ZEBENDE G.F; MACHADO FILHO, A. *Detrended Cross-Correlation Analysis: Measuring cross - correlation between mathematical constantes*. [S.l.], 2009. [3.2.1](#)

ZHENHU, Liang *et al.* Eeg entropy measuresin anesthesia. *Front Comput Neurosci*, v. 9, n. 16, 2015. [1](#)

ZORICK, Todd; MANDELKERN, Mark A. Multifractal detrended fluctuation analysis of human eeg: preliminary investigation and comparison with the wavelet transform modulus maxima technique. *PloS one*, Public Library of Science, v. 8, n. 7, p. e68360, 2013. [1](#)

Amplitude da flutuação e correlação cruzada em sinais eletroencefalográficos: uma modelagem com a função de flutuação rms e o coeficiente de correlação cruzada ρ_{DCCA}

Florêncio Mendes Oliveira Filho

Salvador, Abril de 2019.