

Eva Luana Almeida da Silva
Orientadora: Juliana Oliveira de Carvalho

**Uma visão de soluções na literatura para o
processamento de eletroencefalograma usando
*Detrended Fluctuation Analysis***

Picos - PI
24 de agosto de 2023

Eva Luana Almeida da Silva
Orientadora: Juliana Oliveira de Carvalho

**Uma visão de soluções na literatura para o
processamento de eletroencefalograma usando
*Detrended Fluctuation Analysis***

Trabalho de conclusão do curso submetido
para Universidade Federal do Piauí para con-
clusão do curso de Bacharel em Sistemas de
Informação

Universidade Federal do Piauí
Campus Senador Helvídio Nunes de Barros
Bacharelado em Sistemas de Informação

Picos - PI
24 de agosto de 2023

FICHA CATALOGRÁFICA
Serviço de Processamento Técnico da Universidade Federal do Piauí
Biblioteca José Albano de Macêdo

S586v Silva, Eva Luana Almeida da
Uma visão de soluções na literatura para o processamento de eletroencefalograma usando *Detrended Fluctuation Analysis* [recurso eletrônico] / Eva Luana Almeida da Silva - 2023.
46 f.

1 Arquivo em PDF
Indexado no catálogo *online* da biblioteca José Albano de Macêdo-CSHNB
Aberto a pesquisadores, com restrições da Biblioteca

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do Piauí, Bacharelado em Sistemas de Informação, Picos, 2023.
“Orientadora : Profa. Dra. Juliana Oliveira de Carvalho ”

1. Software - aplicação. 2. Eletroencefalograma (EEG). 3. Algoritmo. 4. Análise de Função Destendenciada (DFA). I. Carvalho, Juliana Oliveira de. II. Título.

CDD 005.3

UMA VISÃO GERAL DO USO DE DFA EM EEG

EVA LUANA ALMEIDA DA SILVA

Monografia Aprovada como exigência parcial para obtenção do grau de Bacharel em Sistemas de Informação.

Data de Aprovação

Picos - PI, 14 de agosto de 2023

Juliana O. de Carvalho
Prof. Juliana Oliveira de Carvalho

Rayner Gomes Sousa
Prof. Rayner Gomes Sousa

Francisca Pâmela Carvalho Nunes
Prof. Francisca Pâmela Carvalho Nunes

Agradecimentos

Primeiramente agradeço a Deus, por me acompanhar e me guiar em cada uma de minhas conquistas. Aos meus avós, pelo amor, zelo e coragem em assumir papéis que ultrapassaram de longe suas obrigações. À minha mãe, por ter dado muito mais do que ela sonhou em ter.

Agradeço à minha irmã Kelly, por desejar e pedir à Deus por tudo de melhor na minha vida dia após dia. Ao meu padrinho por ser inspiração, fortaleza e refúgio. Aos meus amigos que sempre entenderam minha ausência, e a outros que até hoje não a aceitam e me amam mesmo assim: Regina, Waldir, Gi, Cleyton, Fatinha, Bruno, Milena, David, amigos por assim dizer, mas não são menos que irmãos do coração, para esta e muitas outras vidas. Grata à Deus por tê-los!

Agradeço à professora Juliana, uma mulher formidável, agradeço por sua cumplicidade, solidariedade e exemplo a ser seguido. Sempre me deu seu apoio, confiou e acreditou em mim. À minha família do PAAD, em especial Wendel, Humberto, Vitor, e Emanuel, esse quarteto é incrivelmente perfeito junto e amo imensamente cada um.

Por fim, gostaria de agradecer ao meu marido, Ardilles, e ao nosso filho Heitor, por serem meu lar e sem dúvida meu maior incentivo para que eu siga em frente apesar de cada dificuldade.

Amo todos vocês!

Sêneca

Quando se navega sem destino, nenhum vento é favorável.

Resumo

O Eletroencefalograma (EEG) desempenha um papel crucial na medicina ao registrar a Atividade Elétrica Cerebral (AEC) em tempo real, possibilitando diagnósticos precisos e tratamentos eficazes para diferentes doenças neurológicas e psiquiátricas de maneira não invasiva. Com o intuito de obter resultados mais confiáveis, pesquisadores de diferentes áreas estão explorando métodos matemáticos e computacionais aplicados ao EEG, como exemplo a Análise de Flutuação Destendenciada (DFA). A DFA avalia o grau de aleatoriedade dentro de uma série temporal e atribui o parâmetro alfa para a caracterização do comportamento de diferentes tipos de séries, incluindo o EEG, e a perda de seu padrão comportamental pode estar relacionado à distúrbios que comprometem a saúde do indivíduo. Nesta pesquisa é realizado um levantamento sobre o estado da arte para a melhor compreensão das ferramentas para processamento e características de sinais de EEG quando utilizado a DFA. Para isto, procurou-se identificar as soluções computacionais utilizadas para processar, analisar e extrair características do EEG, além de identificar a existência de propostas de solução para o processamento de sinal de EEG, bem como de avaliação de solução para a aplicação da DFA em EEG. De acordo com os dados obtidos, existem algumas ferramentas utilizadas mas poucos trabalhos que propõem avaliá-las, bem como que propõem novas ferramentas. E, por fim, uma das principais lacunas em aberto é a falta de avaliação de ferramentas já existentes para fornecer tanto subsídio para melhoria das mesmas, quanto para o desenvolvimento de novas ferramentas, com o objetivo de fornecer aos pesquisadores suporte para a seleção das melhores soluções de aplicação da DFA em EEG, as quais devem possuir boa usabilidade e atender todas as funcionalidades, e assim, contribuir para o avanço no uso de DFA em EEG.

Palavras-chaves: EEG. DFA. Solução. Sistema. algoritmo. Aplicação.

Abstract

The Electroencephalogram (EEG) plays a crucial role in medicine by recording real-time Brain Electrical Activity (BEA), enabling accurate diagnoses and effective non-invasive treatments for various neurological and psychiatric disorders. In pursuit of more reliable outcomes, researchers from different fields are exploring mathematical and computational methods applied to EEG, as exemplified by Detrended Fluctuation Analysis (DFA). DFA evaluates the degree of randomness within a time series and assigns the parameter alpha to characterize the behavior of different types of series, including EEG, and the loss of its behavioral pattern may be related to disorders that compromise an individual's health. This study conducts a comprehensive survey of the state of the art to enhance understanding of tools for processing and features of EEG signals when employing DFA. To achieve this, computational solutions used to process, analyze, and extract EEG characteristics were identified, as well as the existence of proposed solutions for EEG signal processing and evaluations of the DFA's application in EEG. According to the obtained data, while several tools are used, few studies propose to evaluate them or suggest new tools. And, ultimately, a significant gap lies in the lack of evaluation of existing tools to provide both support for their improvement and the development of new tools. The objective is to offer researchers guidance in selecting the best DFA application solutions for EEG, which should possess good usability and encompass all functionalities, thereby contributing to the advancement of DFA's use in EEG.

Keywords: EEG. DFA. Solution. Software. algorithm. Application.

Lista de ilustrações

Figura 1 – Eletroencefalograma (EEG).	12
Figura 2 – Ilustração da DFA e exemplos de séries temporais com diferentes comportamentos. Adaptado de (RIGOLI et al., 2020)	13
Figura 3 – Fluxograma do Processo de investigação e análise sobre o uso de DFA em EEG.	19

Sumário

1	Introdução	8
1.1	Objetivos	9
1.2	Organização do Trabalho	9
2	Referencial Teórico	11
2.1	Atividade Elétrica Cerebral	11
2.1.1	Eletroencefalograma (EEG)	11
2.2	<i>Detrended Fluctuation Analysis</i> (DFA)	12
2.3	DFA para EEG	14
3	Trabalhos Relacionados	15
4	Metodologia do Trabalho	19
4.1	Questões de pesquisa	19
4.2	Levantamento de uso de DFA em EEG	20
4.3	Requisitos de aceitação e critérios de exclusão	21
5	Uso de DFA para análise de sinal em EEG	22
5.1	Descrição dos trabalhos selecionados	22
5.1.1	Propõe solução	22
5.1.2	EEG de dados experimentais humanos	22
5.1.3	EEG de dados experimentais não humanos	27
5.1.4	EEG de Base de Dados (BD)	27
6	Análise de Resultados	30
6.1	Extração de Dados	30
6.1.1	Perfil dos dados de EEG	30
6.1.2	Perfil das Soluções	31
7	Considerações Finais e Trabalhos Futuros	36
7.1	Conclusões	36
7.2	Direções para Futuras Pesquisas	36
	Referências	38

1 Introdução

O Eletroencefalograma (EEG) é uma ferramenta amplamente utilizada na área clínica e possibilita o registro da Atividade Elétrica Cerebral (AEC) em tempo real de maneira não invasiva. Através do EEG é possível determinar o diagnóstico e tratamento adequado para diferentes doenças neurológicas, psiquiátricas ou ainda doenças associadas (CORAZZA et al., 2021; GÖKSU et al., 2021; CARVALHO et al., 2022).

A manutenção da dinâmica cerebral é essencial à homeostase dos indivíduos, processo pelo qual os organismos respondem a estímulos e ajustam suas funções internas para manter um ambiente interno ótimo para a vida. Perturbações nessa dinâmica podem estar relacionadas com situações patológicas (KANDEL et al., 2014; HALL, 2021). Em geral, as análises realizadas por neurologistas na rotina clínica dependem da acurácia, experiência e confiança do médico em compreender corretamente o EEG. Por isso, os pesquisadores de diferentes áreas, entre elas a psicologia, neurologia, biologia, engenharia, ou em campos interdisciplinares relacionados ao processamento de sinal de EEG, buscam incessantemente respostas oriundas do EEG a partir de modelos matemáticos e computacionais complexos que priorizam o conceito do EEG quanto sua caoticidade e fractalidade (HU; ZHANG, 2019). Alguns exemplos de análises matemáticas aplicadas ao EEG são Entropia Amostral, Entropia Aproximada, Análise de Hurst, Lyapunov e Análise de Flutuação Destendenciada (DÍAZ; CÓRDOVA et al., 2022; GÁRATE et al., 2022b; GÁRATE et al., 2022a; CÓRDOVA et al., 2022; MA et al., 2021; AUNO et al., 2021; DAVID et al., 2020). A *Detrended Fluctuation Analysis* (DFA) ou, em livre tradução para o português, Análise de Flutuação Destendenciada é um exemplo de análise complexa utilizada para identificar memória, autossimilaridade e correlação de longo alcance em diferentes sistemas, seja na dinâmica do mercado de ações, dos valores de criptomoedas, da temperatura de um determinado território, do EEG, entre outros (CHENG; LIU; ZHU, 2019; MENSI; HAMDI; YOON, 2018; SILVA; SILVA; STOSIC, 2020).

No Brasil, em uma pesquisa realizada com médicos em programas de residência em neurologia, foram analisadas tanto a metodologia educacional para a compreensão do EEG, quanto a confiança dos médicos em interpretá-lo corretamente. Segundo o estudo, aproximadamente 45% dos médicos se julgaram incapazes de ler um EEG mesmo contando com supervisão, esse percentual aumenta para 70% quando se trata da confiança em estabelecer laudo sem auxílio de supervisão (LOURENÇO et al., 2021). Pelo fato dos resultados a serem obtidos a partir do EEG dependerem principalmente do nível de acurácia de quem o analisa, pesquisadores de diferentes áreas tentam estabelecer métricas para investigação de perturbações no EEG que não dependem unicamente do fator humano. Métodos matemáticos diversos vêm sendo implementados em soluções computacionais com a finalidade de auxiliar os pesquisadores no processamento de EEG, em especial a DFA, que busca

compreender se o sinal pode apresentar perda de correlação de longo alcance e se essa perda caracteriza um estado alterado, de doença, ou comum ao EEG (PAVLOV et al., 2020; SMITH et al., 2021; PÖLD et al., 2021).

A utilização de um sistema deve possibilitar uma interação plena ao usuário, de tal maneira, que ele utilize ao máximo o apoio computacional disponibilizado pelo sistema (BARBOSA; SILVA, 2010). Entretanto, muitas das soluções utilizadas para a aplicação da DFA no EEG podem implicar em dificuldade de usabilidade para os pesquisadores que em sua maioria são especializados na área da saúde.

Para que um cientista possa estudar o EEG é preciso que ele faça o processamento deste sinal, contudo, é provável que haja dificuldade, em especial àqueles da área da saúde. Ao que tange à usabilidade das soluções utilizadas, sabe-se que os fatores que contribuem para a qualidade do uso de determinados sistema pelo usuário são e devem ser analisados e pensados de modo a mitigar a probabilidade de erros e a tornar seu uso fluido e intuitivo (BARBOSA; SILVA, 2010; BARBOSA et al., 2021).

1.1 Objetivos

O objetivo geral deste trabalho é levantar o estado da arte sobre as soluções utilizadas para o processamento de DFA em EEG. Os objetivos específicos desta pesquisa são:

1. Identificar as principais condições nas quais a DFA tem sido empregada para a análise de EEG.
2. Identificar quais características de sinais de eeg são importantes para análise e processamento de sinais em EEG usando DFA.
3. Contribuir com pesquisadores sobre o uso de *datasets*, apresentando direções futuras.
4. contribuir com arquitetos de *software* sobre questões em aberto em relação a sistemas para análise e processamento de sinal em EEG usando DFA.

1.2 Organização do Trabalho

Este trabalho está organizado em sete capítulos que se apresentam da seguinte forma:

- O Capítulo 2 se refere ao referencial teórico e contempla conceitos fundamentais relacionados ao uso de DFA em EEG;
- O Capítulo 3 se refere aos trabalhos relacionados apresentando artigos de revisão com objetivos semelhantes ao proposto neste trabalho;
- O Capítulo 4 se refere à metodologia empregada neste trabalho;

- O Capítulo 5 se refere à descrição dos artigos selecionados para análise;
- O Capítulo 6 se refere à extração de informação sobre a forma que os artigos selecionados se apresentam para análise;
- O Capítulo 7 se refere à conclusão e trabalhos futuros.

2 Referencial Teórico

Esta seção descreve conceitos e aplicações gerais sobre a atividade elétrica cerebral, a aquisição de EEG e o seu processamento através da DFA.

2.1 Atividade Elétrica Cerebral

O cérebro desempenha um papel fundamental no Sistema Nervoso Central (SNC), sendo responsável por receber, processar e reagir adequadamente aos estímulos originados tanto internamente como externamente nos organismos vivos. O córtex cerebral desempenha a função de receber, interpretar e unir as informações provenientes de todas as vias sensitivas do corpo. Essa integração é essencial para viabilizar a interação entre as diversas partes do corpo, garantindo assim a manutenção da homeostase corporal (HALL, 2021).

O pensamento, o raciocínio e a linguagem são funções cognitivas e de processamento avançado de informações que têm lugar no córtex cerebral. Para executar essas e outras funções, há células especializadas que facilitam a transmissão de impulsos elétricos, os quais culminam na AEC do indivíduo, como no caso dos neurônios que realizam as sinapses (KANDEL et al., 2014; HALL, 2021).

O cérebro é composto por milhões de neurônios, a soma da atividade unitária de cada neurônio pode ser observada sobre o couro cabeludo através do Eletroencefalograma (EEG) (HERCULANO-HOUZEL, 2009; HALL, 2021).

2.1.1 Eletroencefalograma (EEG)

O EEG registra os impulsos elétricos resultantes das sinapses e funciona como o resultado da soma de atividades de neurônios disparando sincronicamente, capturada em uma região próxima ao eletrodo. (HALL, 2021; KANDEL et al., 2014). Ele é efetuado por meio de um dispositivo especializado, o eletroencefalógrafo, que registra a atividade elétrica do cérebro. Eletrodos são colocados no couro cabeludo do paciente e ligados a um amplificador de corrente elétrica que amplifica o sinal cerebral muitas vezes. O amplificador se conecta a um computador, onde as oscilações da corrente elétrica são convertidas em sinais digitais, permitindo análise por médicos ou pesquisadores (SANTOS et al., 2007). A técnica para obtenção do EEG consiste no posicionamento de eletrodos no couro cabeludo, e o aparelho registra a atividade elétrica (Figura 1), sendo esta técnica bastante simples, não invasiva e de baixo custo (ACHARYA et al., 2019).




Figura 1 – Eletroencefalograma (EEG).

2.2 *Detrended Fluctuation Analysis (DFA)*

Em tradução livre para o português, a Análise de Flutuação Destenciada, é um método proposto inicialmente por Peng e colaboradores (1994), através dela é possível quantificar correlações de longo alcance em séries temporais não estacionárias, ou seja, aquelas cujas medidas de tendência e desvios se modificam ao longo do tempo.

Essa metodologia possui uma vantagem em detrimento de outros métodos, porque evita a detecção de falsas correlações quando tais correlações são artefatos de não estacionariedade. O procedimento de remoção da tendência se torna fundamental, pois evita que qualquer ruído externo interfira no comportamento do sistema investigado (PENG et al., 1994; PENG et al., 1995; PENG et al., 2012).

A DFA avalia o grau de aleatoriedade dentro de uma série temporal. Isso é realizado por meio da análise do alfa da DFA (coeficiente angular que rege a inclinação da reta) em um gráfico duplo log da variância residual média em relação ao tamanho da janela utilizada para calcular as estimativas de variância residual, como demonstrado na Figura 2. Ainda conforme o descrito por Rigoli e colaboradores 2020, a parte inferior direita do gráfico, são apresentados exemplos de séries temporais: o ruído branco, o ruído rosa e correlação persistência respectivamente.

A partir da DFA é obtido um parâmetro simples de análise, o expoente alfa do DFA (α -DFA). E, de acordo com a literatura (AZIZ; ABBAS; ARIF, 2005; KITLAS-GOLIŃSKA, 2012) os valores de α -DFA podem apresentar as seguintes interpretações:

- Correlação anti-persistente, se $0 < \alpha < 0,5$;
- Ruído branco, se $\alpha = 0,5$;

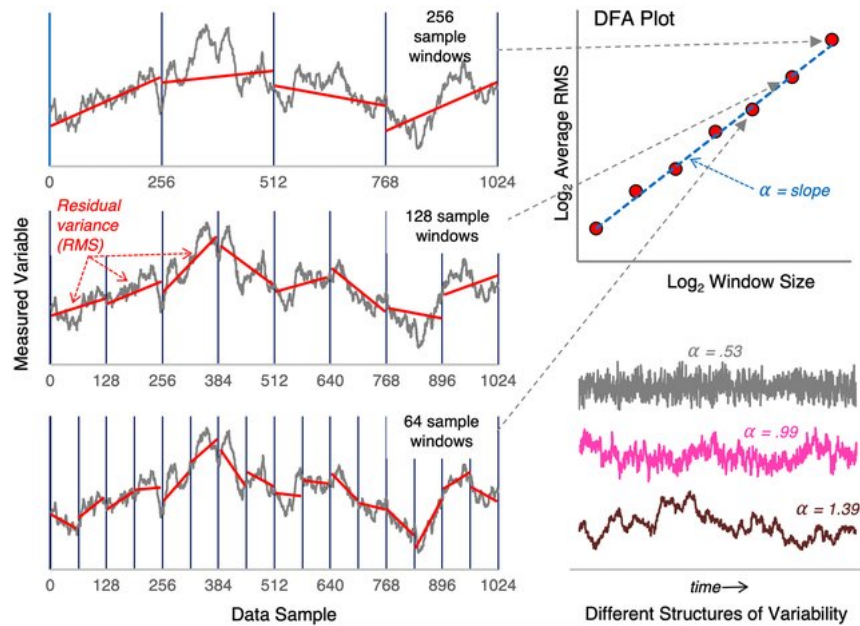


Figura 2 – Ilustração da DFA e exemplos de séries temporais com diferentes comportamentos. Adaptado de (RIGOLI et al., 2020)

- Correlação persistente, $0,5 < \alpha < 1,0$;
- Ruído rosa do tipo $1/f$, se $\alpha = 1,0$;
- Há correlação, mas não segue a lei de potência, se $\alpha > 1,0$;
- E, Ruído browniano que representa a integração do ruído branco, se $\alpha = 1,5$.

Segundo Ihlen (2012) DFA monofractal se caracteriza por avaliar um fenômeno na perspectiva de apenas um expoente de lei de potência, considerando que o fenômeno estudado não depende da escala de tempo ou de espaço (a depender do tipo de sistema analisado). No entanto, em geral surgem muitas variações de tempo e/ou espaço em estruturas biológicas e físicas por exemplo. Essas variações apontam para características multifractais do objeto estudado e podem ser representadas por um espectro multifractal de expoentes da lei de potência (IHLEN, 2012).

Para o contexto da DFA multifractal é importante definir a geometria fractal proposta por volta dos anos sessenta por Mandelbrot, na qual é considerado em quase sua totalidade, que os fenômenos da natureza ou biológicos não são passíveis de avaliação fidedigna a partir da geometria euclidiana. A geometria fractal define três propriedades para estes fenômenos: a) Dependência de escala; b) Autossimilaridade; c) Dimensão fractalizada (MANDELBROT, 1989; ROSAS; FERNANDES, 2021).

Existem inúmeras variações além da DFA mono ou multifractal, mas em resumo, a DFA busca a identificação de autossimilaridade em séries temporais não estacionárias.

2.3 DFA para EEG

A DFA tem sido aplicada em incontáveis áreas relacionadas ao EEG. A seguir são relacionadas algumas aplicações recentes da DFA em EEG:

- Auno e colaboradores (2021) sugeriram que a DFA no EEG pode auxiliar na localização da zona epileptogênica (origem de crise epilética) durante a avaliação pré-cirúrgica de pessoas com epilepsia.
- A DFA aplicada no EEG foi capaz de identificar alterações durante a vigília e durante o sono entre pessoas saudáveis e pessoas com espasmos epiléticos, indicando seu uso para aumento da eficiência no diagnóstico da epilepsia (SMITH et al., 2021).
- A Aplicação para a detecção de Transtorno de Déficit de Atenção e Hiperatividade (TDAH) da DFA no EEG de crianças saudáveis ou com TDAH apresentou a taxa de precisão de 99,17% (GHADERYAN et al., 2022).
- Pavlov e colaboradores (2018) utilizaram a DFA no EEG a partir da movimentação real e imaginária do braço para desenvolvimento de algoritmo de processamento de dados em interfaces cérebro-computador. Segundo a pesquisa, foi demonstrado que as intenções mentais podem ser transformadas em comandos de controle de interfaces cérebro-computador.
- A pesquisa sobre o estado clínico específico da doença de Alzheimer leve e comprometimento cognitivo leve através da DFA se mostra promissora para avaliação quantitativa de EEG para estimar com precisão a cognição na doença de Alzheimer (ZORICK et al., 2020).

3 Trabalhos Relacionados

Este capítulo tem como objetivo apresentar outros *surveys* e afins que apresentam um levantamento na literatura para identificar pesquisas relacionadas a características e métodos para análise de processamento de sinal em EEG.

Motamedi-Fakhr e colaboradores (2014) oferecem uma ampla visão das técnicas de processamento de sinais aplicadas à análise de EEG durante o sono. O artigo abrange diversas fases do processamento, desde pré-processamento até a classificação de características, com destaque para métodos como filtros seletivos de frequência, esquema de rejeição de canal duplo, regressão no domínio do tempo e da frequência, filtragem adaptativa e análise de componentes independentes. Entre as técnicas discutidas, a DFA é notável como uma ferramenta empregada para explorar a complexidade temporal dos sinais EEG, proporcionando uma compreensão mais rica dos padrões subjacentes e dinâmicas durante o sono.

Lotte e colaboradores (2018) apresentam uma revisão abrangente de algoritmos de classificação destinados a interface cérebro-computador (*Brain-Computer Interface* - BCI) baseadas em EEG. A investigação abrange a literatura no período de 2007 a 2017, focando na interseção entre BCIs e aprendizado de máquina. O estudo tem como objetivo identificar novas abordagens de classificação utilizadas no desenvolvimento de BCIs. Os autores compilam e sintetizam estudos relevantes, expondo os algoritmos empregados, bem como suas aplicações em BCIs. Importante ressaltar que, no decorrer da revisão, não é feita qualquer menção ao uso da DFA em nenhuma etapa do processamento.

Por fim, o estudo de Aguiar Neto e Rosa (2019) oferece uma visão sistemática e abrangente da utilização do EEG não invasivo na detecção de biomarcadores associados à depressão. Para alcançar esse objetivo, os autores analisaram mais de 250 artigos detalhando as descobertas e destacando os biomarcadores promissores provenientes de 42 estudos selecionados. Como conclusão, entende-se que o cérebro de pessoas com depressão exibe uma estrutura de rede mais aleatória.

Dentre as características que se mostraram promissoras para o diagnóstico, destaca-se a análise de banda gama e complexidade do sinal, que têm o potencial de identificar sintomas específicos da depressão, inclusive a ideação suicida. Além disso, o estudo dedica uma ampla revisão à abordagem do uso de DFA que inclusive apresenta diminuição significativa em indivíduos deprimidos (NETO; ROSA, 2019).

Apesar de não haver explanação sobre uso da DFA, no artigo de Abiri e colaboradores (2019) são analisados os paradigmas da BCI baseados em EEG, com uma avaliação abrangente de suas vantagens e desvantagens. O público-alvo do artigo são pesquisadores e profissionais na área de neuroreabilitação e tecnologia assistiva. É enfatizada a importância de selecionar a aplicação de BCI mais apropriada para um controle preciso de

dispositivos neuroprotéticos ou de neuroreabilitação.

Além disso, é ressaltado que a adoção correta desses paradigmas pode ter um impacto significativo na eficácia dos dispositivos, especialmente ao auxiliar pessoas com deficiência física e pacientes com lesões cerebrais. Isso desperta um interesse considerável devido às tecnologias disponíveis, como gravação sem fio, amplificadores de baixo custo, maior resolução temporal e métodos avançados de análise de sinal. Portanto, o estudo dos paradigmas de BCI não apenas contribui para a evolução tecnológica, mas também tem um potencial impacto positivo na qualidade de vida dos indivíduos com necessidades especiais (ABIRI et al., 2019).

Yu e Wang (2022) discutem os métodos usados para reconhecimento de emoções com base em sinais de EEG, entre eles a utilização de DFA. Os métodos discutidos estão relacionados à indução de emoções, pré-processamento de EEG, à extração de recursos e à classificação de emoções. O reconhecimento de emoções foi baseado em sinais de EEG em geral e tal reconhecimento é uma tecnologia crítica em inteligência artificial, interação humano-computador e outros campos, pois a emoção afeta todos os aspectos da vida humana.

O estudo de Khosla e colaboradores (2022) oferece uma visão abrangente dos biomarcadores derivados de EEG utilizados em pesquisas sobre a depressão. Eles exploram e comparam tanto algoritmos tradicionais baseados em aprendizado de máquina quanto arquiteturas mais avançadas baseadas em aprendizado profundo no contexto do diagnóstico da depressão. O propósito fundamental da pesquisa é enriquecer a compreensão e a abordagem terapêutica dessa doença mental, enquanto também identificam aplicações abrangentes do processamento de EEG assistido por computador.

A pesquisa visou não apenas melhorar o diagnóstico de diferentes distúrbios, incluindo a depressão, mas também examinar outras possíveis aplicações, como o reconhecimento de emoções e a autenticação de identidade, por meio da análise de sinais EEG. Vale mencionar que a DFA é destacada como uma das metodologias de destaque nesse campo, demonstrando resultados superiores em comparação com abordagens lineares na classificação de pacientes diagnosticados com depressão ((KHOSLA; KHANDNOR; CHAND, 2022)).

O estudo de Romero e colaboradores 2022 oferece uma revisão abrangente da literatura que explora potenciais biomarcadores derivados de EEG no contexto do diagnóstico e tratamento de espasmos infantis. Os autores realizam uma categorização sistemática dos biomarcadores, destacando suas aplicações específicas, que abrangem diagnóstico, avaliação da resposta ao tratamento e previsão. A revisão contempla tanto biomarcadores visuais de EEG quanto biomarcadores computacionais de EEG.

Ainda de acordo com a pesquisa, no que se refere aos biomarcadores visuais, são consideradas características como descargas epileptiformes e oscilações rápidas, que desempenham um papel crucial na identificação e avaliação dos espasmos infantis. Por outro

lado, a análise também engloba biomarcadores computacionais que se baseiam em medidas quantitativas extraídas dos sinais EEG. Essas medições incluem a amplitude do EEG, o espectro de potência, a entropia e correlações de longo alcance, como a DFA (MILÀ et al., 2022).

O estudo de McCallan e colaboradores ((MCCALLAN et al., 2023)) aborda a temática da classificação de crises epiléticas utilizando sinais de EEG e explora diversas abordagens para otimizar esse processo. Uma das principais linhas de investigação envolve o uso de modelos de aprendizado profundo, como as redes neurais convolucionais (CNNs) e as redes de memória de longo prazo (LSTM). Esses modelos são aplicados visando aprimorar a precisão na classificação das crises, proporcionando resultados mais confiáveis.

Com a finalidade de contribuir para o diagnóstico e o tratamento de condições médicas relacionadas a crises epiléticas, a pesquisa de McCallan e colaboradores (2023) também aborda a DFA em suas análises e busca, aprimorar a identificação e categorização de crises por meio da análise de sinais EEG, adotando abordagens variadas que vão desde a utilização de modelos de aprendizado profundo até técnicas de extração de características e algoritmos de classificação.

Na Tabela 1, na primeira coluna, são apresentados os *surveys* encontrados na literatura que analisam processamento de sinais de EEG e então são verificadas quais características foram observadas, assim, na segunda coluna, é verificado se os trabalhos observam se o método utilizado para o processamento de sinal é DFA; na terceira coluna, se os *surveys* analisam se os trabalhos selecionados por eles propõem uma solução para aplicação da DFA no EEG; na coluna quatro, é verificado se os trabalhos relacionados verificam se os trabalhos avaliam uma solução para aplicação da DFA no EEG; na quinta coluna, é verificado se os *surveys* analisam artigos que usam uma solução para aplicação da DFA no EEG; na sexta e sétima coluna, são observados se eles analisam artigos que identificam a quantidade de canais e de eletrodos utilizados para a aquisição do EEG respectivamente; além disso, na oitava coluna, é identificado se os trabalhos relacionados avaliam se trabalhos tratam de EEG sob uma condição específica ou saudáveis; por fim, na última coluna, se o EEG é de origem humana ou não.

Neste Capítulo 3, os estudos examinados oferecem uma visão abrangente sobre a importância intrínseca da extração de informações a partir dos sinais de EEG. Além disso, esses estudos também destacam as diversas opções de análise disponíveis para o EEG. Essas metodologias emergentes têm o potencial de evoluir como marcadores biológicos robustos, desempenhando um papel crucial no âmbito do diagnóstico, tratamento e/ou monitoramento clínico em uma ampla variedade de contextos que abrangem as experiências individuais.

Contudo, até o presente momento e apesar de esforços intensivos de busca, não foram encontrados materiais que abordem a aplicação da DFA em EEG, sobretudo na perspectiva da computação. Essa lacuna se estende tanto na direção dos desenvolvedores de

Tabela 1 – Comparativo entre trabalhos relacionados.

I	II	III	IV	V	VI	VII	VIII	IX
<i>Motamedi-Fakhr et al. (2014)</i>	Sim	Não	Não	Não	Não*	Não	Não**	Não
<i>Lotte et al. (2018)</i>	Não	Não	Não	Não	Não	Não	Não	Não
<i>Neto e Rosa (2019)</i>	Sim	Não	Não	Não	Não	Não	Não**	Não
<i>Abiri et al. (2019)</i>	Não	Não	Não	Não	Sim	Sim	Não**	Não
<i>Yu e Wang (2022)</i>	Sim	Não	Não	Sim	Não	Não	Não**	Não
<i>Khosla, Khandnor e Chand (2022)</i>	Sim	Não	Não	Sim	Sim	Não	Não**	Não
<i>Milà et al. (2022)</i>	Sim	Não	Não	Não	Não	Não	Não**	Não
<i>McCallan et al. (2023)</i>	Sim	Não	Não	Não	Sim	Sim	Não**	Não
Este trabalho	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim

Legenda: **I** - referência do trabalho relacionado; **II** - identifica o uso de DFA; **III** - identifica proposta de solução para processamento de DFA em EEG; **IV** - identifica avaliação de solução para processamento de DFA em EEG; **V** - identifica o uso de solução para processamento de DFA em EEG; **VI** identifica a quantidade de canais para aquisição do EEG; **VII** identifica a quantidade de eletrodos para aquisição do EEG; **VIII** identifica se o EEG está sob uma condição específica ou não; E por fim, **IX** identifica se o EEG é humano ou não. (*) O trabalho filtra artigos que utilizam entre 4-8 canais para a aquisição do EEG e (**) O trabalho filtra artigos cujo EEG apresenta uma condição específica.

software, que podem priorizar a usabilidade, quanto dos engenheiros de software, que podem focar no desempenho das soluções. A ausência de material relevante também abrange informações sobre as principais soluções utilizadas por pesquisadores, especialmente na área da saúde, e suas respectivas licenças, bem como suas vantagens e desvantagens.

4 Metodologia do Trabalho

Neste capítulo é apresentado o processo de identificação e análise de trabalhos na literatura sobre o uso de DFA em EEG na perspectiva de um arquiteto de *software*. O processo em questão consistiu nas seguintes etapas: definição das questões de pesquisa respondidas em relação as soluções para o uso de DFA em EEG; seleção e trabalhos que usam a DFA para EEG; extração de dados de acordo com critérios de avaliação; por fim, análise e interpretação dos dados. A Figura 3 apresenta um fluxograma que representa em etapas o processo descrito.

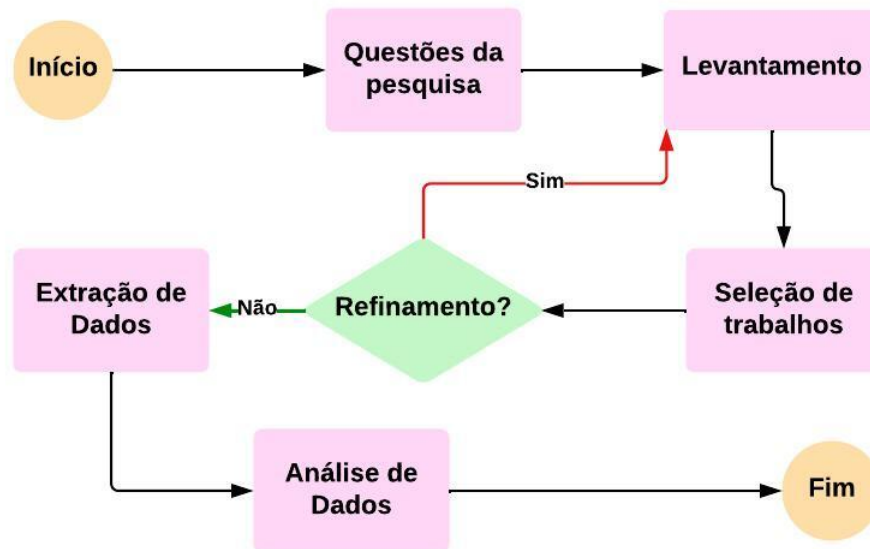


Figura 3 – Fluxograma do Processo de investigação e análise sobre o uso de DFA em EEG.

4.1 Questões de pesquisa

Esta seção trata da definição das questões de pesquisa investigadas. Neste trabalho, a questão de pesquisa principal é:

Questão Principal: Identificar como os pesquisadores realizam a análise do processamento de sinal em EEG usando DFA?

Para responder à questão de pesquisa principal, foram elaboradas algumas questões secundárias voltadas para a extração de informações. Essas questões têm como base a maneira como a DFA contribui para o processamento e aquisição de informações a partir do sinal de EEG. As questões secundárias, juntamente com suas motivações, são apresentadas a seguir:

Questão 01: O sinal de EEG é genérico ou apresenta características específicas?

Essa pergunta permite descobrir se o EEG é tratado de forma geral ou para uma condição específica.

Questão 02: Utiliza dados experimentais? Essa pergunta permite descobrir se o EEG

é oriundo de uma cobaia e não de pessoas.

Questão 03: Utiliza base de dados? Essa pergunta permite descobrir se há o uso de

base de dados de EEG.

Questão 04: Propõe uma solução para uso de DFA em EEG? Essa pergunta per-

mite descobrir se há a proposta de uma solução (ferramenta, aplicação, sistema) para o processamento de EEG.

Questão 05: Avalia uma solução para uso de DFA em EEG? Essa pergunta per-

mite descobrir se há a avaliação de uma solução (ferramenta, aplicação, sistema) para o processamento de EEG.

Questão 06: A solução possui licença ou é de código aberto? Essa pergunta per-

mite identificar se a solução (ferramenta, aplicação, sistema) usada para o processamento de EEG é gratuita ou não.

4.2 Levantamento de uso de DFA em EEG

Esta etapa trata do levantamento na literatura sobre o uso da DFA no processamento de EEG. Para isto, as buscas foram realizadas nas bases *Association for Computing Machinery*¹, *ScienceDirect*², *IEEE Xplore*³, *SpringerLink*⁴, *Web of Science*⁵, *Scopus*⁶, *PubMed*⁷ e *Google Academic*⁸. As *strings* de busca utilizadas são apresentadas na Tabela 2 e datam do período de publicação entre 2019 e 2023.

Tabela 2 – *Strings* de busca para soluções de uso da DFA em EEG.

ID	String de busca
1	“EEG” AND “DFA” AND “application”
2	“EEG” AND “DFA” AND “software”
3	“EEG” AND “DFA” AND “toolbox”

¹ <https://www.acm.org/>

² <https://www.sciencedirect.com/>

³ <https://ieeexplore.ieee.org/Xplore/home.jsp>

⁴ <https://link.springer.com/>

⁵ <https://www.webofscience.com/wos/woscc/basic-search>

⁶ <https://www.scopus.com/>

⁷ <https://pubmed.ncbi.nlm.nih.gov/>

⁸ <https://scholar.google.com.br/?hl=pt>

4.3 Requisitos de aceitação e critérios de exclusão

Apenas os trabalhos que se enquadram com os requisitos de aceitação e não apresentam nenhum dos critérios para exclusão foram selecionados. A seguir são apresentados os itens a serem verificados:

Linguagem do trabalho: Apenas trabalhos escritos em língua inglesa, devido à predominância dessa língua no cenário científico global. A maioria dos avanços científicos, descobertas e comunicações acadêmicas são publicados em inglês, proporcionando uma base sólida para acesso a informações relevantes.

Sinal Fisiológico: Apenas trabalhos que tratem de EEG e nenhum outro tipo de sinal da AEC, tais como Magnetoencefalografia (MEG), Ressonância Magnética Funcional (fMRI) e Tomografia por Emissão de Pósitrons (PET).

Uso de DFA em EEG: Apenas trabalhos que aplicam a DFA, seja de forma exclusiva ou inclusiva.

Quantidade de páginas: Apenas trabalhos com três páginas ou mais, pois tendem a apresentar informações mais detalhadas.

Tipo de Artigo: Trabalhos em formato de resumo simples não são aceitos, pois tendem a apresentar informações menos detalhadas.

5 Uso de DFA para análise de sinal em EEG

5.1 Descrição dos trabalhos selecionados

Esta Seção trata da descrição dos trabalhos selecionados, bem como as relações que podem ser estabelecidas entre os mesmos. Foram encontrados 137 trabalhos e após as filtragens foram selecionados 41 trabalhos, que serão apresentados nas próximas subseções.

5.1.1 Propõe solução

Segundo Castiglioni e colaboradores (2019), sua pesquisa introduz um algoritmo eficiente, capaz de identificar padrões complexos em dados biomédicos, proporcionando resultados de alta resolução. Ao revisar as fórmulas analíticas do DFA multifractal, os autores propõem um método mais rápido e estável em comparação com abordagens tradicionais. A eficácia desse algoritmo é validada através de testes em séries sintéticas, evidenciando sua estabilidade numérica e eficiência computacional notável, economizando cerca de 99% do tempo em comparação com métodos convencionais.

A aplicação prática em sinais fisiológicos extensos, como registros de frequência cardíaca e traços de EEG de estudos do sono, destaca a capacidade do algoritmo em capturar propriedades multifractais/multiescalas com precisão. Esse foi o único trabalho encontrado que propõe uma solução para o uso de DFA em EEG, e disponibiliza o código-fonte do Matlab para o algoritmo que usa DFA em séries temporais fisiológicas, o código para calcular as equações e o código para avaliar a estabilidade numérica e a velocidade do algoritmo.

Ao considerar o desempenho de tempo do algoritmo, é importante notar que ele emprega apenas polinômios de primeira e segunda ordem, e, caso uma ordem maior seja necessária, a velocidade do algoritmo pode ser afetada negativamente (CASTIGLIONI; FAINI, 2019).

5.1.2 EEG de dados experimentais humanos

Neste estudo, tanto o expoente quanto a interceptação da DFA são empregados como métricas computacionais para discernir entre pacientes com espasmos epiléticos e indivíduos saudáveis do grupo de controle. A coleta dos registros foi conduzida utilizando um total de 19 canais, abrangendo um grupo de 40 pacientes com espasmos epiléticos e um grupo de 20 indivíduos saudáveis, representando o grupo de controle. Todas as análises foram realizadas por meio do uso do software MATLAB (SMITH et al., 2021).

O método proposto foi aplicado aos dados de EEG humano para calcular uma estimativa variável no tempo da dependência temporal de longo alcance durante o ciclo sono-vigília de um bebê saudável e para comparar dados de EEG antes e depois do tratamento em indivíduos individuais com epilepsia pediátrica (SMITH et al., 2019).

Dado simulado foi criado para mostrar o desempenho do algoritmo DFA sob várias condições que são comuns no processamento de séries temporais neurais. Foi utilizado o MATLAB para gerar movimento browniano fracionário simulado (FbM) através da função do MATLAB “ffgn” para criar um sinal temporalmente correlacionado com um determinado expoente de Hurst. Além disso, o MATLAB foi usada para obter uma estimativa precisa do expoente do DFA, bem como seus intervalos de confiança associados em dados simulados e dados de EEG humano (SMITH et al., 2019).

O Programa R, versão 4.0.3, foi usado para aplicação de DFA em ECG de bebês correlacionados a seus respectivos EEG com o objetivo de identificar precocemente espasmos epiléticos em bebês com risco de desenvolver a síndrome do espasmo epilético infantil (GOSWAMI et al., 2022).

EEGs obtidos de pacientes com AVC e pessoas saudáveis no *Hospital Canselor Tuanku Muhriz* foram usados para analisar as emoções e sua aquisição foi realizada com 14 canais. A DFA foi extraída do sinal de EEG e o o classificador *K-Nearest Neighbor* - (KNN) foi aplicado com diferentes métricas de distância para comparação (YEAN et al., 2018).

O EEG de 22 canais foi usado para analisar a atividade cerebral durante a tarefa de leitura, dois indivíduos foram testados usando 11 eletrodos. Eles leram um texto entregue aleatoriamente, com um sujeito recebendo treinamento prévio e o outro lendo sem treinamento (FILHO; CRUZ; ZEBENDE, 2019).

O estudo de Oon e colaboradores (2018) conclui que a DFA pode ser usada para compreender a resposta do cérebro humano a estímulos de marketing no contexto do neuromarketing. O EEG de 10 indivíduos em resposta a quatro categorias de mercadorias, com cinco produtos em cada categoria foi analisada utilizando dois classificadores, Rede Neural kNN. A aquisição foi realizada com 32 eletrodos e 32 canais, e, a DFA pode ser empregadas para identificar as preferências do consumidor e aprimorar as estratégias de marketing.

A DFA foi usada para analisar o EEG de pacientes com Transtorno do Espectro do Autismo (TEA) e pessoas com Desenvolvimento Típico (DT). Os resultados mostram que os expoentes do DFA da amplitude das oscilações beta e de gama foram significativamente atenuados nos pacientes com TEA em comparação com os participantes TD (JIA; YU, 2019). Os sinais de EEG de crianças entre 3 e 7 anos com DT e crianças com TEA envolvidos em alguma atividade visualmente estimulante, foram obtidos 19 canais e a DFA constatou que certos canais tinham o menor desvio padrão e alta similaridade diferentes para crianças com DT e crianças com TEA (RADHAKRISHNAN et al., 2021). A DFA, juntamente com outros outros métodos, influencia a precisão da classificação precoce do

TEA a partir de sinais de EEG (ABDOLZADEGAN; MOATTAR; GHOSHUNI, 2020).

A MF-DFA foi usada para avaliar o EEG de crianças com TDAH, pacientes do Centro Compreensivo de Psicologia e Distúrbios Nervosos de Atieh, Teerã, Irã. 24 crianças destras entre 7 e 12 anos, incluindo 12 indivíduos com TDAH e 12 indivíduos saudáveis da mesma idade tiveram EEGs obtidos com 19 canais. O pré-processamento do sinal e a implementação da Rede Neural foram realizados no Matlab (2013a).r2013a) (KHOSHNOUD; NAZARI; SHAMSI, 2018). A MF-DFA foi utilizada para distinguir crianças com TDAH de um grupo de controle de mesma idade a partir do EEG de 21 canais processados usando funções EEGLAB (versão 13) em execução no Matlab (Matlab2013a, The Mathworks, Inc.). As características multifractais baseadas na fonte alcançaram 86,67% de precisão, superando medidas baseadas em canais (KHOSHNOUD; NAZARI; SHAMSI, 2020).

EEG de 64 canais em 57 voluntários saudáveis sem histórico de complicações neurológicas, incluindo TDAH, depressão ou abuso de substâncias, durante uma tarefa de atenção sustentada e repouso com os olhos fechados foi estudada através da DFA implementada no EEGLAB (IRRMISCHER et al., 2018).

Prabhakar e colaboradores (2019) analisa sinais alcoólicos de EEG para um único paciente e busca classificá-los usando vários pós-classificadores. Segundo os autores, apesar da DFA não apresentar um desempenho satisfatório, os resultados mostram alta precisão de classificação, com o *Gaussian Mixture Model* - GMM alcançando 97,91% de precisão, seguido pela Regressão Logística com 97,33% de precisão. A análise discriminante linear teve uma precisão menor de 89,6%.

Neste artigo, o DFA é usada como uma das nove características para a classificação dos sinais de EEG da esquizofrenia em 14 indivíduos saudáveis e 14 esquizofrênicos do *Institute of Psychiatry and Neurology*, Varsóvia, Polônia (PRABHAKAR et al., 2020).

Jia e Yu (2023) usaram a DFA Baseada em Máxima Verossimilhança (ML-DFA) para calcular o expoente DFA das flutuações da Frequência Alfa Instantânea (IAF) em 25 voluntários destras saudáveis. Os dados de EEG foram pré-processados através do software EEGLAB e os dados e/ou código MATLAB do estão disponíveis com os autores, mediante solicitação razoável. O expoente de escala (expoente DFA) das flutuações do IAF é um biomarcador de características neurofisiológicas estável com alta confiabilidade de teste-reteste na região parietal-occipital.

A DFA multifractal (MF-DFA) foi usada para analisar EEG de pacientes com lesão cerebral traumática induzida por explosão leve. E, em estado de repouso, a partir do EEG de doze pacientes com histórico dessa lesão, foi observada uma maior precisão na correlação com medidas relevantes de desempenho cognitivo em comparação com modelos analíticos espectrais (ZORICK et al., 2021).

A DFA foi usada para analisar os sinais de EEG em resposta à estimulação emocional. 64 canais foram utilizados para aquisição do EEG dos participantes. E, foi possível

observar alterações quantitativas diferentes para os estados emocionais de depressão, de relaxamento, de medo e de felicidade (CHAO et al., 2022). A DFA é útil na avaliação emocional de pacientes com Acidente Vascular Cerebral (AVC) por meio de sinais de EEG, segundo estudo com EEGs de pacientes com AVC e controle normal do *Hospital Canselor Tuanku Muhriz* - (HCTM), Kuala Lumpur (NC) (CHOONG et al., 2018). E, a DFA também pode ser usada como um critério de seleção de modo para determinar os artefatos de EEG quando aplicada após o algoritmo Decomposição em Modo Variacional (VMD) utilizando o MATLAB (KAUR et al., 2021).

Seis recursos da DFA foram usadas em EEG a fim de detectar depressão. Os EEGs foram coletados no Instituto Central de Psiquiatria (CIP) de Ranchi, Jharkhand, Índia, em 24 pacientes com depressão e 20 indivíduos normais, a partir de 128 canais. O MATLAB (2015a) junto com o EEGLAB foi usado para todo o pré-processamento e análise de dados dos sinais de EEG. O estudo concluiu que a depressão impacta a região temporal do cérebro e essa característica extraída do EEG pode ajudar na classificação para detecção e escalonamento da gravidade da depressão (MAHATO et al., 2020).

EEGs, adquiridos com 128 canais em 21 voluntários saudáveis do sexo masculino em repouso em condições de olhos abertos e fechados em 4 momentos diferentes do dia, foram estudados através da DFA e a complexidade e a persistência das correlações temporais dos ritmos cerebrais mudaram durante o dia, paralelamente às mudanças no estado de alerta e no desempenho do indivíduo (CROCE et al., 2018).

A análise de EEG de 32 canais frontais em pacientes com distúrbios de consciência (coma ou estado minimamente consciente), pacientes sob anestesia geral e participantes saudáveis em estado normal de vigília. Entre os métodos foi utilizada a DFA e algoritmo genético em SVM no MATLAB (LIANG et al., 2020).

Nakov e colaboradores (2022) desenvolveram classificadores de interface cérebro-computador (BCI) para prever com precisão o desempenho de aprendizagem de crianças com base em EEGs com 18 eletrodos e coletados durante o aprendizado de um segundo idioma. O pacote *Fathon* - DFA foi utilizado para processamento do EEG e os valores de DFA foram posteriormente carregados de arquivos de texto em Python DataFrames para análise.

A MF-DFA foi usada para detectar a fadiga do motorista causada por dirigir por um longo tempo. Os resultados demonstram que o método MF-DFA é mais eficaz na detecção da fadiga ao dirigir em comparação com vários métodos típicos de detecção de fadiga. O artigo sugere que o método proposto pode ser usado para melhorar a segurança no trânsito, detectando a fadiga do motorista em tempo real (WANG et al., 2022a).

Dados de pacientes com Distúrbios da Consciência (DC) e indivíduos saudáveis foram analisados a partir da DFA em EEGs, comparando diferentes estados de consciência. E, a perda de consciência está associada a alterações na estrutura temporal das oscilações neurais em várias escalas de tempo (WEI et al., 2023).

Distinções relacionadas à idade em EEGs durante a execução de tarefas motoras em adultos jovens e idosos através da DFA foram caracterizadas. Os resultados mostraram que a força das mudanças nas correlações de longo alcance e a taxa de aumento no expoente da escala do DFA foram mais pronunciadas em adultos idosos (PAVLOV et al., 2020). Nesse estudo os experimentos foram realizados em dois grupos de voluntários saudáveis e a DFA foi usada para quantificar as diferenças relacionadas à idade. E, a linguagem Python foi usada para o pré-processamento dos dados de EEG através do pacote MNE para Python 3.7 (ver.0.20.0).

A MF-DFA foi utilizada para estudar as propriedades dinâmicas dos sinais de EEG dos sujeitos durante a condução e analisar o efeito do modo de excitação de julgamento proposto no retardo de fadiga. E, adicionando tarefas cognitivas secundárias ao comportamento de dirigir por meio da interação humano-computador pode aliviar a velocidade de desenvolvimento da fadiga (WANG et al., 2022b).

A MF-DFA pode ser usada para extrair características dos sinais de EEG em estado de repouso e para posterior classificação da presença e localização súbitas da dor usando algoritmos de aprendizado de máquina (CAO et al., 2020).

A DFA foi utilizada para analisar EEG em pacientes com parkinson durante diferentes estados de vigília, sono com movimento ocular não rápido (NREM) e sono com movimento rápido dos olhos (REM). O objetivo era identificar biomarcadores de comprometimento cognitivo leve. Os resultados indicaram que A DFA durante o sono NREM pode ser um indicador diagnóstico de comprometimento cognitivo oriundo da doença de parkinson. Os autores usaram o software MATLAB (2018a) para analisar os sinais de EEG de participantes adormecidos (ZHANG et al., 2021).

A caixa de ferramentas statsmodels python foi utilizada para realizar análises estatísticas nos dados de EEG. Esses dados foram pré-processados usando EEGLAB, e o MATLAB (versão 2016b) foi utilizada para execução de scripts personalizados para pré-processar os dados de EEG e realizar a análise de DFA. Para então investigar a relação entre sintomas depressivos e o EEG durante o estado de repouso com os olhos fechados (DUNCAN et al., 2020).

A L-DFA, uma extensão do DFA, é usada em dados de EEG de 20 canais do couro cabeludo do dataset CHB-MIT e, foi proposto um método de predição de crises epiléticas específico para o paciente com base em EEGs usando uma combinação de espectro fractal local, energia de banda relativa e características de modularidade de sincronização. O método atinge alta precisão e supera os trabalhos de última geração no mesmo campo (TANG et al., 2020; WU,).

O modelo modelo de “oscilações críticas” - CROS foi usado para simular a atividade neuronal e comparar os resultados com dados de Magnetoencefalografia/ Eletroencefalografia (M/EEG) obtidos de humanos realizando uma tarefa de detecção de estímulo limite. A DFA foi usada para estudar as correlações temporais na atividade neuronal do

modelo CROS, e os autores comparam esses resultados com aqueles obtidos a partir de gravações M/EEG. Os resultados apoiam a hipótese de que o cérebro humano funciona perto de um ponto crítico (PORTA; COPELLI, 2019). Para tal, foram utilizados o pacote MATLAB NCC, Python para pré-processar os dados e implementar o estimador de máxima verossimilhança, o software SciPy para filtrar, enquanto o pacote powerlaw Python foi usado para a estimativa de máxima verossimilhança dos expoentes para tamanho e duração das avalanches.

5.1.3 EEG de dados experimentais não humanos

De acordo com Blokhina e colaboradores (2023), seu artigo usou o EEG de dados experimentais com ratos Wistar. Os animais foram divididos em dois grupos e submetidos a diferentes tipos de anestesia: um grupo recebeu uma combinação de zoletil/xilazina, enquanto o outro grupo foi anestesiado com isoflurano. Para analisar a atividade elétrica cerebral durante a anestesia, a DFA foi aplicada aos EEGs dos animais. Essas descobertas são de extrema relevância para o controle da profundidade anestésica em experimentos de longa duração.

No entanto, o artigo não detalhou a solução utilizada para processar as análises. Apesar disso, foi mencionado pelos autores o uso de dois eletrodos no animal. Além disso, é importante esclarecer que, após uma avaliação minuciosa do material publicado, o termo EEG usado no trabalho poderia ser melhor classificado como Eletrocorticograma (ECoG). Isso se deve ao fato de que os eletrodos foram implantados entre a dura-máter e o crânio, em vez de serem posicionados externamente no rato, como é típico em um EEG convencional (BLOKHINA et al., 2023).

Em estudo recente (2021) foi usada a DFA reduzida estendida (E-DFA) para analisar o conjunto de dados de EEG de camundongos após a privação de sono. E, essa versão modificada superou os resultados do DFA convencional para identificar mudanças nesses EEGs.

A E-DFA foi utilizada para revelar mudanças estruturais nos EEGs de ratos causadas pela ativação da função de drenagem linfática cerebral devido a um estresse induzido pelo som. O E-DFA proposto proporcionou uma separação mais forte de grupos de ratos com diferentes permeabilidades da barreira hematoencefálica em comparação com a técnica convencional de DFA (PAVLOV et al., 2020).

5.1.4 EEG de Base de Dados (BD)

Neste estudo, dois conjuntos de dados foram empregados: o conjunto de dados de Bonn e o conjunto de dados de Freiburg. O objetivo era identificar crises epiléticas em sinais de eletroencefalograma (EEG). Foram realizados registros de pacientes com epilepsia focal, tanto antes, durante quanto após as crises (MALEKZADEH et al., 2021).

Um aspecto central do artigo é a utilização das características de dimensão fractal do EEG e sua aplicação em um modelo de autocodificador convolucional, por meio da DFA. Isso resultou em uma notável precisão na detecção de crises epiléticas nos conjuntos de dados de Bonn e Freiburg. Os autores sugerem que essa abordagem tem potencial para ser implementada em plataformas de hardware presentes em centros de saúde, contribuindo assim para aprimorar a detecção de crises epiléticas e fornecer cuidados mais eficazes aos pacientes (MALEKZADEH et al., 2021).

Um novo método para classificação precisa dos tipos de crises de epilepsia, utilizando a decomposição de pacotes de ondas e DFA local (L-DFA) pode ser utilizado para caracterizar a estrutura fractal dinâmica dos sinais em cada sub-banda. Os sinais de EEG são classificados utilizando máquina vetorial de suporte. Os resultados experimentais, com base no BD do *Temple University Hospital* contendo o registro de 22 pacientes epiléticos apresentando uma ou mais crises, para o método proposto, atinge uma precisão total de classificação de 97,80% nesse BD, superando os métodos existentes baseados no mesmo BD (TANG; ZHAO; WU, 2020).

O estudo realizado por Mesquita e colaboradores (2021) aplicou a DFA aos sinais de EEG de 10 pacientes epiléticos, obtidos do banco de dados do *Children's Hospital Boston - CHB-MIT*, bem como a um subconjunto de um banco de dados contendo registros de EEG de 24 crianças com crises intratáveis. Esses registros estão publicamente disponíveis no site da PhysioNet (<https://physionet.org/content/chbmit/1.0.0/>). Os resultados destacam perfis de correlação distintos, variando conforme a região cerebral da aquisição do EEG.

De acordo com os autores, os registros foram realizados com 22 canais. O processamento dos sinais de EEG foi conduzido por meio das linguagens de programação MATLAB e R. As funções específicas empregadas neste estudo estão disponíveis no pacote R DFA, acessível pelo seguinte link: <https://cran.r-project.org/> (MESQUITA; FILHO; RODRIGUES, 2021).

Segundo Malekzadeh e colaboradores (2021), a ferramenta Matlab foi utilizada para executar etapas como o pré-processamento dos dados, a extração e seleção de recursos dos sinais de EEG. Além disso, a linguagem de programação Python foi empregada, com o auxílio das bibliotecas Scikit-Learn e Keras, para implementar diversos algoritmos de classificação, incluindo KNN, SVM e CNN-AE.

No estudo conduzido por Xiong e colaboradores (2021), é proposto que indivíduos que sofrem de Apneia Obstrutiva do Sono (AOS) apresentam microestados anômalos durante episódios de hipopneia obstrutiva, e tais microestados estão correlacionados com modificações nos marcadores de EEG associados a distúrbios do sono. O artigo examina os registros de EEG de 100 pacientes com AOS, comparando-os com um grupo controle de indivíduos saudáveis. Esses registros de EEG foram adquiridos do banco de dados ISRUC-Sleep, utilizando um total de seis canais para a aquisição. A subsequente análise desses

registros foi realizada através do uso da ferramenta EEGLAB, incorporada ao ambiente MATLAB.

A DFA é capaz de oferecer *insights* sobre a confiabilidade do engajamento cognitivo e o início de certas funções cerebrais durante a formulação de estratégias comportamentais com componentes perceptíveis de ativação. Neste contexto, foi realizado um estudo com EEG de 36 voluntários saudáveis que estavam envolvidos em uma tarefa de aritmética mental, com aplicação da técnica DFA ((SELEZNOV et al., 2019)).

Os registros utilizados foram providos pelo formato de dados europeu (European Data Format) e podem ser acessados e detalhados na pesquisa conduzida por (2019). Esses conjuntos de dados estão disponíveis para a comunidade de pesquisadores em neurociência, visando investigar a dinâmica cerebral durante períodos de carga cognitiva. Todas as análises e visualizações dos dados foram executadas utilizando a linguagem de programação Python 3.6.

6 Análise de Resultados

6.1 Extração de Dados

Esta Seção se refere à extração de dados das soluções de DFA em EEG. Aqui, todos os artigos serão tabelados de forma geral para que sejam avaliados o perfil dos dados de EEG e o perfil das soluções utilizadas para DFA em EEG. Este processo ocorreu de forma a responder as questões definidas na Seção 4.1. Nas subseções a seguir, são apresentados os resultados obtidos de acordo com as questões de pesquisa.

6.1.1 Perfil dos dados de EEG

Nas Tabelas 3 e 4 estão elencados os trabalhos que contribuem para as questões (4.1) 01, 02 e 03, bem como são detalhados os registros de EEG. São avaliadas desde a quantidade de eletrodos e canais utilizados para a aquisição do sinal, até o perfil dos sujeitos, sejam eles originados de um experimento ou mesmo de uma base de dados. De acordo com os trabalhos selecionados são identificados:

ID: Identificação do artigo, facilita a visualização da quantidade de material analisado.

Trabalho: Referência do artigo.

Canais: Apresenta a quantidade de canais utilizada para a aquisição do EEG ou “Não identificado”, quando a pesquisa não divulga a quantidade explicitamente.

Eletrodos: Apresenta a quantidade de eletrodos utilizada para a aquisição do EEG ou “Não identificado”, quando a pesquisa não divulga a quantidade explicitamente.

Especificidade: Apresenta o critério para a aquisição do EEG, ou seja, se trata de uma doença ou situação específica, ou geral considerando qualquer indivíduo saudável.

Origem: Apresenta a origem do EEG, sendo considerada de uma pessoa, um animal ou uma simulação.

Os dados detalhados nas Tabelas 3 e 4 são quantificados para permitir uma melhor visualização dos resultados obtidos na Tabela 5. No que diz respeito ao perfil dos dados de EEG, observou-se que a DFA é frequentemente empregada para avaliar situações anômalas ou específicas, como epilepsia, distúrbios do sono, depressão e concentração. No entanto, poucos estudos fornecem detalhes claros sobre a quantidade de eletrodos e canais utilizados para aquisição do sinal EEG. A predominância do uso de EEG humano, devido à sua natureza não invasiva, foi também uma constatação relevante.

Tabela 3 – Perfil do EEG (1ª parte).

ID	Trabalho	Canais	Eletrodos	Especificidade	Origem
01	Castiglioni e Faini (2019)	Não identificado	Não identificado	Estudo do sono	Humano
02	Smith et al. (2021)	19	Não identificado	Espasmos epilépticos	Humano
03	Smith et al. (2019)	Não identificado	Não identificado	Sono-vigília e epilepsia	Humano
04	Goswami et al. (2022)	Não identificado	Não identificado	Espasmos epilépticos	Humano
05	Yean et al. (2018)	14	Não identificado	AVC	Humano
06	Filho, Cruz e Zebende (2019)	22	11	Leitura	Humano
07	Oon, Saidatul e Ibrahim (2018)	32	32	Estímulo de marketing	Humano
08	Jia e Yu (2019)	Não identificado	Não identificado	Espectro autista	Humano
09	Radhakrishnan et al. (2021)	19	Não identificado	Espectro autista	Humano
10	Abdolzadegan, Moattar e Ghoshuni (2020)	Não identificado	Não identificado	Espectro autista	Humano
11	Khoshnoud, Nazari e Shamsi (2018)	19	Não identificado	TDAH	Humano
12	Khoshnoud, Nazari e Shamsi (2020)	21	Não identificado	TDAH	Humano
13	Irrmischer et al. (2018)	64	Não identificado	Atenção e repouso	Humano
14	Prabhakar, Rajaguru e Lee (2019)	Não identificado	Não identificado	Alcoolismo	Humano
15	Prabhakar et al. (2020)	Não identificado	Não identificado	esquizofrenia	Humano
16	Jia et al. (2023)	Não identificado	Não identificado	Saudável	Humano
17	Zorick et al. (2021)	Não identificado	Não identificado	Lesão cerebral	Humano
18	Chao et al. (2022)	64	Não identificado	Alteração emocional	Humano
19	Choong et al. (2018)	Não identificado	Não identificado	Alteração emocional e AVC	Humano
20	Kaur et al. (2021)	Não identificado	Não identificado	Eliminar artefato	Humano

6.1.2 Perfil das Soluções

Nas Tabelas 6 e 7 estão elencados os trabalhos que contribuem para as questões (4.1) 04, 05 e 06, bem como são detalhadas as soluções para o uso de DFA em EEG. São avaliadas as soluções usadas, se são de código aberto (gratuito) ou possuem licença, e se a solução está sendo proposta ou está sendo avaliada pelos autores. De acordo com os trabalhos selecionados são identificados:

ID: Identificador do artigo, facilita a visualização da quantidade de material analisado.

Trabalho: Referência do artigo.

Usa: Apresenta a solução utilizada para a aplicação da DFA no EEG ou “Não identificada”, quando a pesquisa não divulga a solução explicitamente.

Tabela 4 – Perfil do EEG (2ª parte).

ID	Trabalho	Canais	Eletrodos	Especificidade	Origem
21	Mahato et al. (2020)	128	Não identificado	Depressão	Humano
22	Croce et al. (2018)	128	Não identificado	Estado de alerta	Humano
23	Liang et al. (2020)	32	Não identificado	Anestesiado	Humano
24	Nakov e Alimardani (2022)	Não identificado	18	AVC	Humano
25	Wang et al. (2022a)	Não identificado	Não identificado	Fadiga na direção	Humano
26	Wei et al. (2023)	Não identificado	Não identificado	Distúrbios da Consciência	Humano
27	Pavlov et al. (2020)	Não identificado	Não identificado	Adulto e idoso	Humano
28	Wang et al. (2022b)	Não identificado	Não identificado	Fadiga na direção	Humano
29	Cao et al. (2020)	Não identificado	Não identificado	Dor súbita	Humano
30	Zhang et al. (2021)	Não identificado	Não identificado	Parkinson e sono	Humano
31	Duncan et al. (2020)	Não identificado	Não identificado	Depressão	Humano
32	Tang et al. (2020)	20	Não identificado	Epilepsia	Humano
33	Porta e Copelli (2019)	Não identificado	Não identificado	Saudável	Modelo CROS e humano
34	Blokhina et al. (2023)	Não identificado	Não identificado	Anestesiado	Rato
35	Pavlov et al. (2021)	Não identificado	Não identificado	Privação de sono	Camundongo
36	Pavlov et al. (2020)	Não identificado	Não identificado	Estresse por som	Rato
37	Malekzadeh et al. (2021)	Não identificado	Não identificado	Epilepsia	Humano
38	Tang, Zhao e Wu (2020)	Não identificado	Não identificado	Epilepsia	Humano
39	Mesquita, Filho e Rodrigues (2021)	22	Não identificado	Não identificado	Humano
40	Xiong et al. (2021)	Não identificado	Não identificado	Apneia do sono	Humano
41	Seleznov et al. (2019)	Não identificado	Não identificado	Tarefa mental	Humano

Tabela 5 – Tabulação dos resultados gerais do perfil do EEG.

Detalhamento	Qtd de Artigos	Não informado
EEG Generalista	02	01
EEG Específico	38	01
Qtd Canais	14	27
Qtd Eletrodos	03	38
EEG Humano	37	0
EEG Animal	03	0
EEG Simulado	01	0

Gratuita: Apresenta “Sim” caso a solução (usada, proposta e/ou avaliada) seja gratuita, “Não” caso contrário, ou “Não identificada” quando não foi identificada nenhuma solução.

Propõe: Apresenta a solução proposta ou “Não” caso não seja proposta nenhuma solu-

ção.

Avalia: Apresenta “Sim” caso seja avaliada uma solução ou “Não” caso contrário.

Tabela 6 – Perfil da solução (1ª parte).

ID	Trabalho	Usa	Gratuita	Propõe	Avalia
01	Castiglioni e Faini (2019)	Não	Sim/Não	Algoritmo para DFA em MATLAB	Algoritmo para DFA em MATLAB
02	Smith et al. (2021)	MATLAB	Não	Não	Não
03	Smith et al. (2019)	MATLAB	Não	Não	Não
04	Goswami et al. (2022)	Programa R	Sim	Não	Não
05	Yean et al. (2018)	Não identificado	Não identificado	Não	Não
06	Filho, Cruz e Zebende (2019)	Não identificado	Não identificado	Não	Não
07	Oon, Saidatul e Ibrahim (2018)	Não identificado	Não identificado	Não	Não
08	Jia e Yu (2019)	Não identificado	Não identificado	Não	Não
09	Radhakrishnan et al. (2021)	Não identificado	Não identificado	Não	Não
10	Abdolzadegan, Moattar e Ghoshuni (2020)	Não identificado	Não identificado	Não	Não
11	Khoshnoud, Nazari e Shamsi (2018)	MATLAB	Não	Não	Não
12	Khoshnoud, Nazari e Shamsi (2020)	MATLAB	Não	Não	Não
13	Irrmischer et al. (2018)	EEGLAB	Sim	Não	Não
14	Prabhakar, Rajaguru e Lee (2019)	Não identificado	Não identificado	Não	Não
15	Prabhakar et al. (2020)	Não identificado	Não identificado	Não	Não
16	Jia et al. (2023)	EEGLAB	Sim	Não	Não
17	Zorick et al. (2021)	Não identificado	Não identificado	Não	Não
18	Chao et al. (2022)	Não identificado	Não identificado	Não	Não
19	Choong et al. (2018)	Não identificado	Não identificado	Não	Não
20	Kaur et al. (2021)	MATLAB	Não	Não	Não

Os dados descritos nas Tabelas 6 e 7 são quantificados para permitir uma melhor visualização dos resultados obtidos na Tabela 8. Ao analisar o perfil das soluções empregadas, constatou-se uma carência no âmbito da pesquisa em soluções de DFA em EEG sob a perspectiva da computação. A maioria das abordagens identificadas utilizam combinações de soluções pagas e gratuitas, sugerindo possíveis limitações de acesso a determinadas

Tabela 7 – Perfil da solução (2ª parte).

ID	Trabalho	Usa	Gratuita	Propõe	Avalia
21	Mahato et al. (2020)	MATLAB/EEGLAB	Não/Sim	Não	Não
22	Croce et al. (2018)	Não identificado	Não identificado	Não	Não
23	Liang et al. (2020)	MATLAB	Não	Não	Não
24	Nakov e Alimardani (2022)	Python	Sim	Não	Não
25	Wang et al. (2022a)	Não identificado	Não identificado	Não	Não
26	Wei et al. (2023)	Não identificado	Não identificado	Não	Não
27	Pavlov et al. (2020)	Não identificado	Não identificado	Não	Não
28	Wang et al. (2022b)	Não identificado	Não identificado	Não	Não
29	Cao et al. (2020)	Não identificado	Não identificado	Não	Não
30	Zhang et al. (2021)	MATLAB	Não	Não	Não
31	Duncan et al. (2020)	EEGLAB/MATLAB	Sim/Não	Não	Não
32	Tang et al. (2020)	Não identificado	Não identificado	Não	Não
33	Porta e Copelli (2019)	MATLAB/Python	Não/Sim	Não	Não
34	Blokhina et al. (2023)	Não identificado	Não identificado	Não	Não
35	Pavlov et al. (2021)	Não identificado	Não identificado	Não	Não
36	Pavlov et al. (2020)	Não identificado	Não identificado	Não	Não
37	Malekzadeh et al. (2021)	MATLAB/Python	Não/Sim	Não	Não
38	Tang, Zhao e Wu (2020)	Não identificado	Não identificado	Não	Não
39	Mesquita, Filho e Rodrigues (2021)	MATLAB/R	Não/Sim	Não	Não
40	Xiong et al. (2021)	EEGLAB/MATLAB	Sim/Não	Não	Não
41	Seleznov et al. (2019)	Python	Sim	Não	Não

funcionalidades disponíveis apenas em soluções licenciadas. Notavelmente, apenas um estudo apresentou uma proposta de algoritmo de DFA específico para EEG, avaliando seu desempenho de tempo de execução. Esse cenário sugere uma oportunidade para o desenvolvimento de soluções computacionais mais acessíveis e completas, direcionadas tanto aos pesquisadores de computação quanto aos da área da saúde.

No entanto, a falta de minuciosidade na descrição das etapas de processamento do EEG e na aplicação da DFA em muitos estudos indica a necessidade de uma comunicação mais clara e detalhada. Essa lacuna pode ser atribuída às diferentes áreas de expertise dos autores, o que sugere a existência de um nicho de pesquisadores em áreas não computacionais que necessitam de soluções computacionais de fácil uso e com funcionalidades

abrangentes para avançar nas aplicações da DFA em EEG.

Tabela 8 – Tabulação dos resultados gerais do perfil das soluções para DFA em EEG.

Detalhamento	Qtd de Artigos	Não informado
Usa Apenas Solução Gratuita	05	22
Usa Apenas Solução Paga	07	22
Usa Solução Paga + Gratuita	07	22
Propõe Solução	01	0
Avalia Solução	01	0

Toda a descrição dos artigos selecionados e sua tabulação contribuem para responder às questões secundárias desta pesquisa, e, conseqüentemente responder a questão central, que trata da forma como a DFA é aplicada ao EEG. Poucos artigos apresentam minuciosamente todas as etapas utilizadas para o processamento do EEG e o uso da DFA para tal. Essa informação implica no surgimento de dúvidas, talvez esse detalhamento não seja do interesse dos autores, nem objeto de suas pesquisas especificamente. Entretanto, claramente há um nicho composto por pesquisadores que são de áreas distantes da computação e necessitam utilizar soluções computacionais com boa usabilidade, de preferência gratuita e completa em suas funcionalidades, a fim de avançar ainda mais no uso de diferentes aplicações de DFA em EEG.

7 Considerações Finais e Trabalhos Futuros

7.1 Conclusões

Este trabalho teve como objetivo principal levantar o estado da arte sobre a forma de utilização da DFA para o processamento de EEG, considerando aplicações, algoritmos, ferramentas e sistemas como soluções possíveis para o processamento e uso de DFA no sinal de EEG.

Inicialmente foi traçado o perfil do EEG identificando as características principais para a aquisição do mesmo, tais como a quantidade de canais e de eletrodos, de quem são os registros e se há alguma condição associada à pessoa/animal registrado, configurando a primeira contribuição para pesquisadores.

Em um segundo momento foi realizado o levantamento do perfil das soluções caracterizadas por algoritmos, ferramentas, aplicações ou sistemas. Através dessa caracterização foi possível perceber como nos últimos anos tem-se realizado o processamento do EEG com a DFA.

Dessa maneira a pergunta principal deste estudo foi respondida, ou seja, foi estabelecida uma compreensão atualizada das maneiras utilizadas pelos pesquisadores para aplicar a DFA em EEG.

7.2 Direções para Futuras Pesquisas

Com base nos resultados desta pesquisa de revisão, algumas direções para futuras pesquisas podem ser sugeridas:

1. **Desenvolvimento de Algoritmos Específicos para DFA em EEG:** Considerando a carência de soluções computacionais especializadas em DFA para EEG, pesquisas futuras poderiam explorar o desenvolvimento de algoritmos otimizados e eficientes, levando em consideração os desafios específicos apresentados pelos sinais EEG.
2. **Acesso Aberto a Soluções Computacionais:** Investigar a criação de soluções de DFA em EEG de código aberto e gratuitas, visando democratizar o acesso a funcionalidades avançadas e promover a colaboração entre pesquisadores de diferentes áreas, incluindo a computação e a saúde.
3. **Padronização e Transparência na Descrição de Métodos:** Estabelecer diretrizes para a descrição detalhada das etapas de processamento de EEG e aplicação

da DFA, permitindo uma compreensão mais completa e reproduzível dos métodos empregados em estudos futuros.

4. **Avaliação Comparativa de Soluções:** Realizar estudos comparativos entre diferentes soluções de DFA em EEG, considerando critérios como desempenho, precisão e usabilidade. Isso poderia fornecer *insights* valiosos para a seleção adequada de abordagens em diferentes contextos de pesquisa.
5. **Integração Interdisciplinar:** Fomentar a colaboração entre pesquisadores das áreas de computação e saúde, buscando abordagens integradas que atendam às necessidades de ambos os campos e impulsionem o avanço nas aplicações da DFA em EEG.
6. **Exploração de Novos Domínios de Aplicação:** Investigar o uso da DFA em EEG em novos domínios de aplicação, além dos tradicionais, como *neurofeedback*, detecção de padrões anômalos e monitoramento de estados cognitivos, explorando potenciais benefícios clínicos e práticos.

Referências

- ABDOLZADEGAN, D.; MOATTAR, M. H.; GHOSHUNI, M. A robust method for early diagnosis of autism spectrum disorder from eeg signals based on feature selection and dbscan method. *Biocybernetics and Biomedical Engineering*, Elsevier, v. 40, n. 1, p. 482–493, 2020. Citado 3 vezes nas páginas 24, 31 e 33.
- ABIRI, R. et al. A comprehensive review of eeg-based brain–computer interface paradigms. *Journal of neural engineering*, IOP Publishing, v. 16, n. 1, p. 011001, 2019. Citado 3 vezes nas páginas 15, 16 e 18.
- ACHARYA, U. R. et al. Characterization of focal eeg signals: a review. *Future Generation Computer Systems*, Elsevier, v. 91, p. 290–299, 2019. Citado na página 11.
- AUNO, S. et al. Detrended fluctuation analysis in the presurgical evaluation of parietal lobe epilepsy patients. *Clinical Neurophysiology*, Elsevier, v. 132, n. 7, p. 1515–1525, 2021. Citado 2 vezes nas páginas 8 e 14.
- AZIZ, W.; ABBAS, R.; ARIF, M. Detrended fluctuation analysis of synthetic and real rr-interval time series of healthy subjects. *J. Appl. Em. Sci*, v. 1, n. 2, p. 58–63, 2005. Citado na página 12.
- BARBOSA, S.; SILVA, B. *Interação humano-computador*. [S.l.]: Elsevier Brasil, 2010. Citado na página 9.
- BARBOSA, S. D. J. et al. Interação humano-computador e experiência do usuário. *Auto publicação*, 2021. Citado na página 9.
- BLOKHINA, I. A. et al. Characterization of anesthesia in rats from eeg in terms of long-range correlations. *Diagnostics*, MDPI, v. 13, n. 3, p. 426, 2023. Citado 3 vezes nas páginas 27, 32 e 34.
- CAO, T. et al. Resting state eeg-based sudden pain recognition method and experimental study. *Biomedical Signal Processing and Control*, Elsevier, v. 59, p. 101925, 2020. Citado 3 vezes nas páginas 26, 32 e 34.
- CARVALHO, M. S. et al. Interictal and postictal 18 f-fdg pet/ct in epileptogenic zone localization. *Radiologia Brasileira*, SciELO Brasil, 2022. Citado na página 8.
- CASTIGLIONI, P.; FAINI, A. A fast dfa algorithm for multifractal multiscale analysis of physiological time series. *Frontiers in physiology*, Frontiers Media SA, v. 10, p. 115, 2019. Citado 3 vezes nas páginas 22, 31 e 33.
- CHAO, J. et al. Exploratory cross-frequency coupling and scaling analysis of neuronal oscillations stimulated by emotional images: an evidence from eeg. *IEEE Transactions on Cognitive and Developmental Systems*, IEEE, 2022. Citado 3 vezes nas páginas 25, 31 e 33.
- CHENG, Q.; LIU, X.; ZHU, X. Cryptocurrency momentum effect: Dfa and mf-dfa analysis. *Physica A: Statistical Mechanics and its Applications*, Elsevier, v. 526, p. 120847, 2019. Citado na página 8.

- CHOONG, W. et al. Eeg-based emotion assessment using detrended fluctuation analysis (dfa). *Journal of Telecommunication, Electronic and Computer Engineering (JTEC)*, v. 10, n. 1-13, p. 105–109, 2018. Citado 3 vezes nas páginas 25, 31 e 33.
- CORAZZA, L. A. et al. Electroencephalographic findings among inpatients with covid-19 in a tertiary hospital from a middle-income country. *Arquivos de Neuro-Psiquiatria, SciELO Brasil*, v. 79, p. 315–320, 2021. Citado na página 8.
- CÓRDOVA, F. et al. On the meaning of hurst entropy applied to eeg data series. *Procedia Computer Science*, Elsevier, v. 199, p. 1385–1392, 2022. Citado na página 8.
- CROCE, P. et al. Circadian rhythms in fractal features of eeg signals. *Frontiers in physiology*, Frontiers Media SA, v. 9, p. 1567, 2018. Citado 3 vezes nas páginas 25, 32 e 34.
- DAVID, S. A. et al. A combined measure to differentiate eeg signals using fractal dimension and mfdfa-hurst. *Communications in Nonlinear Science and Numerical Simulation*, Elsevier, v. 84, p. 105170, 2020. Citado na página 8.
- DÍAZ, D.; CÓRDOVA, F. et al. Visualization of eeg brain entropy dynamic maps in basal resting state conditions. *Procedia Computer Science*, Elsevier, v. 199, p. 1393–1400, 2022. Citado na página 8.
- DUNCAN, N. W. et al. Intrinsic activity temporal structure reactivity to behavioural state change is correlated with depressive symptoms. *European Journal of Neuroscience*, Wiley Online Library, v. 52, n. 12, p. 4840–4850, 2020. Citado 3 vezes nas páginas 26, 32 e 34.
- FILHO, F. O.; CRUZ, J. L.; ZEBENDE, G. Analysis of the eeg bio-signals during the reading task by dfa method. *Physica A: Statistical Mechanics and its Applications*, Elsevier, v. 525, p. 664–671, 2019. Citado 3 vezes nas páginas 23, 31 e 33.
- GÁRATE, E. et al. Hurst entropy profiles for beta low and beta high eeg sub-bands ii: Intergroup comparison. *Procedia Computer Science*, Elsevier, v. 199, p. 1424–1431, 2022. Citado na página 8.
- GÁRATE, E. et al. Hurst entropy profiles for beta low and beta high eeg sub-bands part i: Intragroup comparison. *Procedia Computer Science*, Elsevier, v. 199, p. 1416–1423, 2022. Citado na página 8.
- GHADERYAN, P. et al. New interdependence feature of eeg signals as a biomarker of timing deficits evaluated in attention-deficit/hyperactivity disorder detection. *Measurement*, Elsevier, v. 199, p. 111468, 2022. Citado na página 14.
- GÖKSU, E. Ö. et al. Early and late-onset nonconvulsive status epilepticus after stroke. *Arquivos de Neuro-Psiquiatria, SciELO Brasil*, v. 79, p. 384–389, 2021. Citado na página 8.
- GOSWAMI, I. et al. Early transient dysautonomia predicts the risk of infantile epileptic spasm syndrome onset: A prospective cohort study. *Frontiers in Neurology*, Frontiers Media SA, v. 13, p. 1090155, 2022. Citado 3 vezes nas páginas 23, 31 e 33.
- HALL, J. E. *Guyton & Hall. Tratado de fisiología médica*. [S.l.]: Elsevier Health Sciences, 2021. Citado 2 vezes nas páginas 8 e 11.

HERCULANO-HOUZEL, S. The human brain in numbers: a linearly scaled-up primate brain. *Frontiers in human neuroscience*, Frontiers, p. 31, 2009. Citado na página 11.

HU, L.; ZHANG, Z. *EEG signal processing and feature extraction*. [S.l.]: Springer, 2019. Citado na página 8.

IHLEN, E. A. Introduction to multifractal detrended fluctuation analysis in matlab. *Frontiers in physiology*, Frontiers Research Foundation, v. 3, p. 141, 2012. Citado na página 13.

IRRMISCHER, M. et al. Strong long-range temporal correlations of beta/gamma oscillations are associated with poor sustained visual attention performance. *European Journal of Neuroscience*, Wiley Online Library, v. 48, n. 8, p. 2674–2683, 2018. Citado 3 vezes nas páginas 24, 31 e 33.

JIA, H. et al. Scale-free dynamics in instantaneous alpha frequency fluctuations: Validation, test–retest reliability and its relationship with task manipulations. *Brain Topography*, Springer, v. 36, n. 2, p. 230–242, 2023. Citado 3 vezes nas páginas 24, 31 e 33.

JIA, H.; YU, D. Attenuated long-range temporal correlations of electrocortical oscillations in patients with autism spectrum disorder. *Developmental Cognitive Neuroscience*, Elsevier, v. 39, p. 100687, 2019. Citado 3 vezes nas páginas 23, 31 e 33.

KANDEL, E. et al. *Princípios de neurociências-5*. [S.l.]: AMGH Editora, 2014. Citado 2 vezes nas páginas 8 e 11.

KAUR, C. et al. Eeg signal denoising using hybrid approach of variational mode decomposition and wavelets for depression. *Biomedical Signal Processing and Control*, Elsevier, v. 65, p. 102337, 2021. Citado 3 vezes nas páginas 25, 31 e 33.

KHOSHNOUD, S.; NAZARI, M. A.; SHAMSI, M. Functional brain dynamic analysis of adhd and control children using nonlinear dynamical features of eeg signals. *Journal of integrative neuroscience*, IOS Press, v. 17, n. 1, p. 17–30, 2018. Citado 3 vezes nas páginas 24, 31 e 33.

KHOSHNOUD, S.; NAZARI, M. A.; SHAMSI, M. Source-based multifractal detrended fluctuation analysis for discrimination of adhd children in a time reproduction paradigm. In: *BIOSIGNALS*. [S.l.: s.n.], 2020. p. 38–48. Citado 3 vezes nas páginas 24, 31 e 33.

KHOSLA, A.; KHANDNOR, P.; CHAND, T. Automated diagnosis of depression from eeg signals using traditional and deep learning approaches: A comparative analysis. *Biocybernetics and Biomedical Engineering*, v. 42, n. 1, p. 108–142, 2022. ISSN 0208-5216. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0208521621001431>>. Citado 2 vezes nas páginas 16 e 18.

KITLAS-GOLIŃSKA, A. Detrended fluctuation analysis in biomedical signal processing: selected examples. *Studies in Logic, Grammar and Rhetoric*, v. 29, n. 42, 2012. Citado na página 12.

LIANG, Z. et al. Constructing a consciousness meter based on the combination of non-linear measurements and genetic algorithm-based support vector machine. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 28, n. 2, p. 399–408, 2020. Citado 3 vezes nas páginas 25, 32 e 34.

- LOTTE, F. et al. A review of classification algorithms for eeg-based brain–computer interfaces: a 10 year update. *Journal of neural engineering*, iOP Publishing, v. 15, n. 3, p. 031005, 2018. Citado 2 vezes nas páginas 15 e 18.
- LOURENÇO, E. S. et al. Eeg education in brazil: a national survey of adult neurology residents. *Arquivos de Neuro-Psiquiatria*, SciELO Brasil, v. 80, p. 43–47, 2021. Citado na página 8.
- MA, M. K.-H. et al. Regularity and randomness in ageing: Differences in resting-state eeg complexity measured by largest lyapunov exponent. *Neuroimage: Reports*, Elsevier, v. 1, n. 4, p. 100054, 2021. Citado na página 8.
- MAHATO, S. et al. Detection of depression and scaling of severity using six channel eeg data. *Journal of medical systems*, Springer, v. 44, p. 1–12, 2020. Citado 3 vezes nas páginas 25, 32 e 34.
- MALEKZADEH, A. et al. Automatic diagnosis of epileptic seizures in eeg signals using fractal dimension features and convolutional autoencoder method. *Big Data and Cognitive Computing*, MDPI, v. 5, n. 4, p. 78, 2021. Citado 4 vezes nas páginas 27, 28, 32 e 34.
- MANDELBROT, B. B. Fractal geometry: what is it, and what does it do? *Proceedings of the Royal Society of London. A. Mathematical and Physical Sciences*, The Royal Society London, v. 423, n. 1864, p. 3–16, 1989. Citado na página 13.
- MCCALLAN, N. et al. Epileptic multi-seizure type classification using electroencephalogram signals from the temple university hospital seizure corpus: A review. *Expert Systems with Applications*, p. 121040, 2023. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417423015427>>. Citado 2 vezes nas páginas 17 e 18.
- MENSI, W.; HAMDI, A.; YOON, S.-M. Modelling multifractality and efficiency of gcc stock markets using the mf-dfa approach: A comparative analysis of global, regional and islamic markets. *Physica A: Statistical Mechanics and its Applications*, Elsevier, v. 503, p. 1107–1116, 2018. Citado na página 8.
- MESQUITA, V. B.; FILHO, F. M. O.; RODRIGUES, P. C. Detection of crossover points in detrended fluctuation analysis: an application to eeg signals of patients with epilepsy. *Bioinformatics*, Oxford University Press, v. 37, n. 9, p. 1278–1284, 2021. Citado 3 vezes nas páginas 28, 32 e 34.
- MILÀ, B. R. et al. Eeg biomarkers for the diagnosis and treatment of infantile spasms. *Frontiers in Neurology*, Frontiers, v. 13, p. 960454, 2022. Citado 3 vezes nas páginas 16, 17 e 18.
- MOTAMEDI-FAKHR, S. et al. Signal processing techniques applied to human sleep eeg signals—a review. *Biomedical Signal Processing and Control*, Elsevier, v. 10, p. 21–33, 2014. Citado 2 vezes nas páginas 15 e 18.
- NAKOV, N.; ALIMARDANI, M. Using eeg brain signals to predict children’s learning performance during technology-assisted language learning. In: IEEE. *2022 IEEE 3rd International Conference on Human-Machine Systems (ICHMS)*. [S.l.], 2022. p. 1–5. Citado 3 vezes nas páginas 25, 32 e 34.

- NETO, F. S. de A.; ROSA, J. L. G. Depression biomarkers using non-invasive eeg: A review. *Neuroscience & Biobehavioral Reviews*, Elsevier, v. 105, p. 83–93, 2019. Citado 2 vezes nas páginas 15 e 18.
- OON, H. N.; SAIDATUL, A.; IBRAHIM, Z. Analysis on non-linear features of electroencephalogram (eeg) signal for neuromarketing application. In: IEEE. *2018 international conference on computational approach in smart systems design and applications (ICASSDA)*. [S.l.], 2018. p. 1–8. Citado 3 vezes nas páginas 23, 31 e 33.
- PAVLOV, A. et al. Extended detrended fluctuation analysis of sound-induced changes in brain electrical activity. *Chaos, Solitons & Fractals*, Elsevier, v. 139, p. 109989, 2020. Citado 4 vezes nas páginas 9, 27, 32 e 34.
- PAVLOV, A. et al. Detrended fluctuation analysis of eeg patterns associated with real and imaginary arm movements. *Physica A: Statistical Mechanics and its Applications*, Elsevier, v. 509, p. 777–782, 2018. Citado na página 14.
- PAVLOV, A. N. et al. Effects of sleep deprivation on the brain electrical activity in mice. *Applied Sciences*, MDPI, v. 11, n. 3, p. 1182, 2021. Citado 3 vezes nas páginas 27, 32 e 34.
- PAVLOV, A. N. et al. Age-related distinctions in eeg signals during execution of motor tasks characterized in terms of long-range correlations. *Sensors*, MDPI, v. 20, n. 20, p. 5843, 2020. Citado 3 vezes nas páginas 26, 32 e 34.
- PENG, C.-K. et al. Mosaic organization of dna nucleotides. *Physical review e, APS*, v. 49, n. 2, p. 1685, 1994. Citado na página 12.
- PENG, C.-K. et al. Quantification of scaling exponents and crossover phenomena in nonstationary heartbeat time series. *Chaos: an interdisciplinary journal of nonlinear science*, American Institute of Physics, v. 5, n. 1, p. 82–87, 1995. Citado na página 12.
- PENG, Z.-Y. et al. Existence of memory in membrane channels: analysis of ion current through a voltage-dependent potassium single channel. *Cell Biology International*, Wiley Online Library, v. 36, n. 11, p. 973–979, 2012. Citado na página 12.
- PÖLD, T. et al. Long-term stability of resting state eeg-based linear and nonlinear measures. *International Journal of Psychophysiology*, Elsevier, v. 159, p. 83–87, 2021. Citado na página 9.
- PORTA, L. D.; COPELLI, M. Modeling neuronal avalanches and long-range temporal correlations at the emergence of collective oscillations: Continuously varying exponents mimic m/eeg results. *PLoS computational biology*, Public Library of Science San Francisco, CA USA, v. 15, n. 4, p. e1006924, 2019. Citado 3 vezes nas páginas 27, 32 e 34.
- PRABHAKAR, S. K. et al. Schizophrenia eeg signal classification based on swarm intelligence computing. *Computational Intelligence and Neuroscience*, Hindawi, v. 2020, 2020. Citado 3 vezes nas páginas 24, 31 e 33.
- PRABHAKAR, S. K.; RAJAGURU, H.; LEE, S.-W. A comprehensive analysis of alcoholic eeg signals with detrend fluctuation analysis and post classifiers. In: IEEE. *2019 7th International Winter Conference on Brain-Computer Interface (BCI)*. [S.l.], 2019. p. 1–6. Citado 3 vezes nas páginas 24, 31 e 33.

- RADHAKRISHNAN, M. et al. Investigating eeg signals of autistic individuals using detrended fluctuation analysis. *Traitement du Signal*, v. 38, n. 5, 2021. Citado 3 vezes nas páginas 23, 31 e 33.
- RIGOLI, L. M. et al. Co-actors exhibit similarity in their structure of behavioural variation that remains stable across range of naturalistic activities. *Scientific reports*, Nature Publishing Group UK London, v. 10, n. 1, p. 6308, 2020. Citado 3 vezes nas páginas 6, 12 e 13.
- ROSAS, L. F.; FERNANDES, T. D. A geometria fractal. *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics*, v. 8, n. 1, 2021. Citado na página 13.
- SANTOS, W. et al. Análise estatística do eletrocorticograma durante o fenômeno da depressão alastrante em córtex cerebral de ratos nutridos e desnutridos. Universidade Federal Rural de Pernambuco, 2007. Citado na página 11.
- SELEZNOV, I. et al. Detrended fluctuation, coherence, and spectral power analysis of activation rearrangement in eeg dynamics during cognitive workload. *Frontiers in human neuroscience*, Frontiers Media SA, v. 13, p. 270, 2019. Citado 3 vezes nas páginas 29, 32 e 34.
- SILVA, H. S. da; SILVA, J. R. S.; STOSIC, T. Multifractal analysis of air temperature in brazil. *Physica A: Statistical Mechanics and its Applications*, Elsevier, v. 549, p. 124333, 2020. Citado na página 8.
- SMITH, R. J. et al. Computational characteristics of interictal eeg as objective markers of epileptic spasms. *Epilepsy Research*, Elsevier, v. 176, p. 106704, 2021. Citado 5 vezes nas páginas 9, 14, 22, 31 e 33.
- SMITH, R. J. et al. Inference on long-range temporal correlations in human eeg data. *IEEE journal of biomedical and health informatics*, IEEE, v. 24, n. 4, p. 1070–1079, 2019. Citado 3 vezes nas páginas 23, 31 e 33.
- TANG, L. et al. Seizure prediction using multi-view features and improved convolutional gated recurrent network. *IEEE Access*, IEEE, v. 8, p. 172352–172361, 2020. Citado 3 vezes nas páginas 26, 32 e 34.
- TANG, L.; ZHAO, M.; WU, X. Accurate classification of epilepsy seizure types using wavelet packet decomposition and local detrended fluctuation analysis. *Electronics Letters*, Wiley Online Library, v. 56, n. 17, p. 861–863, 2020. Citado 3 vezes nas páginas 28, 32 e 34.
- WANG, F. et al. A driving fatigue feature detection method based on multifractal theory. *IEEE Sensors Journal*, IEEE, v. 22, n. 19, p. 19046–19059, 2022. Citado 3 vezes nas páginas 25, 32 e 34.
- WANG, F. et al. Study on the effect of judgment excitation mode to relieve driving fatigue based on mf-dfa. *Brain sciences*, MDPI, v. 12, n. 9, p. 1199, 2022. Citado 3 vezes nas páginas 26, 32 e 34.
- WEI, X. et al. Aberrant temporal correlations of ongoing oscillations in disorders of consciousness on multiple time scales. *Cognitive Neurodynamics*, Springer, v. 17, n. 3, p. 633–645, 2023. Citado 3 vezes nas páginas 25, 32 e 34.

- WU, X. Seizure prediction using multi-view features and improved convolutional gated recurrent network. Citado na página 26.
- XIONG, X. et al. Eeg microstate in obstructive sleep apnea patients. *Scientific Reports*, Nature Publishing Group UK London, v. 11, n. 1, p. 17178, 2021. Citado 3 vezes nas páginas 28, 32 e 34.
- YEAN, C. W. et al. Analysis of the distance metrics of knn classifier for eeg signal in stroke patients. In: IEEE. *2018 International conference on computational approach in smart systems design and applications (ICASSDA)*. [S.l.], 2018. p. 1–4. Citado 3 vezes nas páginas 23, 31 e 33.
- YU, C.; WANG, M. Survey of emotion recognition methods using eeg information. *Cognitive Robotics*, v. 2, p. 132–146, 2022. ISSN 2667-2413. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2667241322000118>>. Citado 2 vezes nas páginas 16 e 18.
- ZHANG, C. et al. Nrem sleep eeg characteristics correlate to the mild cognitive impairment in patients with parkinsonism. *BioMed Research International*, Hindawi Limited, v. 2021, p. 1–10, 2021. Citado 3 vezes nas páginas 26, 32 e 34.
- ZORICK, T. et al. Information transfer and multifractal analysis of eeg in mild blast-induced tbi. *Computational and Mathematical Methods in Medicine*, Hindawi, v. 2021, 2021. Citado 3 vezes nas páginas 24, 31 e 33.
- ZORICK, T. et al. Eeg multifractal analysis correlates with cognitive testing scores and clinical staging in mild cognitive impairment. *Journal of Clinical Neuroscience*, Elsevier, v. 76, p. 195–200, 2020. Citado na página 14.
- ZYMA, I. et al. Electroencephalograms during mental arithmetic task performance. *Data*, MDPI, v. 4, n. 1, p. 14, 2019. Citado na página 29.



**TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA
“JOSÉ ALBANO DE MACEDO”**

Identificação do Tipo de Documento

- () Tese
() Dissertação
(X) Monografia
() Artigo

Eu, **Eva Luana Almeida da Silva**, autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação: “**Uma visão de soluções na literatura para o processamento de eletroencefalograma usando *Detrended Fluctuation Analysis***” de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI 28 de agosto de 2023.

Eva Luana Almeida da Silva
Assinatura