



UNIVERSIDADE FEDERAL DO PARÁ  
NÚCLEO DE TEORIA E PESQUISA DO COMPORTAMENTO  
PROGRAMA DE PÓS-GRADUAÇÃO EM NEUROCIÊNCIA E  
COMPORTAMENTO

Arthur Gonsales da Silva

**Modelo Híbrido Inception-XGB para  
Discriminação de Padrões Artefatuais em  
Eletroencefalografia de Pacientes com Epilepsia**

Belém

2022

Arthur Gonsales da Silva

# **Modelo Híbrido Inception-XGB para Discriminação de Padrões Artefatuais em Eletroencefalografia de Pacientes com Epilepsia**

Projeto de mestrado apresentado ao Programa de Pós-graduação em Neurociência e Comportamento do Núcleo de Teoria e Pesquisa do Comportamento da Universidade Federal do Pará como requisito parcial para obtenção do título de mestre em Neurociência e Comportamento.

Universidade Federal do Pará

Orientador: Prof. Dr. Bruno Duarte Gomes

Coorientador: Prof. Dr. Fernando Allan de Farias Rocha

Belém

2022

Arthur Gonsales da Silva

# **Modelo Híbrido Inception-XGB para Discriminação de Padrões Artefatuais em Eletroencefalografia de Pacientes com Epilepsia**

Projeto de mestrado apresentado ao Programa de Pós-graduação em Neurociência e Comportamento do Núcleo de Teoria e Pesquisa do Comportamento da Universidade Federal do Pará como requisito parcial para obtenção do título de mestre em Neurociência e Comportamento.

Conceito: \_\_\_\_\_

Belém, 28 de março de 2022.

## BANCA EXAMINADORA

---

**Prof. Dr. Bruno Duarte Gomes** - Orientador  
Instituto de Ciências Biológicas, UFPA

---

**Prof. Dr. Fernando Allan de Farias Rocha** - Coorientador  
Instituto de Ciências Biológicas, UFPA

---

**Prof. Dr. Antônio Pereira Junior**  
Instituto de Tecnologia, UFPA

---

**Prof. Dr. Givago da Silva Souza**  
Instituto de Ciências Biológicas, UFPA

---

**Prof. Dr. Rommel Thiago Jucá Ramos**  
Instituto de Ciências Biológicas, UFPA  
(Membro suplente)

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD  
Sistema de Bibliotecas da Universidade Federal do Pará  
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

---

S586m Silva, Arthur Gonsales da.  
Modelo Híbrido Inception-XGB para Discriminação de Padrões  
Artefatuais em Eletroencefalografia de Pacientes com Epilepsia /  
Arthur Gonsales da Silva. — 2022.  
44 f. : il. color.

Orientador(a): Prof. Dr. Bruno Duarte Gomes  
Coorientador(a): Prof. Dr. Fernando Allan de Farias Rocha  
Dissertação (Mestrado) - Universidade Federal do Pará, Núcleo  
de Teoria e Pesquisa do Comportamento, Programa de Pós-  
Graduação em Neurociências e Comportamento, Belém, 2022.

1. epilepsia. 2. aprendizado de máquina. 3. classificação. 4.  
série temporal. 5. eletroencefalografia. I. Título.

CDD 150.285

---

# Agradecimentos

Meus agradecimentos vão primeiramente aos meus pais, que mesmo em meio à todas as dificuldades que a vida os impôs, deram tudo de si para que hoje eu possa ter a oportunidade de estar prestes a concluir meu mestrado.

Em segundo lugar, agradeço ao meu orientador, Prof. Dr. Bruno Duarte Gomes, pessoa a qual eu devo muito da minha carreira até aqui, que me proporcionou oportunidades acadêmicas e profissionais de valor inestimável, principalmente em um momento difícil para quem produz ciência no Brasil.

Aproveito aqui para estender agradecimentos a todas as pessoas que de forma direta ou indireta contribuíram para minha formação, tanto dentro quanto fora da academia, e que talvez sem elas as coisas pudessem ser bem mais difíceis.

*“Nullius in verba”*  
*(The Royal Society of London for Improving Natural Knowledge, 1660)*

# Resumo

O objetivo deste trabalho foi comparar o desempenho de diferentes algoritmos de aprendizado de máquina em uma tarefa de classificação de quatro tipos de padrões artefatuais comumente encontrados em registros de Eletroencefalografia (EEG). Os padrões foram processados usando uma Rede Neural Convolutacional (CNN) do tipo *Inception*. Foram usados registros de pacientes portadores de Epilepsia de uma base pública de dados. Um total de 200 pacientes participaram do estudo, sendo 100 homens e 100 mulheres, com idades e comorbidades associadas variadas. Na engenharia de dados nós utilizamos a Transformada de Hilbert-Huang (HHT) para extração de potência e fase instantâneas de amostras correspondendo à 1 segundo de registro cada, distribuídas em quatro classes de padrões artefatuais. Sendo estas: a) movimento ocular, b) movimento muscular, c) ruído eletrostático, e d) tremores musculares. As amostras bidimensionais compostas por potência e fase foram processadas pela arquitetura *Inception*, reduzidas à um vetor unidimensional e então alimentaram quatro diferentes algoritmos de aprendizado de máquina, sendo estes: a) *Extreme Gradient Boosting* (XGB), b) *Random Forest Classifier* (RFC), c) *K-Neighbors Classifier* (k-NN) e d) *Logistic Regression* (LR). A média das acurácias de cada modelo, por instancia de treinamento (*fold*), foi comparada através do teste estatístico ANOVA, para verificar diferenças estatísticas entre os modelos. Os resultados mostraram que o algoritmo XGB obteve melhor performance, com acurácia de 94.82% aproximadamente 13% mais preciso que o modelo linha de base, que teve acurácia de 83.97% quando treinado nos dados brutos. Foi estabelecido assim um modelo final híbrido *Inception-XGB* inédito, em conjunto com um eficiente processo de extração de características.

**Palavras-chave:** epilepsia, aprendizado de máquina, classificação, série temporal, eletroencefalografia

# Abstract

The aim of this study is to compare the performance of different machine learning algorithms for the task of discriminating four artifactual patterns of common occurrence in electroencephalography (EEG) recordings. These patterns were processed by an Inception Convolutional Neural Network (CNN) from EEG recorded from epilepsy patients. The EEG was part of a public available dataset. A total of 200 patients participated in the study, 100 men and 100 women, with varying ages and associated comorbidities. For feature engineering we used the Hilbert-Huang Transform (HHT) to obtain instantaneous power and phase from EEG samples comprising one second of recording each. They contained artifacts distributed in four classes: a) eye movement, b) muscle movement, c) electrostatic noise, and d) shivering. The two-dimensional samples composed of power and phase were processed by the Inception architecture where they were reduced to a one-dimensional vector and then fed to four different machine learning algorithms, namely: a) Extreme Gradient Boosting (XGB), b) Random Forest Classifier (RFC), c) K-Neighbors Classifier (k-NN), and d) Logistic Regression (LR). The average accuracy of each model, per training instance, was compared using ANOVA in order to verify the existence of statistical difference among models. The results demonstrated that the XGB algorithm had the best performance, reaching an accuracy score of 94.82%, outperforming the baseline model, which reached an accuracy score of 83.97% when trained with raw EEG data. This established an unprecedented Inception-XGB hybrid model together with an efficient feature extraction process.

**Keywords:** epilepsy, machine learning, classification, time-series, electroencephalography

# Lista de ilustrações

Figura 1.	Em preto um registro comum de EEG com padrões de crise do segundo 0 ao segundo 60, aproximadamente. Em vermelho são exibidos os padrões artefatuais extraídos do sinal, e em azul, o sinal reconstruído, semelhante ao gráfico em preto. . . . .	14
Figura 2.	Gráfico da porcentagem de referências publicadas, por tipo de método, no campo da remoção de artefatos nos últimos cinco anos (a contar de 2019). . . . .	15
Figura 3.	Ilustração de diferentes tipos de modelos de aprendizado de máquina. B ilustra o funcionamento de um algoritmo <i>ensemble</i> baseado em AD, onde cada <i>base learner</i> vota em uma classe, para uma dada amostra, para que esta seja ou não a classe final estimada. . . . .	21
Figura 4.	Representação diagramática da localização dos eletrodos no sistema 10-20, padronizado internacionalmente para registro clínico de EEG. . . . .	27
Figura 5.	Amostra randômica coletada da base de dados sem qualquer procedimento de extração de características aplicado. . . . .	28
Figura 6.	Visualização com <i>Principal Component Analysis</i> (PCA) da classe de tremor muscular ( <i>shivering</i> ) antes e depois do aumento de dados com SMOTE. . . . .	29
Figura 7.	Representação gráfica de potência e fase instantâneas extraídas da amostra exibida anteriormente através da Transformada de Hilbert-Huang. . . . .	30
Figura 8.	Arquitetura <i>Inception</i> utilizada para extração de características dos registros de EEG. A seta preta aponta a direção da propagação da amostra na rede. . . . .	31
Figura 9.	Fluxo de modelagem empregado neste estudo. . . . .	33
Figura 10.	Curvas ROC do Classificador final, exibindo a performance por classe. . . . .	37

# Lista de tabelas

Tabela 1.	Tabela de parâmetros otimizados da rede <i>Inception</i> utilizada para extração de características. . . . .	35
Tabela 2.	Tabela comparativa das performances que determinam a linha de base da classificação. . . . .	35
Tabela 3.	Tabela comparativa das performances atingidas pelos modelos treinados com validação cruzada para seleção do algoritmo final . . . . .	36
Tabela 4.	Tabela de parâmetros do classificador final . . . . .	37
Tabela 5.	Cronograma de execução do projeto em 2019 . . . . .	40
Tabela 6.	Cronograma de execução do projeto em 2020 . . . . .	40
Tabela 7.	Cronograma de execução do projeto em 2021 . . . . .	40
Tabela 8.	Cronograma de execução do projeto em 2022 . . . . .	41

# Lista de abreviaturas e siglas

EEG	Eletroencefalografia
ICA	Independent Component Analysis
BSS	Blind Source Separation
HHT	Hilbert-Huang Transform
EMD	Empirical Mode Decomposition
HSA	Hilbert Spectral Analysis
IMF	Intrinsic Mode Functions
ILAE	International League Against Epilepsy
SVM	Support Vector Machine
k-NN	k-Nearest Neighbors
AD	Árvore de Decisão
XGB	Extreme Gradient Boosting
RFC	Random Forest Classifier
k-NN	K Neighbors Classifier
LR	Logistic Regression
RC	Ridge Classifier
SMOTE	Synthetic Minority Over-sampling Technique
LM-BFGS	Limited-memory Broyden-Fletcher-Goldfarb-Shanno
CNN	Convolutional Neural Network

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>13</b>
1.1	Aplicações do Aprendizado de Maquina	16
<b>2</b>	<b>CONTEXTUALIZAÇÃO E TERMINOLOGIAS DO TRABALHO</b>	<b>19</b>
2.1	Eletroencefalografia	19
2.2	Eletroencefalografia e Epilepsia	19
2.3	Eletroencefalografia, Epilepsia e Aprendizado de Maquina	20
<b>3</b>	<b>TRABALHOS RELACIONADOS</b>	<b>22</b>
<b>4</b>	<b>JUSTIFICATIVA</b>	<b>23</b>
<b>5</b>	<b>CONTRIBUIÇÃO À ÁREA</b>	<b>24</b>
<b>6</b>	<b>OBJETIVOS</b>	<b>25</b>
6.1	Objetivo Geral	25
6.2	Objetivos Específicos	25
<b>7</b>	<b>METODOLOGIA</b>	<b>26</b>
7.1	Participantes	26
7.2	Amostras do Estudo	26
7.3	Segmentação das Séries Temporais	27
7.4	Análise de Dados	28
7.4.1	Aumento de Dados	28
7.4.2	Decomposição das Séries Temporais	29
7.4.3	Extração de Características	31
7.5	Definição da Linha de Base do Classificador	32
7.6	Seleção do Classificador Final	33
7.7	Teste Estatístico	33
7.8	Fluxo de Modelagem	33
7.9	Materiais e Instrumentos	34
<b>8</b>	<b>RESULTADOS</b>	<b>35</b>
8.1	Otimização da Extração de Características	35
8.2	Definição da Linha de Base do Classificador	35
8.3	Seleção do Classificador Final	36
8.3.1	Parâmetros do Classificador Final	37

8.3.2	Curvas ROC do Classificador Final . . . . .	37
8.4	<b>XV Congresso Brasileiro de Inteligência Computacional 2021 . . . .</b>	<b>38</b>
9	<b>CONCLUSÃO . . . . .</b>	<b>39</b>
10	<b>CRONOGRAMA . . . . .</b>	<b>40</b>
	<b>Referências . . . . .</b>	<b>42</b>

# 1 Introdução

A epilepsia é uma desordem elétrica do cérebro, caracterizada por interrupções recorrentes e imprevisíveis da atividade neuronal normal, as chamadas crises epiléticas. A epilepsia não é uma doença por si só, mas sim uma variedade de desordens que refletem uma disfunção cerebral que pode ter causas distintas (Fisher et al., 2005).

Segundo Fisher et al. (2005), o conceito central na definição da epilepsia é uma alteração contínua no cérebro que aumenta a probabilidade de ocorrência de crises futuras. Neste contexto não mais que duas crises são necessárias para o diagnóstico da doença, mas apenas uma crise associada a um distúrbio duradouro do cérebro capaz de originar outras futuras crises convulsivas.

A Eletroencefalografia (EEG) é o procedimento-diagnóstico mais importante para epilepsia, que demanda validação através do EEG. O EEG pode responder a três principais perguntas para o diagnóstico de pacientes com suspeita de epilepsia: a) o paciente tem epilepsia?, b) onde é a região epileptogênica? e c) quão boa será a terapia? (Noachtar & Rémi, 2009).

A sensibilidade e especificidade do EEG dependem de alguns fatores como idade e procedimentos de registro. O EEG revela características encontradas em várias síndromes epiléticas como: a) *Spikes*, b) Ondas afiadas, c) descargas epileptiformes benignas da infância, d) Complexos de ondas de pico, e) Complexos de ondas de pico lentas, f) Complexos de ondas de pico de 3 Hz, g) *Polyspikes*, h) Hipsarritmia, i) Padrão de convulsão e j) Padrão de *status* epilético (Noachtar & Rémi, 2009). A partir disso, o EEG ajuda na determinação do tipo de crise, bem como na escolha de medicamentos antiepiléticos, além de contribuir para o diagnóstico das crises focal ou generalizada, idiopática ou sintomática, dentre outras síndromes (Smith, 2005).

Uma análise cuidadosa dos registros eletroencefalográficos pode promover perspectivas valiosas e melhorar o entendimento dos mecanismos causadores da epilepsia (Adeli, Zhou, & Dadmehr, 2003). O eletroencefalograma registra várias frequências diferentes em sinais cerebrais não estacionários de diferentes canais distribuídos no escalpo (Harpale & Bairagi, 2016).

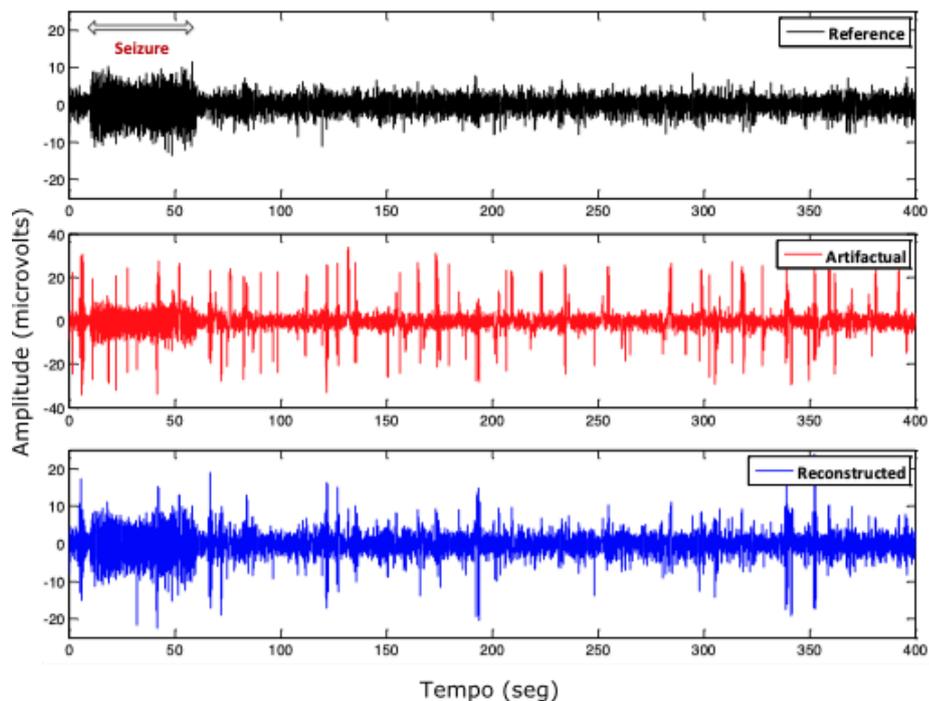
O EEG bruto pode vir 'contaminado' com uma série de componentes indesejados, como ruídos e artefatos causados por fontes de energia, fortes de ondas eletromagnéticas do ambiente, piscadas (e movimentos oculares em geral), batimentos cardíacos e movimentos musculares. A presença desses artefatos é inevitável durante o registro do EEG, afetando sua análise, o que pode produzir informações não precisas e laboriosas rotinas de processamento digital de sinais com o objetivo de minorar ou remover completamente os artefatos (Lai

et al., 2018).

No contexto da epilepsia, artefatos relacionados a movimentos musculares impõem um grande desafio para a precisão de sistemas baseados em computação. Estes artefatos possuem grande distribuição espectral e, portanto, perturbam todas as bandas de frequência clássicas do EEG. Em particular, artefatos de movimentação sobrepõem a banda Beta de 15-30Hz, bem como afetam também um intervalo de frequência menor, chegando à 2Hz, o que torna a banda Alfa vulnerável a interferências (M. S. Islam et al., 2020).

Na figura 1 a seguir, M. K. Islam, Rastegarnia, and Yang (2015) faz uma importante demonstração dos efeitos que os artefatos causam em sinais de EEG.

Figura 1. Em preto um registro comum de EEG com padrões de crise do segundo 0 ao segundo 60, aproximadamente. Em vermelho são exibidos os padrões artefatuais extraídos do sinal, e em azul, o sinal reconstruído, semelhante ao gráfico em preto.



Fonte: islam2015wavelet

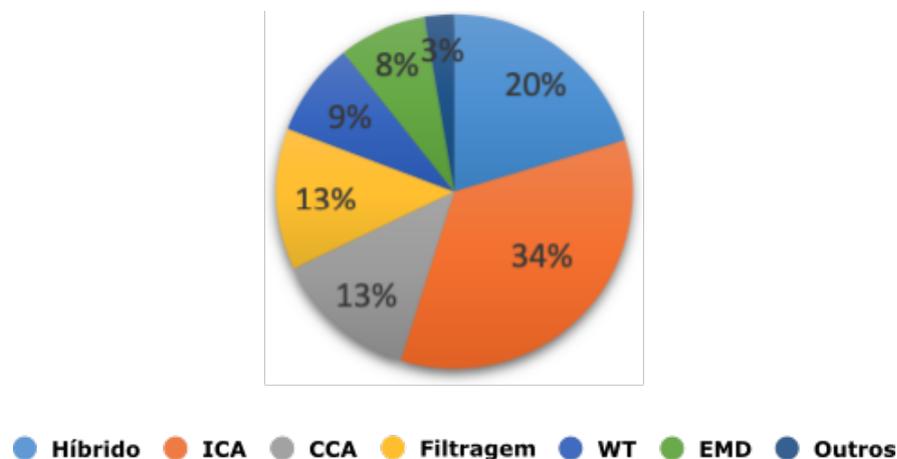
Vários métodos para detecção e remoção de artefato do EEG são amplamente utilizados atualmente, sendo provavelmente a abordagem mais simples dentre estes, uma avaliação qualitativa através de um observador treinado que exclui artefatos visualmente. Ainda que algumas estratégias possam ser automatizadas, em geral, o risco desses métodos retirarem ou modificarem trechos do EEG que não correspondem a artefatos pode ser considerável, o que leva muitos pesquisadores a tratar estes dados com métodos baseados em inspeção visual. Esta, no entanto, é uma abordagem subjetiva, demorada e não confiável, especialmente por conta da natureza altamente transitória do EEG (Levitt et al., 2018).

A análise de componentes independentes (ICA - *Independent component analysis*) é um dos métodos mais utilizados para remoção de artefatos de registros de eletroencefalografia, onde os componentes extraídos de trechos de sinais ruidosos são descartados e os componentes com informações não ruidosas são mantidos, reconstruindo assim um sinal sem artefatos. No entanto, o processo de avaliação e classificação dos componentes independentes (ICs) calculados como artefatos ou como EEG importante não é em geral automatizado. Podendo assim introduzir novos artefatos no sinal, ou concentrar-se apenas em tipos específicos de ruídos, não sendo adequado para aplicações em tempo real. Ou ainda modificar ou retirar trechos do EEG que não correspondem realmente a artefatos (Radüntz, Scouten, Hochmuth, & Meffert, 2017).

A figura abaixo (Figura 2) mostra a porcentagem de estudos nos últimos cinco anos, segundo o método de tratamento de artefatos usado. Os algoritmos mais utilizados são aqueles baseados em *Blind Source Separation* (BSS), especialmente o ICA (Jiang, Bian, & Tian, 2019).

Na figura 2 a seguir, Jiang et al. (2019) faz uma importante constatação das porcentagens de publicação de literatura separadas por método.

Figura 2. Gráfico da porcentagem de referências publicadas, por tipo de método, no campo da remoção de artefatos nos últimos cinco anos (a contar de 2019).



Fonte: Jiang et al. (2019)

O sinal de EEG é não linear e não estacionário em sua natureza, o que torna interpretar estes sinais uma tarefa complexa. Pode ser observado na literatura que os pesquisadores costumam extrair características, performar análises estatísticas, elencar padrões extraídos e então comparar diferentes classificadores para estes dados, o que configura uma série de etapas padronizadas que podem ser automatizadas (Acharya, Oh, Hagiwara, Tan, & Adeli, 2018).

Existem diversos métodos para análise de sinais não lineares, como por exemplo transformada de Fourier janelada, transformada Wavelet, distribuição WignerVille, dentre

outros, cada um possuindo suas próprias limitações. A transformada Wavelet, por exemplo, capta flutuações rápidas e frequentes no sinal, porém é extremamente sensível a ruídos, dependendo assim de uma função wavelet base ideal, o que adiciona um componente de complexidade na análise (Wang & Ji, 2018). A transformada de Fourier janelada, por sua vez, é baseada na transformada de Fourier tradicional, sendo um método linear de análise (Wang & Ji, 2018).

Huang et al. (1998) desenvolveu um método para análise não linear de sinais, chamado de Transformada de Hilbert-Huang (HHT), consistindo em duas partes: a *Empirical mode decomposition* (EMD) e a *Hilbert spectral analysis* (HSA):

1. EMD: Trata-se de um método *data-driven* que decompõe um sinal em um conjunto de sub-sinais com modos de oscilação significativamente diferentes uns dos outros (Zheng et al., 2021).
2. HSA: Trata-se de um operador linear que recebe um sinal e produz seu conjugado harmônico correspondente, de onde são derivadas potência e fase instantâneas para uma dada amostra (Zheng et al., 2021).

Diferente de outros métodos que requerem um conjunto de informações pré-definidas sobre o sinal (como wavelets e Fourier), a HHT é um método de decomposição *data-driven*, adaptativo e algorítmico, de onde podemos identificar modos de oscilação no sinal independentemente de frequências e amplitudes variáveis, o que torna a HHT mais eficiente em explicar a não-estacionariedade de um sinal. (Zheng et al., 2021).

O método HHT tem numerosas vantagens se comparado a métodos lineares tradicionais como a transformada de Fourier e vem sendo aplicado em diversos campos de pesquisa, sendo considerado um método altamente adaptável e flexível quando aplicado ao processamento de sinais para extração de informações. De fato, a HHT é um método algorítmico e não analítico como são as transformadas Wavelet e de Fourier.

Apesar das extensivas pesquisas no campo da detecção e remoção de artefatos de sinais de EEG reportadas na literatura até agora, não existe um consenso geral de uma solução ótima para todos os tipos de artefatos existentes (Jiang et al., 2019). A tendência atual da detecção e remoção de artefatos utiliza aprendizado de máquina para fornecer soluções automatizadas com maior eficiência (Lai et al., 2018).

## 1.1 Aplicações do Aprendizado de Máquina

A discriminação dos padrões de ativação neuronal depende de um algoritmo de classificação que automaticamente estima a classe de uma amostra representada por um vetor de características (Lotte, Congedo, Lécuyer, Lamarche, & Arnaldi, 2007).

Muitos algoritmos para classificação foram propostos na literatura, incluindo abordagens miméticas e baseadas em regras, métodos tempo-frequência, transformada Wavelet, redes neurais artificiais, análise de componentes independentes, *support vector machines*, mineração de dados, correspondência de modelos e classificação topográfica (Tzallas, Tsipouras, & Fotiadis, 2009).

Aprendizagem de máquina é uma abordagem promissora para classificação de amostras de EEG. A eficiência deste tipo de método é principalmente determinada pelas técnicas de extração e seleção de características que reduzem a dimensionalidade dos dados de entrada. Essa redução é implementada via abordagens matemáticas, não importando assim a origem e distribuição dos dados analisados (Bastos, Marques, Adamatti, & Billa, 2020).

Para exploração de características profundas em um conjunto de dados de imagem, algoritmos de inteligência artificial com maiores propriedades discriminativas são cada vez mais necessários. Neste contexto, as Redes Neurais Convolucionais (CNN) são introduzidas, uma vez que estas possuem capacidade de aprender padrões de alto nível de complexidade aprofundando sua arquitetura de camadas convolucionais, o que garante uma melhor performance de predição ao classificador final (Fahim, Sarker, Sarker, Sheikh, & Das, 2020).

Arquiteturas do tipo CNN tem se mostrado a melhor escolha em problemas envolvendo classificação de dados de imageamento médico. Redes pré-treinadas como a *Inception* tem demonstrado grande sucesso em diversas aplicações médicas. Além do mais, este tipo de CNN mitiga a insuficiência de dados para treino, problema recorrente em bases de dados médicos. Isto acontece não só por modelos como este possibilitarem estratégias de aumento de dados, mas também por reduzirem significativamente a dimensionalidade dos dados processados pelas camadas convolucionais (Ramaneswaran, Srinivasan, Vincent, & Chang, 2021).

Existem diversos algoritmos classificadores baseados em aprendizado de máquina. O algoritmo *Extreme Gradient Boosting* (XGB) é um classificador do tipo *ensemble*, composto por diversas árvores de decisão (AD). Quando comparado com outros algoritmos de classificação, o XGB demonstra performance superior, com boa tolerância à ruídos e boa capacidade de generalização (Yang, Li, & Di, 2019). O XGB faz parte do conjunto de algoritmos testados neste trabalho.

A detecção e remoção de artefatos presentes em sinais de EEG representa um desafio real e é crucial para a interpretação confiável de medidas quantitativas baseadas no eletroencefalograma (Anastasiadou et al., 2014). Muitas síndromes epilépticas são associadas com características específicas do EEG, algumas bem aceitas, outras ainda não incluídas no sistema de classificação atual da Liga Internacional Contra a Epilepsia (LICE), devido à quantidade insuficiente de dados (Smith, 2005).

A automatização da detecção de padrões artefatuais em sinais de EEG de pacientes epiléticos através do uso de aprendizado de máquina é de extrema importância quando se tem em vista que diagnóstico e tratamento tardios podem ocasionar problemas ao paciente. Crises podem afetar as funções sensoriais e motoras, bem como consciência, estado emocional, memória, cognição ou comportamento (Fisher et al., 2005).

## 2 Contextualização e Terminologias do Trabalho

### 2.1 Eletroencefalografia

A eletroencefalografia é uma ferramenta não-invasiva para medir a atividade elétrica do cérebro através de eletrodos posicionados no escalpo. Estes eletrodos registram a voltagem que resulta do fluxo interno e externo dos neurônios (Biasiucci, Franceschiello, & Murray, 2019).

Apesar de muito consolidado, o EEG continua sendo de extrema importância em campos como o da psicologia experimental, mas também vem sendo utilizado como uma verdadeira técnica de neuroimagem com aplicações recentes em neurociência translacional e também em neurociência computacional. A versatilidade e acessibilidade desta técnica, em conjunto com os avanços no processamento digital de sinais permite que esta ferramenta ainda produza inovações importantes (Biasiucci et al., 2019).

Embora seja caracterizado por sua versatilidade e acessibilidade, é importante ressaltar que o EEG detecta apenas uma porção das atividades elétricas que ocorrem no cérebro, e faz isso a despeito da co-ocorrência de outros tipos de atividades elétricas, como batimento cardíaco, movimento ocular e outras atividades musculares. Para ser mais claro, o EEG não mede potenciais de ação, mas sim potenciais pós-sinápticos, que são mais lentos quando comparados ao primeiro. (Biasiucci et al., 2019).

### 2.2 Eletroencefalografia e Epilepsia

Métodos baseados em computação tem diversas aplicações na área medica, como por exemplo diagnósticos automatizados. Estes sistemas podem ser utilizados por medicos para diagnosticar certas desordens através da análise automatizada de imagens medicas ou sinais fisiológicos registrados dos pacientes (Ibrahim, Djemal, & Alsuwailem, 2018).

O diagnóstico medico é, por vezes, uma tarefa desafiadora que requer muito esforço e expertise por parte dos profissionais. Com os avanços nos campos de processamento digital de sinais e aprendizado de máquina, sistemas baseados em computação tem se tornado capazes de concluir tarefas cada vez mais complexas e sofisticadas, incluindo a análise de sinais de EEG. Estas automações poderão salvar cada vez mais tempo bem como melhorar a acurácia global de diagnósticos de várias desordens (Ibrahim et al., 2018).

Analisar anomalias em sinais cerebrais pode prover informações importantes sobre

as condições patológicas do órgão. O EEG, que captura estes sinais, tem enorme potencial de aplicações diversas para este tipo de análise, uma vez que os registros de EEG já vem sendo usados por muito tempo para o diagnóstico da epilepsia (Ibrahim et al., 2018).

## 2.3 Eletroencefalografia, Epilepsia e Aprendizado de Máquina

O aprendizado de máquina se aproveita de princípios e conceitos da ciência da computação e da estatística aplicada para o desenvolvimento de algoritmos capazes de realizar tarefas com base na interpretação dos dados ao invés de obedecer a ordens explícitas de um programador (Abbasi & Goldenholz, 2019).

Avanços vem ocorrendo no campo da epilepsia em conjunto com técnicas de aprendizado de máquina através do melhoramento de métodos em coleta, armazenamento e processamento de dados (Abbasi & Goldenholz, 2019). A maioria das tarefas em aprendizado de máquina são classificadas como aprendizado supervisionado ou não supervisionado. Na aprendizagem supervisionada, um algoritmo é treinado em um dado conjunto de dados com amostras rotuladas em uma determinada quantidade de classes, de maneira que o modelo final seja capaz de estimar a classe de uma amostra nova e não rotulada (Abbasi & Goldenholz, 2019).

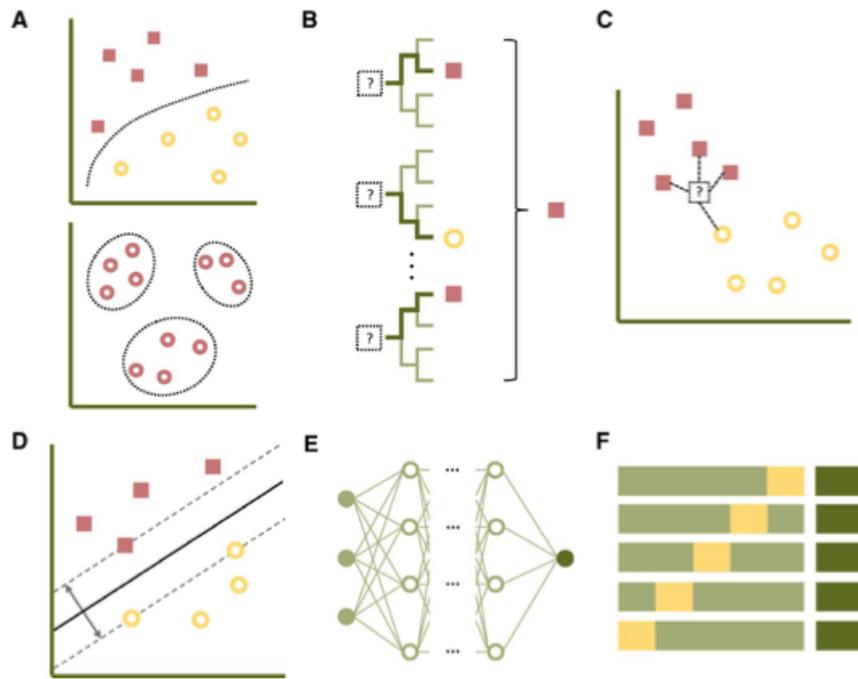
Um exemplo de aplicação de modelos supervisionados é o treinamento de um algoritmo em um conjunto de dados de EEG rotulados, para que este possa classificar e/ou detectar padrões epileptiformes em pacientes.

Tanto em abordagens supervisionadas quanto não supervisionadas, um ranqueamento de importância preditiva para cada preditor inserido no modelo é identificado em um processo chamado seleção de características, seja este processo manual, com base em conhecimento de domínio, ou automatizado pelo próprio classificador (Abbasi & Goldenholz, 2019).

Dentre os algoritmos de aprendizado de máquina mais utilizados estão os baseados em árvores de decisão, como o *random forest*, que cria múltiplas árvores de decisão internas, chamadas de *base learners* com base nos dados de treino, onde cada um destes *base learners* é treinado em um subconjunto diferente e randômico de preditores. O *random forest* resultante gera o que é chamado de *ensemble output*, que nada mais é do que a classe estimada com maior frequência pelos *base learners* para uma dada amostra, o que acaba por se tornar um sistema de classificação por votação (Abbasi & Goldenholz, 2019).

Na figura 3 a seguir, Abbasi and Goldenholz (2019) mostra uma representação visual interessante sobre o funcionamento de diferentes tipos de modelos de aprendizado de máquina.

Figura 3. Ilustração de diferentes tipos de modelos de aprendizado de máquina. B ilustra o funcionamento de um algoritmo *ensemble* baseado em AD, onde cada *base learner* vota em uma classe, para uma dada amostra, para que esta seja ou não a classe final estimada.



Fonte: Abbasi e Goldenholz (2019)

Comprovada a utilidade do aprendizado de máquina para análise de grandes e complexos conjuntos de dados, atenção considerada vem sendo empregada na automação da detecção de padrões em registros de EEG de pacientes portadores de epilepsia. Uma grande variedade de técnicas vem sendo aplicadas nesta tarefa, incluindo *support vector machines* (SVM), *k-Neares Neighbors* (k-NN) e classificadores de *deep learning* (Abbasi & Goldenholz, 2019).

Em paralelo às tarefas de classificação e predição, técnicas de aprendizado de máquina também vem sendo aplicadas no diagnóstico da doença em si, usando como base diferentes fontes de dados para a conclusão deste tipo de tarefa (Abbasi & Goldenholz, 2019).

### 3 Trabalhos Relacionados

Raghu, Sriraam, Temel, Rao, and Kubben (2020), em artigo recente, utilizou a mesma base de dados utilizada neste trabalho para propor uma arquitetura de CNN com transferencia de aprendizado para classificação de crises epiléticas. Dois modelos foram testados, uma rede Googlenet e uma rede *InceptionV3*, ambas alcançando acurácias de 82.85% e 88.30% respectivamente.

Uma estratégia de detecção de artefatos em sinais de EEG foi recentemente proposta por Yasoda, Ponmagal, Bhuvaneshwari, and Venkatachalam (2020). Em trabalho intitulado *Automatic detection and classification of EEG artifacts using fuzzy kernel SVM and wavelet ICA (WICA)*, é estabelecido que registros de EEG são quase sempre contaminados com diferentes tipos de artefatos enquanto o registro é feito, e que diagnósticos clínicos e aplicações de Interface Cerebro-maquina frequentemente necessitam de detecção e remoção de artefatos automatizada. O modelo proposto pelos autores foi capaz de atingir acurácia final de 86.1% para tarefa de classificação binária entre amostras artefatuais e não artefatuais.

Outro método de classificação de sinais de EEG de pacientes com epilepsia foi proposto por Gao, Gao, Chen, Liu, and Zhang (2020). Nesta abordagem os autores primeiramente transformam os sinais de EEG em *power spectrum density energy diagrams* e então treinam uma CNN com transferencia de aprendizado para classificar quatro diferentes estados de epilepsia. A acurácia final alcançada pelo modelo proposto pelos autores é de 92.5%

## 4 Justificativa

O processo de discriminação de diferentes padrões artefatuais em registros de EEG estabelece um importante desafio no campo da análise automatizada de sinais, uma vez que segundo Čukić, Stokić, Simić, and Pokrajac (2020), até mesmo o sucesso da discriminação de depressão em registros de EEG pode ser atribuído ao procedimento correto de extração de características e não a um método particular de classificação.

Isto posto, este trabalho procura desenvolver uma abordagem robusta, que inclui técnica avançada para extração de características das amostras de EEG, bem como um modelo híbrido de alto desempenho na tarefa de classificação dos padrões artefatuais, uma vez que este tipo de abordagem é extremamente útil em equipamentos de registro, bem como em aplicações de Interface Cerebro-maquina, onde a detecção fina de padrões artefatuais impacta enormemente na qualidade da coleta de dados neuronais, sobretudo em situações onde o paciente possui comorbidades associadas que alteram os padrões de ativação cerebrais, que é o caso deste trabalho, uma vez que nosso modelo deve ser capaz de generalizar amostras de pacientes com diferentes sexos, idades e comorbidades associadas.

## 5 Contribuição à Área

Historicamente, com base na literatura e nas práticas atuais de processamento de informação neuronal e aprendizado de máquina, o tipo de modelagem apresentada neste trabalho é considerada de alta complexidade e usualmente requer alto poder de armazenamento e de processamento computacionais para que se possa atingir resultados satisfatórios em tarefas de classificação e regressão uma vez que séries temporais, especificamente as produzidas pelo cérebro, possuem extrema complexidade associada. A saber, são séries temporais não lineares e não ergódicas.

Neste trabalho visamos apresentar uma abordagem de maior robustez, que compreende desde o processo de extração de características utilizando técnica apropriada para dados não estacionários, bem como a modelagem destas características por um modelo híbrido de alta capacidade de generalização, podendo ser embarcado em equipamentos de registro e em outros *softwares* do segmento.

## 6 Objetivos

### 6.1 Objetivo Geral

Identificar quatro diferentes tipos de padrões artefatuais em registros de EEG de pacientes portadores de epilepsia, utilizando uma rede CNN do tipo *Inception* para extração de características, em conjunto com um algoritmo de aprendizado de máquina para classificação.

### 6.2 Objetivos Específicos

- Modelar de forma indireta as comorbidades associadas que podem ou não alterar o padrão de ativação neuronal dos pacientes, caso este as portem.
- Utilizar a HHT como método de decomposição dos sinais e extração de potência e fase instantâneas dos registros de EEG.
- Estabelecer um formato multicanal para amostras processadas com a HHT para modelagem com a rede CNN do tipo *Inception*.

# 7 Metodologia

## 7.1 Participantes

Foram admitidos para o estudo 200 pacientes, sendo 100 homens e 100 mulheres, com idades variadas (nem sempre informadas) e diferentes tipos de comorbidades associadas, diagnosticados com epilepsia e submetidos previamente ao procedimento de registro eletrofisiológico para captação do padrão de ativação neuronal destas pessoas. A seleção dos participantes não leva em consideração a condição em que a epilepsia se manifesta nos sujeitos, não importando se esta é focal ou generalizada, uma vez que o interesse está direcionado puramente para os padrões artefatuais registrados pelos eletrodos.

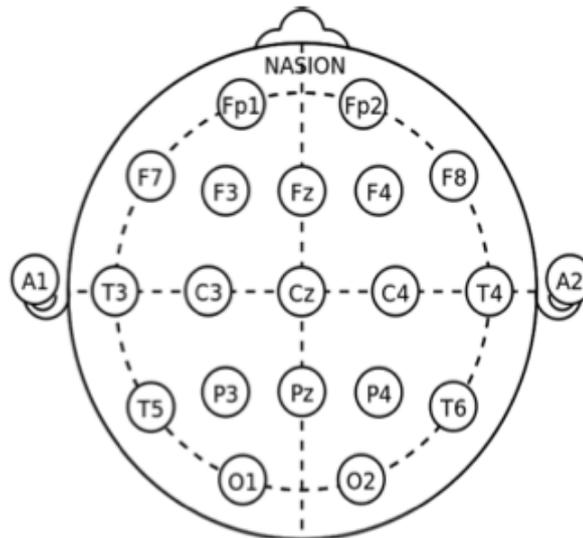
## 7.2 Amostras do Estudo

As amostras de registro de EEG foram disponibilizadas através de um disco rígido externo fornecido por pesquisadores do *Temple University Hospital* (TUH) ao Laboratório de Neurofisiologia Eduardo Oswaldo Cruz (LNEOC), para fins de pesquisa científica. O disco enviado pelos pesquisadores conta com cerca de 4 *Terabytes* em registros de EEG de sujeitos portadores de epilepsia atendidos no mesmo hospital, desde o ano de 2008.

Todos os arquivos possuem formato .edf, estando separados por seções e acompanhados de um arquivo de texto simples, descrevendo informações básicas (não padronizadas) sobre os pacientes. Além das informações adicionais sobre os pacientes, cada arquivo de registro possui marcações manuais que indicam o início e o fim, no tempo, de anomalias capturadas pelos eletrodos.

Todos os registros de EEG utilizados neste estudo foram obtidos através do sistema 10-20 de montagem dos eletrodos, devido a este sistema ter demonstrado resultados clínicos satisfatórios e ter ganhado aceitação mundial (Chatrian, Lettich, & Nelson, 1985). Na figura 4 a seguir, feita por Khazi, Kumar, and Vidya (2012), o sistema 10-20 é demonstrado.

Figura 4. Representação diagramática da localização dos eletrodos no sistema 10-20, padronizado internacionalmente para registro clínico de EEG.



Fonte: Khazi et al. (2012)

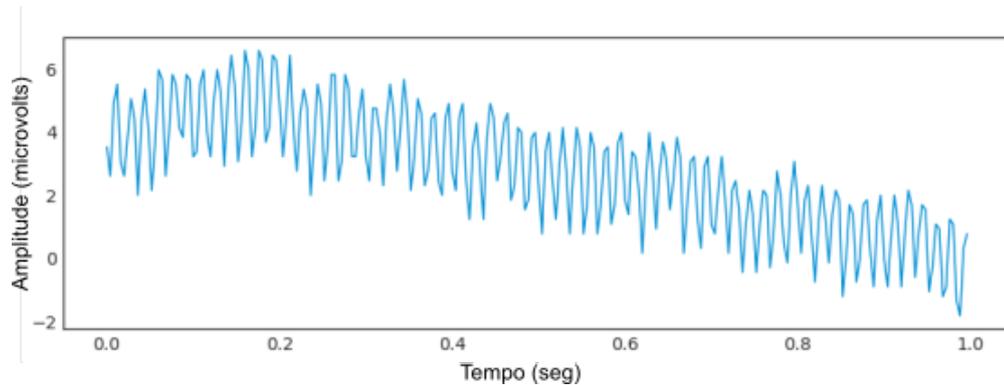
As amostras foram randomicamente selecionadas, levando em consideração apenas um número balanceado de pacientes masculinos e femininos, e filtrados pela menor taxa de amostragem comum a todos os registros, que corresponde a 250Hz. Todas as amostras disponíveis foram concatenadas em quatro series temporais, cada uma correspondente a uma classe da modelagem.

### 7.3 Segmentação das Séries Temporais

As quatro series temporais resultantes do processo de concatenação foram então segmentadas em amostras de 250 pontos, correspondentes a 1 segundo de registro, e então separadas em suas devidas classes, sendo estas: a) movimento ocular, b) ruído eletrostático, c) movimento muscular e d) tremores musculares (*shivering*), cada classe compreendendo uma fatia de 25% da base de dados total de 20.992 amostras.

A figura 5 a seguir mostra uma amostra randomica retirada da base de dados sem a aplicação de qualquer técnica de processamento e/ou extração de características, correspondente à 1 segundo de atividade neuronal.

Figura 5. Amostra randômica coletada da base de dados sem qualquer procedimento de extração de características aplicado.



Fonte: Autor.

Por se tratar de um dado de alta complexidade e não linearidade, fez-se necessário o uso de um método de extração de características adequado para a modelagem destes sinais, neste caso, aplicamos a transformada de Hilbert-Huang para decomposição das amostras.

## 7.4 Análise de Dados

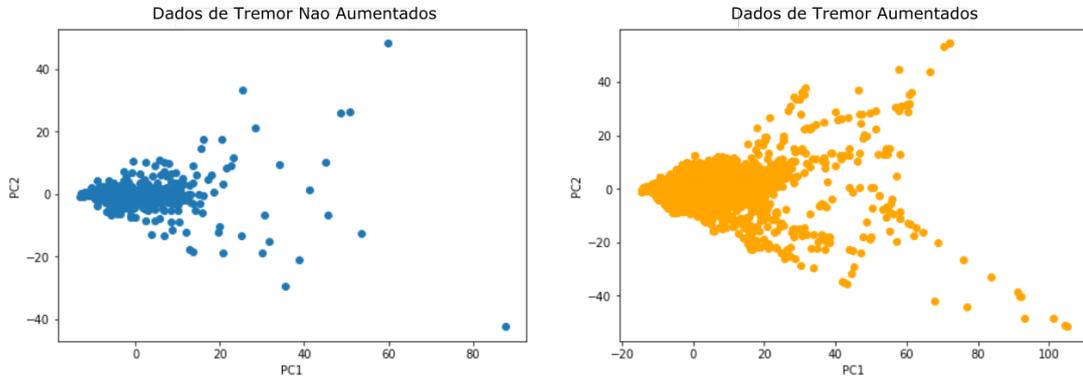
### 7.4.1 Aumento de Dados

No conjunto de dados utilizado neste estudo, a classe de tremores musculares (*shivering*) tem poucas amostras disponíveis quando comparada ao restante das classes, contando com apenas apenas 509 observações. Isso pode afetar a performance do modelo durante o treinamento, tornando não confiável a sua capacidade de generalização final.

Para aumento da quantidade de amostras na classe problemática utilizamos o método *Synthetic Minority Over-sampling Technique* (SMOTE), que super amostra a quantidade de observações para uma dada classe com base na real distribuição das amostras daquela classe (Chawla, Bowyer, Hall, & Kegelmeyer, 2002).

Na figura 6 a seguir é apresentada uma comparação visual das amostras de tremor muscular (*shivering*) antes e depois do aumento de dados com SMOTE.

Figura 6. Visualização com *Principal Component Analysis* (PCA) da classe de tremor muscular (*shivering*) antes e depois do aumento de dados com SMOTE.



Fonte: Autor.

Na figura 6 acima utilizamos a técnica de *Principal Component Analysis* (PCA) para reduzir a base de dados de 250 preditores para os dois estatisticamente mais importantes, possibilitando assim a visualização do conjunto de dados em duas dimensões. Ao final do processo, temos uma base de dados perfeitamente balanceada, onde todas as classes possuem a mesma quantidade de amostras.

#### 7.4.2 Decomposição das Séries Temporais

A transformada de Hilbert-Huang, proposta por Huang et al. (1998) consiste de duas etapas de processamento de um sinal, EMD e HSA, já citadas anteriormente. Primeiramente um sinal é decomposto em  $N$  *Intrinsic mode functions* (IMFs) através do método EMD. Uma IMF precisa satisfazer duas condições para que seja extraída: a) em todo o conjunto de dados, o número de extremas e o número de cruzamentos em zero necessitam ser iguais ou diferentes ao menos em um; b) em qualquer ponto do sinal, a média do envelope definido pela máxima local e do envelope definido pela mínima local precisam ser iguais a zero (Wang & Ji, 2018).

Com as IMFs extraídas, a HSA pode ser obtida, uma vez que esta se baseia na existência destes componentes. Primeiramente calculamos  $c_j(t)$  através da transformada de Hilbert, como mostrado na equação abaixo (Wang & Ji, 2018):

$$c(t) = \frac{1}{\pi} \times P \int_{-\infty}^{\infty} \frac{c_j(\tau)}{t-\tau} d\tau$$

Na fórmula acima, a variável  $P$  indica o valor principal Cauchy. Com base nisso podemos calcular o valor de  $z_j(t)$  a seguir:

$$z_j(t) = c_j(t) + ic_j(t) = a_j(t) \times e^{i\theta_j(t)}$$

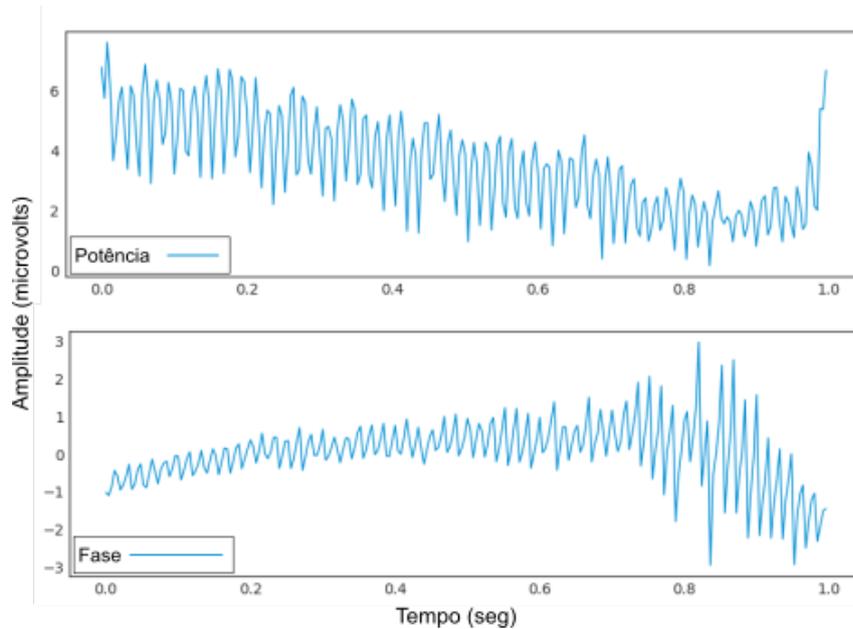
Na fórmula acima,  $c_j(t)$  e  $ic_j(t)$  formam um par conjugado complexo, a partir do qual obtemos um sinal analítico  $z_j(t)$ , como na fórmula a seguir (Wang & Ji, 2018):

$$a_j(t) = [c_j^2(t) + c_j^2(t)]^{1/2}, \theta_j(t) = \arctan\left(\frac{c_j(t)}{c_j(t)}\right)$$

Nesta última fórmula,  $a_j(t)$  é a potência instantânea de  $c_j(t)$ , o que reflete que a energia de  $c_j(t)$  varia com o tempo, e  $\theta_j(t)$  é a fase instantânea de  $c_j(t)$  (Wang & Ji, 2018).

Através do procedimento descrito acima, extraímos as IMFs, e posteriormente potência e fase de cada uma das amostras do conjunto de dados. As imagens a seguir mostram potência e fase extraídas para a mesma amostra bruta exemplificada na figura 5.

Figura 7. Representação gráfica de potência e fase instantâneas extraídas da amostra exibida anteriormente através da Transformada de Hilbert-Huang.



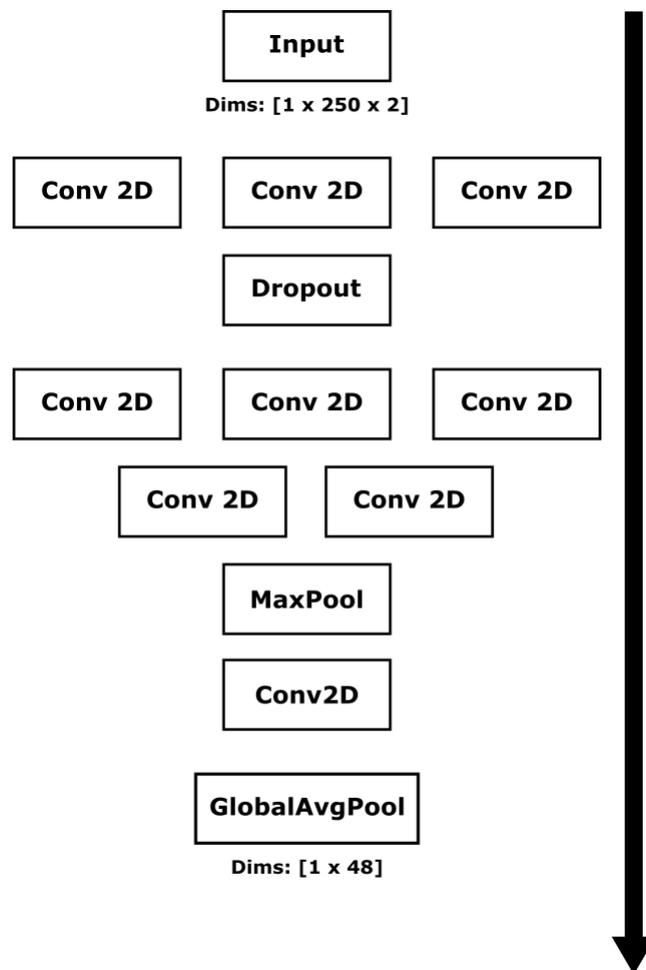
Fonte: Autor

Com os componentes de potência e fase extraídos, construímos amostras multidimensionais, estando no primeiro canal a potência, e no segundo canal a fase, configurando amostras de dimensões  $[1 \times 250 \times 2]$ .

### 7.4.3 Extração de Características

Para extração de padrões das amostras foi utilizada uma CNN do tipo *Inception* (Szegedy et al., 2015). Este modelo atingiu o estado da arte em classificação e detecção de imagens em larga escala no *ImageNet Large-Scale Visual Recognition Challenge 2014* (ILSVRC14), possuindo uma arquitetura cuidadosamente construída de forma a permitir o aprofundamento das camadas convolucionais sem aumentar o custo computacional do modelo (Szegedy et al., 2015).

Figura 8. Arquitetura *Inception* utilizada para extração de características dos registros de EEG. A seta preta aponta a direção da propagação da amostra na rede.



Fonte: Autor

A rede *Inception* recebe uma amostra de dimensões [1 x 250 x 2] e reduz esta para um vetor de características unidimensional de [1 x 48], que alimentará o algoritmo de aprendizado de máquina acoplado ao final da arquitetura *Inception* para classificação. A redução significativa na quantidade de dimensões das amostras é fruto da aplicação de uma camada *GlobalAveragePooling2D*, que reduz a dimensionalidade às médias dos mapas de características extraídos pelas camadas convolucionais.

Para convergência do modelo apresentado acima, aplicamos um processo de otimização bayesiana em um esqueleto base da rede *Inception*, incluindo uma camada *fully connected* não utilizada no processo final de classificação, mas necessária para o treinamento do modelo nos dados, afim de possibilitar o encontro de parametros como: a) número de filtros (por camada), b) dimensões dos filtros (por camada), c) número de blocos *Inception* e d) taxa de *dropout*, todos selecionados de forma dinâmica.

Quanto às etapas de otimização bayesiana, utilizamos um *Gaussian process* (GP), um poderoso algoritmo para predição de amostras com base em informações adquiridas a priori no processo de treinamento. Este modelo é frequentemente utilizado para atribuição de probabilidades à funções que descrevem um conjunto de dados, onde a média da distribuição das probabilidades representa a mais provável caracterização do conjunto de dados (Frazier, 2018).

Utilizando o algoritmo GP, podemos estimar a função de aquisição que melhor explorou o espaço amostral de onde foi derivado o conjunto de parametros que levou a rede *Inception* à convergencia. A função de aquisição utilizada foi a *Expected Improvement* (Frazier, 2018), em conjunto com o algoritmo de otimização *Limited-memory Broyden-Fletcher-Goldfarb-Shanno* (LM-BFGS) (Liu & Nocedal, 1989), o que finaliza nossa etapa de otimização bayesiana, alcançando um erro na validação de 0.21 para a arquitetura exibida na figura 7.

## 7.5 Definição da Linha de Base do Classificador

Foram treinados cinco diferentes modelos de aprendizado de máquina a fim de determinar uma linha de base para a tarefa de classificação de amostras de registros aretfatuais de EEG de pacientes portadores de epilepsia.

Os modelos utilizados neste estudo foram: a) *K Neighbors Classifier* (k-NN), b) *Logistic Regressor* (LR), c) *Random Forest Classifier* (RFC), d) *Ridge Classifier* (RC), e e) *Extreme Gradient Boosting* (XGB). A seleção destes algoritmos se deu pela viabilidade de treinamento em GPU para cada um deles.

Treinamos os modelos supracitados nos dados sem qualquer tipo de processamento referente à decomposição dos sinais e/ou extração de características, utilizando apenas as amostras de EEG correspondentes à 1 segundo de registro.

Um total de 10% do conjunto de dados foi previamente separado para validação final (com dados não vistos pelo modelo). Do restante, 70% foi utilizado para treinamento com validação cruzada, utilizando *k-fold* igual à 10, com os 30% remanescentes destinados ao teste.

## 7.6 Seleção do Classificador Final

A seleção do classificador final se deu através do retreinamento dos algoritmos utilizados na definição da linha de base no conjunto de dados composto pelas características extraídas com a rede *Inception* dos componentes de potência e fase decompostos dos sinais originais através da HHT. As mesmas configurações de treinamento utilizadas para determinação da linha de base foram replicadas para o classificador final.

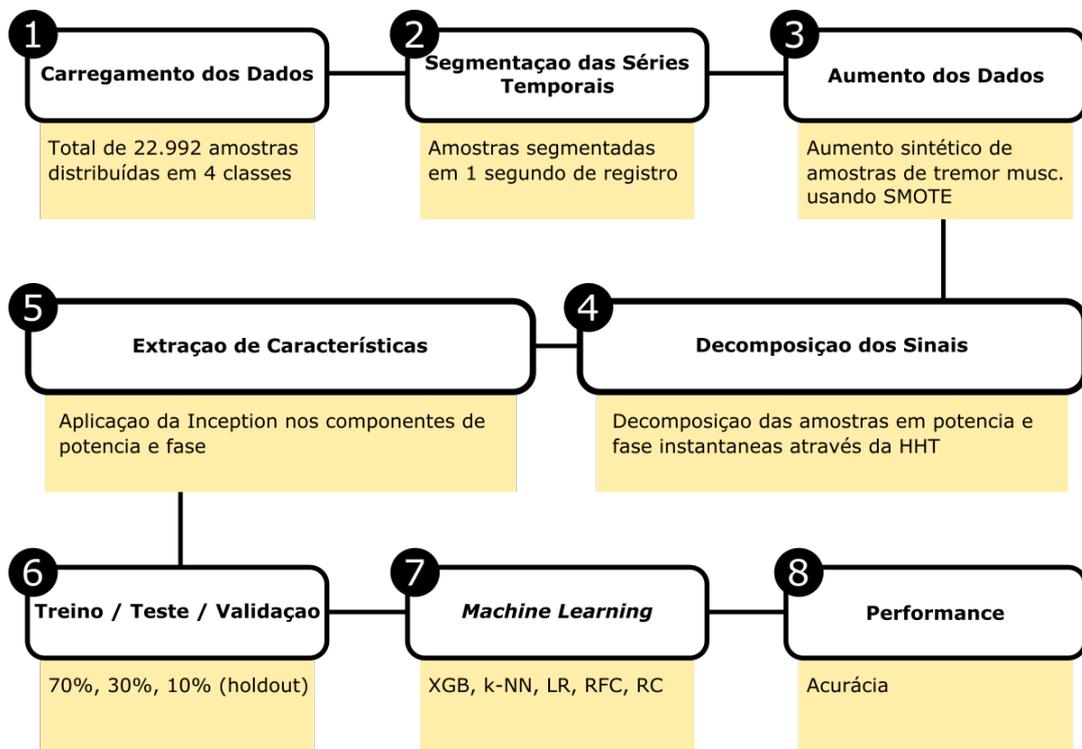
## 7.7 Teste Estatístico

Neste estudo utilizamos o teste ANOVA *One-way* para comparar as acurácias de cada instância de treinamento (*fold*), de cada modelo de aprendizado de máquina treinado antes da seleção do algoritmo final. O teste ANOVA foi aplicado através da biblioteca *Scipy*, e o nível de significância empregado neste estudo foi de 5%

## 7.8 Fluxo de Modelagem

Na figura 9 a seguir é exibido o fluxo de modelagem empregado neste estudo, desde a segmentação das séries temporais até a classificação pelo modelo final.

Figura 9. Fluxo de modelagem empregado neste estudo.



Fonte: Autor

## 7.9 Materiais e Instrumentos

Utilizamos a plataforma *Deepnote*, que disponibiliza diferentes tipos de máquinas virtuais em nuvem para modelagem dos mais variados tipos de projetos em ciência de dados, além de fornecerem um *Integrated Development Environment* (IDE) próprio, em Python 3.8, para desenvolvimento de projetos.

As especificações técnicas da máquina virtualizada em nuvem utilizada para este trabalho são: Linux Ubuntu 20.04 LTS; 60GB RAM; Processador Intel 2vCPU 2.50GHz, SSD 12GB, Placa de Vídeo Dedicada NVIDIA Tesla K80.

Para manipulação dos registros de EEG utilizamos a biblioteca MNE-Python (Gramfort et al., 2013), em sua versão 0.19.2.

Para modelagem dos algoritmos de aprendizado de máquina utilizamos a biblioteca PyCaret (Ali, 2020) em sua versão 2.3. Esta biblioteca contempla todos os principais frameworks e modelos de aprendizado de máquina considerados padrão-ouro no mercado, facilitando o processo de treinamento e comparação de performance destes algoritmos.

## 8 Resultados

### 8.1 Otimização da Extração de Características

Aplicamos um processo de otimização bayesiana em uma arquitetura base da rede *Inception*, composta de uma camada *bottleneck*, e uma camada *inception* ajustável em sua quantidade e em seus hiperparâmetros por camada. Os parâmetros otimizados resultantes estão listados na tabela 1 a seguir.

Tabela 1. Tabela de parâmetros otimizados da rede *Inception* utilizada para extração de características.

Parâmetros	Valores
Número de blocos <i>Inception</i>	2
Número de filtros	48
Tamanho dos filtros	4
Taxa de <i>dropout</i>	0.05
<i>Batch size</i>	8
Número de épocas	49

Fonte: Autor.

A taxa de erro alcançada pela arquitetura definida pelos parâmetros mostrados acima foi de 0.21.

### 8.2 Definição da Linha de Base do Classificador

As performances dos modelos k-NN, LR, RFC, RC e XGB obtidas no treinamento para definição da linha de base estão listadas na tabela 2 a seguir.

Tabela 2. Tabela comparativa das performances que determinam a linha de base da classificação.

Modelo	Acurácia	AUC	Recall	Precisão	F1	Kappa	MCC
<b>XGB</b>	0.8397	0.9555	0.6691	0.8307	0.8331	0.7447	0.7455
<b>RFC</b>	0.8189	0.9345	0.6348	0.8043	0.8090	0.7072	0.7086
<b>k-NN</b>	0.4674	0.7396	0.4002	0.6735	0.4698	0.2549	0.2915
<b>LR</b>	0.3205	0.5233	0.3067	0.3970	0.3419	0.0530	0.0559
<b>RC</b>	0.2964	0.0000	0.2976	0.3963	0.3235	0.0453	0.0487

Fonte: Autor.

Quando aplicado aos 30% de amostras para teste, o modelo XGB linha de base atingiu acurácia de 0.8489, e quando aplicado aos 10% de amostras não utilizadas, atingiu

acurácia de 0.8572, mantendo uma mesma performance em diferentes conjuntos de dados.

### 8.3 Seleção do Classificador Final

O retreino dos modelos utilizados para definição da linha de base nos dados processados pela HHT e pela rede *Inception* geraram as seguintes métricas apresentadas na tabela 3 a seguir.

Tabela 3. Tabela comparativa das performances atingidas pelos modelos treinados com validação cruzada para seleção do algoritmo final

<b>Modelo</b>	<b>Acurácia</b>	<b>AUC</b>	<b>Recall</b>	<b>Precisão</b>	<b>F1</b>	<b>Kappa</b>	<b>MCC</b>
<b>XGB</b>	0.9482	0.9948	0.9482	0.9483	0.9482	0.9309	0.9310
<b>RFC</b>	0.9335	0.9921	0.9336	0.9337	0.9335	0.9114	0.9115
<b>k-NN</b>	0.9251	0.9826	0.9252	0.9256	0.9246	0.9001	0.9006
<b>LR</b>	0.9148	0.9869	0.9149	0.9150	0.9145	0.8864	0.8866
<b>RC</b>	0.8620	0.0000	0.8623	0.8637	0.8587	0.8161	0.8186

Fonte: Autor.

Devido à utilização de uma base de dados perfeitamente balanceada, a acurácia pode ser adotada como uma métrica de avaliação de performance confiável.

O resultado do teste ANOVA *One-way* nas acurácias, por *fold*, dos modelos foi de 51.38 ( $p < 0.000$ ), e sugere que existe diferença estatística significativa entre as performances dos algoritmos testados, o que nos permite adotar o modelo XGB, apesar de sua maior complexidade, por este apresentar performance superior.

Quando aplicado aos 30% de amostras para teste, o modelo XGB atingiu acurácia de 0.9490, e quando aplicado aos 10% de amostras não utilizadas, atingiu acurácia de 0.9417, mantendo sua capacidade de generalização em diferentes conjuntos de dados.

### 8.3.1 Parâmetros do Classificador Final

Na tabela 4 a seguir estão listados os parâmetros do classificador final após o retreino.

Tabela 4. Tabela de parâmetros do classificador final

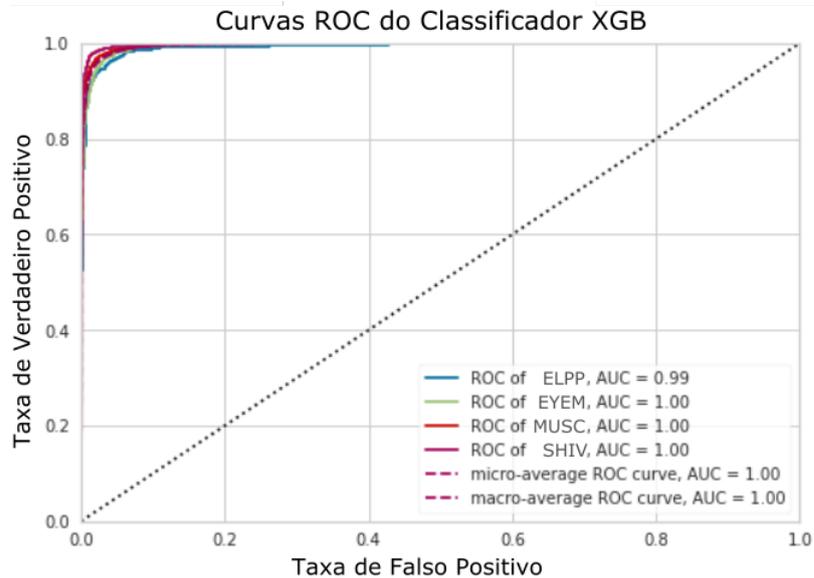
Parâmetros	Valores
Taxa de aprendizagem	0.3000
<i>Max depth</i>	6
Número de estimadores	100
<i>Random state</i>	42
<i>Alpha regularization</i>	0
<i>Lambda regularization</i>	1

Fonte: Autor.

### 8.3.2 Curvas ROC do Classificador Final

Na figura 10 a seguir podemos analisar a performance do classificador final por classe.

Figura 10. Curvas ROC do Classificador final, exibindo a performance por classe.



Fonte: Autor

Na figura 10 acima, ELPP refere à ruído eletrostático, EYEM à ruído gerado por movimento ocular, MUSC à ruído muscular e SHIV à ruído por tremor muscular.

## 8.4 XV Congresso Brasileiro de Inteligência Computacional 2021

Uma versão inicial deste trabalho foi aceita, apresentada e publicada no XV Congresso Brasileiro de Inteligência Computacional de 2021 (CBIC 2021) como artigo completo.

## 9 Conclusão

O presente estudo sugere que a aplicação de um modelo XGB em vetores de características extraídos a partir de uma arquitetura *Inception*, de componentes de potência e fase instantâneas obtidas através da HHT, é a melhor configuração de aprendizado de máquina para classificação de padrões artefatuais em registros de EEG de pacientes portadores de epilepsia.

Nossos resultados garantem boa precisão na detecção de padrões artefatuais em pacientes de diferentes sexos, idades e com diferentes comorbidades associadas, uma vez que todas estas especificidades foram modeladas em conjunto. Isto posto, nós consideramos o resultado como robusto, uma vez que foi capaz de ultrapassar consideravelmente a performance do modelo linha de base, com uma eficácia superior em cerca de 13%, indicando o impacto positivo que a aplicação da HHT e de uma rede *Inception* tem para este tipo de problema. Estes resultados são assegurados não só pelas regras de validação do modelo durante e após o treinamento, mas também pelo teste ANOVA feito nas métricas resultantes. O modelo conta com boa acurácia e mantém uma mesma capacidade de generalização em diferentes conjuntos de dados.

Ainda que contando com uma excelente capacidade de generalização e com boas métricas de performance no treinamento, a acurácia global do modelo ainda pode ser melhorada, uma vez que a arquitetura *Inception* utilizada para extração de características alcançou erro na validação de 0.21, métrica que pode ser melhorada aumentando a quantidade de parâmetros ajustáveis durante o processo de otimização bayesiana, o que consequentemente aumenta consideravelmente o tempo de duração desta etapa.

## 10 Cronograma

Tabela 5. Cronograma de execução do projeto em 2019

2019										
Atividades	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
Revisão Bibliográfica	X	X	X	X	X	X	X	X	X	X
Aquisição de Dados	X									
Escrita do Projeto						X	X	X	X	X

Fonte: Autor.

Tabela 6. Cronograma de execução do projeto em 2020

2020												
Atividades	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
Revisão Bibliográfica	X	X	X	X	X	X	X	X	X	X	X	X
Processamento dos Dados	X	X	X	X	X							
Modelagem dos Dados	X	X	X	X	X	X	X	X	X	X	X	X
Testes e Otimização	X	X	X	X	X	X	X	X	X	X	X	X

Fonte: Autor.

Tabela 7. Cronograma de execução do projeto em 2021

2021											
Atividades	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov
Revisão Bibliográfica	X	X	X	X	X	X	X	X	X	X	X
Testes e Otimização	X	X	X	X	X	X	X	X	X	X	X
Escrita da Qualificação			X	X	X						
Revisão da Qualificação						X	X	X			
Qualificação								X			

Fonte: Autor.

Tabela 8. Cronograma de execução do projeto em 2022

2022			
<b>Atividades</b>	Jan	Fev	Mar
Revisão Bibliográfica	X	X	X
Testes e Otimização	X	X	
Escrita da Versão Final			X
Revisão da Versão Final			X
Defesa da Dissertação			X

Fonte: Autor.

## Referências

- Abbasi, B., & Goldenholz, D. M. (2019). Machine learning applications in epilepsy. *Epilepsia*, *60*(10), 2037–2047. Citado 2 vezes nas páginas 20 e 21.
- Acharya, U. R., Oh, S. L., Hagiwara, Y., Tan, J. H., & Adeli, H. (2018). Deep convolutional neural network for the automated detection and diagnosis of seizure using eeg signals. *Computers in biology and medicine*, *100*, 270–278. Citado na página 15.
- Adeli, H., Zhou, Z., & Dadmehr, N. (2003). Analysis of eeg records in an epileptic patient using wavelet transform. *Journal of neuroscience methods*, *123*(1), 69–87. Citado na página 13.
- Ali, M. (2020, July). Pycaret: An open source, low-code machine learning library in python [Computer software manual]. Retrieved from <https://www.pycaret.org> (PyCaret version 2.3) Citado na página 34.
- Anastasiadou, M., Hadjipapas, A., Christodoulakis, M., Papathanasiou, E. S., Papacostas, S. S., & Mitsis, G. D. (2014). Detection and removal of muscle artifacts from scalp eeg recordings in patients with epilepsy. In *2014 IEEE International Conference on Bioinformatics and Bioengineering* (pp. 291–296). Citado na página 17.
- Bastos, N. S., Marques, B. P., Adamatti, D. F., & Billa, C. Z. (2020). Analyzing eeg signals using decision trees: A study of modulation of amplitude. *Computational Intelligence and Neuroscience*, *2020*. Citado na página 17.
- Biasiucci, A., Franceschiello, B., & Murray, M. M. (2019). Electroencephalography. *Current Biology*, *29*(3), R80–R85. Citado na página 19.
- Chatrian, G. E., Lettich, E., & Nelson, P. L. (1985). Ten percent electrode system for topographic studies of spontaneous and evoked eeg activities. *American Journal of EEG technology*, *25*(2), 83–92. Citado na página 27.
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). Smote: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, *16*, 321–357. Citado na página 28.
- Čukić, M., Stokić, M., Simić, S., & Pokrajac, D. (2020). The successful discrimination of depression from eeg could be attributed to proper feature extraction and not to a particular classification method. *Cognitive Neurodynamics*, *14*(4), 443–455. Citado na página 23.
- Fahim, S. R., Sarker, Y., Sarker, S. K., Sheikh, M. R. I., & Das, S. K. (2020). Self attention convolutional neural network with time series imaging based feature extraction for transmission line fault detection and classification. *Electric Power Systems Research*, *187*, 106437. Citado na página 17.
- Fisher, R. S., Boas, W. V. E., Blume, W., Elger, C., Genton, P., Lee, P., & Engel Jr, J. (2005). Epileptic seizures and epilepsy: definitions proposed by the international league against epilepsy (ilae) and the international bureau for epilepsy (ibe). *Epilepsia*, *46*(4), 470–472. Citado 2 vezes nas páginas 13 e 18.

- Frazier, P. I. (2018). A tutorial on bayesian optimization. *arXiv preprint arXiv:1807.02811*. Citado na página 32.
- Gao, Y., Gao, B., Chen, Q., Liu, J., & Zhang, Y. (2020). Deep convolutional neural network-based epileptic electroencephalogram (eeg) signal classification. *Frontiers in neurology*, *11*, 375. Citado na página 22.
- Gramfort, A., Luessi, M., Larson, E., Engemann, D. A., Strohmeier, D., Brodbeck, C., ... Hämäläinen, M. S. (2013). MEG and EEG data analysis with MNE-Python. *Frontiers in Neuroscience*, *7*(267), 1–13. doi: 10.3389/fnins.2013.00267 Citado na página 34.
- Harpale, V. K., & Bairagi, V. K. (2016). Time and frequency domain analysis of eeg signals for seizure detection: A review. In *2016 international conference on microelectronics, computing and communications (microcom)* (pp. 1–6). Citado na página 13.
- Huang, N. E., Shen, Z., Long, S. R., Wu, M. C., Shih, H. H., Zheng, Q., ... Liu, H. H. (1998). The empirical mode decomposition and the hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society of London. Series A: mathematical, physical and engineering sciences*, *454*(1971), 903–995. Citado 2 vezes nas páginas 16 e 29.
- Ibrahim, S., Djemal, R., & Alsuwailem, A. (2018). Electroencephalography (eeg) signal processing for epilepsy and autism spectrum disorder diagnosis. *Biocybernetics and Biomedical Engineering*, *38*(1), 16–26. Citado 2 vezes nas páginas 19 e 20.
- Islam, M. K., Rastegarnia, A., & Yang, Z. (2015). A wavelet-based artifact reduction from scalp eeg for epileptic seizure detection. *IEEE journal of biomedical and health informatics*, *20*(5), 1321–1332. Citado na página 14.
- Islam, M. S., El-Hajj, A. M., Alawieh, H., Dawy, Z., Abbas, N., & El-Imad, J. (2020). Eeg mobility artifact removal for ambulatory epileptic seizure prediction applications. *Biomedical Signal Processing and Control*, *55*, 101638. Citado na página 14.
- Jiang, X., Bian, G.-B., & Tian, Z. (2019). Removal of artifacts from eeg signals: a review. *Sensors*, *19*(5), 987. Citado 2 vezes nas páginas 15 e 16.
- Khazi, M., Kumar, A., & Vidya, M. (2012). Analysis of eeg using 10: 20 electrode system. *International Journal of Innovative Research in Science, Engineering and Technology*, *1*(2), 185–191. Citado na página 27.
- Lai, C. Q., Ibrahim, H., Abdullah, M. Z., Abdullah, J. M., Suandi, S. A., & Azman, A. (2018). Artifacts and noise removal for electroencephalogram (eeg): A literature review. In *2018 ieee symposium on computer applications & industrial electronics (iscae)* (pp. 326–332). Citado 3 vezes nas páginas 13, 14 e 16.
- Levitt, J., Nitenson, A., Koyama, S., Heijmans, L., Curry, J., Ross, J. T., ... Saab, C. Y. (2018). Automated detection of electroencephalography artifacts in human, rodent and canine subjects using machine learning. *Journal of neuroscience methods*, *307*, 53–59. Citado na página 14.

- Liu, D. C., & Nocedal, J. (1989). On the limited memory bfgs method for large scale optimization. *Mathematical programming*, 45(1), 503–528. Citado na página 32.
- Lotte, F., Congedo, M., Lécuyer, A., Lamarche, F., & Arnaldi, B. (2007). A review of classification algorithms for eeg-based brain–computer interfaces. *Journal of neural engineering*, 4(2), R1. Citado na página 16.
- Noachtar, S., & Rémi, J. (2009). The role of eeg in epilepsy: a critical review. *Epilepsy & Behavior*, 15(1), 22–33. Citado na página 13.
- Radüntz, T., Scouten, J., Hochmuth, O., & Meffert, B. (2017). Automated eeg artifact elimination by applying machine learning algorithms to ica-based features. *Journal of neural engineering*, 14(4), 046004. Citado na página 15.
- Raghu, S., Sriraam, N., Temel, Y., Rao, S. V., & Kubben, P. L. (2020). Eeg based multi-class seizure type classification using convolutional neural network and transfer learning. *Neural Networks*, 124, 202–212. Citado na página 22.
- Ramaneswaran, S., Srinivasan, K., Vincent, P., & Chang, C.-Y. (2021). Hybrid inception v3 xgboost model for acute lymphoblastic leukemia classification. *Computational and Mathematical Methods in Medicine*, 2021. Citado na página 17.
- Smith, S. J. (2005). Eeg in the diagnosis, classification, and management of patients with epilepsy. *Journal of Neurology, Neurosurgery & Psychiatry*, 76(suppl 2), ii2–ii7. Citado 2 vezes nas páginas 13 e 17.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the ieee conference on computer vision and pattern recognition* (pp. 1–9). Citado na página 31.
- Tzallas, A. T., Tsipouras, M. G., & Fotiadis, D. I. (2009). Epileptic seizure detection in eegs using time–frequency analysis. *IEEE transactions on information technology in biomedicine*, 13(5), 703–710. Citado na página 17.
- Wang, H., & Ji, Y. (2018). A revised hilbert–huang transform and its application to fault diagnosis in a rotor system. *Sensors*, 18(12), 4329. Citado 3 vezes nas páginas 16, 29 e 30.
- Yang, L., Li, Y., & Di, C. (2019). Application of xgboost in identification of power quality disturbance source of steady-state disturbance events. In *2019 ieee 9th international conference on electronics information and emergency communication (iceiec)* (pp. 1–6). Citado na página 17.
- Yasoda, K., Ponnagall, R., Bhuvaneshwari, K., & Venkatachalam, K. (2020). Automatic detection and classification of eeg artifacts using fuzzy kernel svm and wavelet ica (wica). *Soft Computing*, 24(21), 16011–16019. Citado na página 22.
- Zheng, J., Liang, M., Sinha, S., Ge, L., Yu, W., Ekstrom, A., & Hsieh, F. (2021). time-frequency analysis of scalp eeg with hilbert-huang transform and deep learning. *IEEE journal of biomedical and health informatics*, 26(4), 1549–1559. Citado na página 16.