

Discriminação de Padrões Artefatuais em Eletroencefalografia de Pacientes com Epilepsia usando Algoritmo do Tipo Ensemble

Arthur Gonsales da Silva
Instituto de Ciências Biológicas
Universidade Federal do Pará
Belém, Brasil
gonzalezarthur@tuta.io

Gabriel Freitas Damasceno
Instituto de Ciências Biológicas
Universidade Federal do Pará
Belém, Brasil
gabriel.damasceno@icb.ufpa.br

Adrielle do Espírito Santo Macedo
Instituto de Ciências Biológicas
Universidade Federal do Pará
Belém, Brasil
adrielle.macedo@icb.ufpa.br

Fernando Allan de Farias Rocha
Instituto de Ciências Biológicas
Universidade Federal do Pará
Belém, Brasil
rochaf@ufpa.br

Bruno Duarte Gomes
Instituto de Ciências Biológicas
Universidade Federal do Pará
Belém, Brasil
brunodgomes@ufpa.br

Abstract—Em estudos de processamento digital de sinais e aprendizado de máquina aplicados a registros de Eletroencefalografia (EEG) de pacientes portadores de epilepsia, pesquisadores normalmente necessitam de um método automatizado e acurado para detectar e/ou discriminar padrões artefatuais em seguimentos de dados, uma vez que métodos manuais e baseados em conhecimento de domínio são altamente passíveis de erro e viés. Muitos métodos vem sendo empregados em tarefas de detecção e classificação de sinais de EEG, porém a grande maioria destas estratégias, quando consideradas de alta eficiência, requerem considerável poder de armazenamento e processamento computacionais, uma vez que dados de atividade neuronal possuem grande complexidade associada. Como uma alternativa à abordagens mais complexas, neste trabalho visamos desenvolver um método de mais baixo custo computacional para discriminação de padrões artefatuais em registros de EEG de pacientes com epilepsia, utilizando a Transformada de Hilbert-Huang (HHT) e um conjunto de estatísticas paramétricas e não paramétricas para extração de informação das amostras, juntamente com um modelo *ensemble*, baseado em Árvores de Decisão (AD) para discriminação entre três tipos diferentes de padrões artefatuais nos seguimentos de dados.

Index Terms—epilepsia, aprendizado de máquina, classificação, série temporal, eletroencefalografia

I. 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 [1].

Segundo [1], 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 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 demandam 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? [2].

A sensibilidade e especificidade do EEG depende 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 [2]. 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 [3].

Uma análise cuidadosa dos registros eletroencefalográficos pode promover *insights* valiosos e melhorar o entendimento dos mecanismos causadores da epilepsia [4]. O EEG registra várias frequências diferentes em sinais cerebrais não estacionários de diferentes canais distribuídos no escalpo [5].

O EEG bruto pode vir 'contaminado' com uma série de componentes indesejados, como ruídos e artefatos causados por fontes de energia, fortes 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 [6].

Na Figura 1 a seguir, [7] faz uma importante demonstração dos efeitos que os artefatos causam em sinais de EEG.




Fig. 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.

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. O maior risco deste método está na possibilidade de remoção acidental de trechos do EEG que não correspondem a artefatos, o que leva muitos pesquisadores a tratar o resultado desses métodos com inspeção visual. Esta, no entanto, é uma abordagem subjetiva, demorada e não confiável, especialmente por conta da natureza altamente transitória do EEG [8].

A análise de componentes independentes (ICA - *Independent component analysis*) é um dos métodos mais utilizados para remoção de artefatos de registros de EEG, 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 [9].

Na Figura 2, [10] mostra a porcentagem de estudos nos últimos cinco anos (a contar de 2019), segundo o método de tratamento de artefatos usado. Os algoritmos mais utilizados são aqueles baseados em *Blind Source Separation* (BSS), especialmente o ICA [10].

Apesar das extensivas pesquisas no campo da detecção e remoção de artefatos de sinais de EEG reportadas na literatura

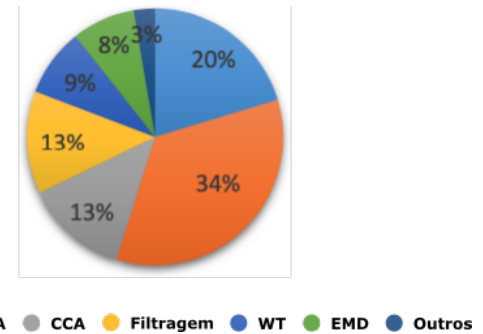


Fig. 2. Gráfico da porcentagem de referências publicadas, por tipo de método, no campo da remoção de artefatos nos últimos cinco anos (a contar de 2019).

até agora, não existe um consenso geral de uma solução ótima para todos os tipos de artefatos existentes [10]. A tendência atual da detecção e remoção de artefatos utiliza aprendizado de máquina para fornecer soluções automatizadas com maior eficiência [6].

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, realizar 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 [11].

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 a mais na análise [12]. A transformada de Fourier janelada, por sua vez, é baseada na transformada de Fourier tradicional, sendo um método linear de análise [12].

Em [13], os autores desenvolveram 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). 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 Wavelete e de Fourier.

A. Algoritmos de Classificação e as Árvores de Decisão

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 [14].

Muitos algoritmos para classificação foram propostos na literatura, incluindo abordagens miméticas e baseadas em redes, métodos tempo-frequência, transformada Wavelet, redes neurais artificiais, ICA, *support vector machines*, mineração de dados, correspondência de modelos e classificação topográfica [15].

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 dos dados analisados (e na maioria das vezes, não importando também que distribuição estatística esses dados seguem). Árvores de decisão (AD) são algoritmos de aprendizagem de máquina pertencentes à classe dos modelos de aprendizado supervisionado. Modelos AD dividem problemas complexos em diversos subproblemas de complexidade menor, repetindo este processo recursivamente para gerar uma árvore capaz de emitir uma predição para a modelagem do problema em questão [16].

Em uma AD, cada nó recebe um rótulo de classe, nós não terminais, o que inclui o nó raiz e outros nós internos, contém testes condicionais para atributos dos dados de entrada para que amostras com diferentes características sejam separadas e classificadas de acordo [16].

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 EEG [17]. Muitas síndromes epiléticas são associadas com características específicas do EEG, algumas bem aceitas, outras ainda não incluídas no sistema de classificação atual da *International League Against Epilepsy* (ILAE), devido à quantidade insuficiente de dados [3].

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 [1].

II. TRABALHOS RELACIONADOS

No artigo [18], os autores utilizaram a mesma base de dados utilizada neste trabalho para propor uma arquitetura de *Convolutional Neural Network* (CNN) com *transfer learning* 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 no trabalho [19]. No artigo 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 *brain-computer interface* 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 no trabalho [20]. Nesta abordagem os autores primeiramente transformam os sinais de EEG em *power spectrum density energy diagrams* e então treinam uma CNN com *transfer learning* para classificar quatro diferentes estados de epilepsia. A acurácia final alcançada pelo modelo proposto pelos autores é de 92.5%

III. METODOLOGIA

A. Seleção de 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.

B. 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 [21].

Na Figura 3 a seguir, uma representação gráfica do sistema 10-20 feita por [22] é demonstrada.




Fig. 3. Representação diagramática da localização dos eletrodos no sistema 10-20, padronizado internacionalmente para registro clínico de EEG.

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 três series temporais, cada uma correspondente a uma classe da modelagem.

As três series temporais resultantes do processo de concatenação foram então segmentadas em amostras de 250 pontos, correspondentes a um segundo de registro, e então separadas em suas devidas classes, sendo estas: a) movimento ocular, b) ruído eletrostático e c) movimento muscular, o que resultou em uma base de dados final de 5162 amostras, sendo 33.1% destas classificadas como ruído eletrostático, 33.9% classificadas como movimento ocular e 33% classificadas como movimento muscular.

A Figura 4 a seguir mostra uma amostra randômica retirada da base de dados sem a aplicação de qualquer técnica de processamento e/ou extração de características, sendo apenas um registro correspondente à um segundo de atividade neuronal.




Fig. 4. Amostra randômica coletada da base de dados sem qualquer procedimento de extração de características aplicado.

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 HHT para decomposição das amostras.

C. Extração de Características

A HHT 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 [12].

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 HHT, como mostrado na equação abaixo [12]:

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

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

$$z_j(t) = c_j(t) + ic_j(t) = a_j(t) \times e^{i\theta_j(t)} \quad (2)$$

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 [12]:

$$a_j(t) = [c_j^2(t) + c_j^2(t)]^{1/2}, \theta_j(t) = \arctan\left(\frac{c_j(t)}{c_j(t)}\right) \quad (3)$$

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 $c_j(t)$ [12].

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 4.




Fig. 5. Representação gráfica de potência e fase instantâneas extraídas da amostra exibida anteriormente através da HHT.

Segundo [23], estatísticas paramétricas podem produzir resultados relativamente satisfatórios quando seguimentos de EEG respeitam alguns critérios específicos, em especial, quando estes possuem relativo baixo número de pontos de dados. Com base nisso calculamos quinze preditores que incluem estatísticas paramétricas e não paramétricas, bem como características baseadas em entropia, uma vez que, segundo descrito em [24], algumas destas informações baseadas em entropia tem demonstrado alta performance na caracterização de mudanças em sinais de EEG.

- Média
- Mediana
- Valor mínimo
- Valor máximo
- Desvio absoluto médio
- Desvio padrão
- Variância
- Raiz quadrada média
- Derivação média (ordem = 1)
- *Skew*
- *Kurtosis*
- *Interquartile range* (IQR)
- Cruzamentos em zero (zero crossing rate)
- Entropia Espectral de Fourier
- Entropia Espectral de Welch

Com isso concluímos a etapa de extração de características, tanto para potência quanto para fase, com um conjunto de dados de 5162 amostras de dimensões [1 x 30] cada, sem normalização e sem remoção de valores extremos.

D. Treinamento do Modelo

Como mencionado anteriormente, neste trabalho optamos por utilizar um modelo classificador *ensemble*, baseado em AD, devido à sua excelente performance em diversas competições de aprendizado de máquina, bem como sua adaptabilidade à dados perdidos ou extremos, sendo esta última característica um padrão em dados de EEG.

Um total de 70% dos dados foram utilizados para treinamento com *cross-validation*, sendo os 30% restantes utilizados para validação *hold-out* do algoritmo. A otimização se deu através do algoritmo *RandomSearchCV*, com $k\text{-fold} = 10$.

E. Materiais e Instrumentos

Foi utilizada neste trabalho como principal ferramenta para modelagem dos dados a plataforma para ciência de dados *Deepnote*. O *Deepnote* disponibiliza diferentes tipos de máquinas virtuais em nuvem para modelagem dos mais variados tipos de projetos em ciência de dados, além de fornecer uma *integrated development environment* (IDE) própria para Python.

As especificações técnicas da máquina virtualizada em nuvem utilizada para este trabalho são: Linux Ubuntu 20.04 LTS; 2GB RAM; Processador Intel 2vCPU 2.50GHz, SSD 5GB. Todos os processamentos, experimentos e resultados foram geridos e gerados neste equipamento, sendo em todas

as etapas de execução do projeto utilizada a linguagem de programação Python, em sua versão 3.7.

Para carregamento, inspeção visual e segmentação das amostras de sinais foi utilizada a biblioteca MNE-Python [25], em sua versão 0.19.2. Esta biblioteca é direcionada para manipulação de séries temporais, principalmente relacionadas a eventos biológicos no campo das neurociências.

Para treinamento e validação dos modelos de aprendizado de máquina analisados neste trabalho foi utilizada a biblioteca PyCaret [26] em sua versão 2.0. Esta biblioteca contempla todos os principais *frameworks* e modelos considerados padrão-ouro no mercado, sendo assim facilitado o processo de treinamento e comparação de performance destes algoritmos.

IV. RESULTADOS PRELIMINARES

Nas tabelas I e II, são exibidas, respectivamente, a comparação de performance entre cinco modelos baseados em AD treinados no experimento, ranqueados por performance, tendo o modelo XGBoost a melhor performance, e os hiperparâmetros otimizados do modelo vencedor, que podem ser utilizados para replicação do estudo.

As Figuras 6 e 7 a seguir mostram, respectivamente, as curvas ROC e uma matriz de confusão, dois populares métodos de avaliação que permitem um entendimento mais profundo da performance do modelo.

A. Comparação de Modelos

TABLE I
TABELA COMPARATIVA DE PERFORMANCE DOS CINCO PRIMEIROS MODELOS BASEADOS EM AD TREINADOS.

Modelo	Acurácia	AUC	<i>Recall</i>	Precisão	F1
XGBoost	0.9004	0.0000	0.9004	0.9033	0.9005
LightGBM	0.8968	0.0000	0.8968	0.9003	0.8969
GBC	0.8958	0.0000	0.8958	0.8983	0.8958
CatBoost	0.8958	0.0000	0.8957	0.9003	0.8960
ETC	0.8903	0.0000	0.8902	0.8942	0.8903

B. Hiperparâmetros do Modelo XGBoost

TABLE II
GRADE DE HIPERPARÂMETROS OTIMIZADOS DO MODELO XGBOOST ENCONTRADOS ATRAVÉS DO ALGORITMO *RandomSearchCV*

Parâmetros	Valores
<i>criterion</i>	<i>gini</i>
<i>max_depth</i>	6
<i>learning_rate</i>	0.3
<i>number of estimators</i>	100

C. Curvas ROC




Fig. 6. Curvas ROC para análise da performance do classificador por classe modelada.

D. Matriz de Confusão

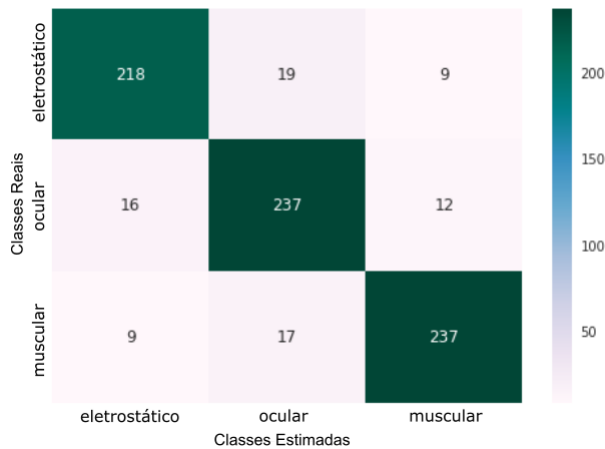


Fig. 7. Matriz de confusão para avaliação da quantidade de acertos e erros do modelo por classe, nos dados de validação hold-out.

V. CONCLUSÃO

Como mostrado na Figura 6, os valores de *AUC score* para ruído eletrostático, movimento ocular e movimento muscular foram, respectivamente, de 96% 97% e 98% o que denota estabilidade no treinamento e performance classe a classe.

Na matriz de confusão apresentada na Figura 7, vemos que, ainda que de maneira leve, a classe de movimento ocular foi a que mais provocou 'confusão' no modelo, uma vez que dezoito amostras de ruídos eletrostáticos e dezessete amostras de ruídos musculares foram classificadas como movimento ocular, sendo estes números os maiores em erro.

Dessa forma podemos concluir que, o modelo XGBoost treinado até aqui, utilizando como amostras, estatísticas paramétricas, não paramétricas e baseadas em entropia dos componentes de potência e fase instantâneas, extraídos através

da HHT de seguimentos artefatuais de EEG de pacientes portadores de epilepsia, atingiu performance satisfatória preliminarmente, uma vez que, para além de classificar seguimentos artefatuais de pacientes sem comorbidades, este modelo é capaz de manter boa performance preditiva quando analisando amostras de pacientes com diferentes doenças associadas que podem ou não ter impacto no padrão de ativação neuronal.

O resultado desta modelagem pode ser justificado por algumas das propriedades de treinamento do próprio modelo XGBoost, que segundo parui2019emotion, além de uma implementação mais eficaz do algoritmo de descida de gradiente, possui capacidade de computar cálculos de forma paralela e distribuída, o que torna este modelo extremamente popular no campo da ciência de dados devido à sua alta eficiência.

REFERÊNCIAS

- [1] R. S. Fisher, W. V. E. Boas, W. Blume, C. Elger, P. Genton, P. Lee, and J. Engel Jr, "Epileptic seizures and epilepsy: definitions proposed by the international league against epilepsy (ilae) and the international bureau for epilepsy (ibe)," *Epilepsia*, vol. 46, no. 4, pp. 470–472, 2005.
- [2] S. Noachtar and J. Rémi, "The role of eeg in epilepsy: a critical review," *Epilepsy & Behavior*, vol. 15, no. 1, pp. 22–33, 2009.
- [3] S. J. Smith, "Eeg in the diagnosis, classification, and management of patients with epilepsy," *Journal of Neurology, Neurosurgery & Psychiatry*, vol. 76, no. suppl 2, pp. ii2–ii7, 2005.
- [4] H. Adeli, Z. Zhou, and N. Dadmehr, "Analysis of eeg records in an epileptic patient using wavelet transform," *Journal of neuroscience methods*, vol. 123, no. 1, pp. 69–87, 2003.
- [5] V. K. Harpale and V. K. Bairagi, "Time and frequency domain analysis of eeg signals for seizure detection: A review," in *2016 International Conference on Microelectronics, Computing and Communications (MicroCom)*. IEEE, 2016, pp. 1–6.
- [6] C. Q. Lai, H. Ibrahim, M. Z. Abdullah, J. M. Abdullah, S. A. Suandi, and A. Azman, "Artifacts and noise removal for electroencephalogram (eeg): A literature review," in *2018 IEEE Symposium on Computer Applications & Industrial Electronics (ISCAIE)*. IEEE, 2018, pp. 326–332.
- [7] M. K. Islam, A. Rastegarnia, and Z. Yang, "A wavelet-based artifact reduction from scalp eeg for epileptic seizure detection," *IEEE journal of biomedical and health informatics*, vol. 20, no. 5, pp. 1321–1332, 2015.
- [8] J. Levitt, A. Nitenson, S. Koyama, L. Heijmans, J. Curry, J. T. Ross, S. Kamberling, and C. Y. Saab, "Automated detection of electroencephalography artifacts in human, rodent and canine subjects using machine learning," *Journal of neuroscience methods*, vol. 307, pp. 53–59, 2018.
- [9] T. Radüntz, J. Scouten, O. Hochmuth, and B. Meffert, "Automated eeg artifact elimination by applying machine learning algorithms to ica-based features," *Journal of neural engineering*, vol. 14, no. 4, p. 046004, 2017.
- [10] X. Jiang, G.-B. Bian, and Z. Tian, "Removal of artifacts from eeg signals: a review," *Sensors*, vol. 19, no. 5, p. 987, 2019.
- [11] U. R. Acharya, S. L. Oh, Y. Hagiwara, J. H. Tan, and H. Adeli, "Deep convolutional neural network for the automated detection and diagnosis of seizure using eeg signals," *Computers in biology and medicine*, vol. 100, pp. 270–278, 2018.
- [12] H. Wang and Y. Ji, "A revised hilbert–huang transform and its application to fault diagnosis in a rotor system," *Sensors*, vol. 18, no. 12, p. 4329, 2018.
- [13] N. E. Huang, Z. Shen, S. R. Long, M. C. Wu, H. H. Shih, Q. Zheng, N.-C. Yen, C. C. Tung, and H. H. Liu, "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*, vol. 454, no. 1971, pp. 903–995, 1998.
- [14] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche, and B. Arnaldi, "A review of classification algorithms for eeg-based brain–computer interfaces," *Journal of neural engineering*, vol. 4, no. 2, p. R1, 2007.

- [15] A. T. Tzallas, M. G. Tsipouras, and D. I. Fotiadis, "Epileptic seizure detection in eegs using time–frequency analysis," *IEEE transactions on information technology in biomedicine*, vol. 13, no. 5, pp. 703–710, 2009.
- [16] N. S. Bastos, B. P. Marques, D. F. Adamatti, and C. Z. Billa, "Analyzing eeg signals using decision trees: A study of modulation of amplitude," *Computational Intelligence and Neuroscience*, vol. 2020, 2020.
- [17] M. Anastasiadou, A. Hadjipapas, M. Christodoulakis, E. S. Papathanasiou, S. S. Papacostas, and G. D. Mitsis, "Detection and removal of muscle artifacts from scalp eeg recordings in patients with epilepsy," in *2014 IEEE International Conference on Bioinformatics and Bioengineering*. IEEE, 2014, pp. 291–296.
- [18] S. Raghu, N. Sriraam, Y. Temel, S. V. Rao, and P. L. Kubben, "Eeg based multi-class seizure type classification using convolutional neural network and transfer learning," *Neural Networks*, vol. 124, pp. 202–212, 2020.
- [19] K. Yasoda, R. Ponmagal, K. Bhuvaneshwari, and K. Venkatachalam, "Automatic detection and classification of eeg artifacts using fuzzy kernel svm and wavelet ica (wica)," *Soft Computing*, vol. 24, no. 21, pp. 16 011–16 019, 2020.
- [20] Y. Gao, B. Gao, Q. Chen, J. Liu, and Y. Zhang, "Deep convolutional neural network-based epileptic electroencephalogram (eeg) signal classification," *Frontiers in neurology*, vol. 11, p. 375, 2020.
- [21] G. E. Chatrian, E. Lettich, and P. L. Nelson, "Ten percent electrode system for topographic studies of spontaneous and evoked eeg activities," *American Journal of EEG technology*, vol. 25, no. 2, pp. 83–92, 1985.
- [22] M. Khazi, A. Kumar, and M. Vidya, "Analysis of eeg using 10: 20 electrode system," *International Journal of Innovative Research in Science, Engineering and Technology*, vol. 1, no. 2, pp. 185–191, 2012.
- [23] S.-Y. Tseng, R.-C. Chen, F.-C. Chong, and T.-S. Kuo, "Evaluation of parametric methods in eeg signal analysis," *Medical engineering & physics*, vol. 17, no. 1, pp. 71–78, 1995.
- [24] I. B. Slimen, L. Boubchir, Z. Mbarki, and H. Seddik, "Eeg epileptic seizure detection and classification based on dual-tree complex wavelet transform and machine learning algorithms," *Journal of biomedical research*, vol. 34, no. 3, p. 151, 2020.
- [25] A. Gramfort, M. Luessi, E. Larson, D. A. Engemann, D. Strohmeier, C. Brodbeck, R. Goj, M. Jas, T. Brooks, L. Parkkonen, and M. S. Hämäläinen, "MEG and EEG data analysis with MNE-Python," *Frontiers in Neuroscience*, vol. 7, no. 267, pp. 1–13, 2013.
- [26] M. Ali, *PyCaret: An open source, low-code machine learning library in Python*, July 2020, pyCaret version 2.3. [Online]. Available: <https://www.pycaret.org>