

Detecção de epilepsia em eletroencefalogramas utilizando redes neurais convolucionais reduzidas

Epilepsy detection in electroencephalogram using reduced convolutional neural networks

Deteccción de epilepsia mediante electroencefalogramas usando redes neuronales convolucionales reducidas

Luiz Antonio Nicolau Anghinoni¹, Marcelo Teixeira², Marco Antonio de Castro Barbosa³,
Dalcimar Casanova², Jefferson Tales Oliva²

1 Bacharel, Programa de Pós-Graduação em Engenharia Elétrica e Computação, Universidade Tecnológica Federal do Paraná, Pato Branco (PR), Brasil.


2 Doutor, Programa de Pós-Graduação em Engenharia Elétrica e Computação, Universidade Tecnológica Federal do Paraná, Pato Branco (PR), Brasil.

3 Doutor, Programa de Pós-Graduação em Engenharia de Produção e Sistemas, Universidade Tecnológica Federal do Paraná, Pato Branco (PR), Brasil.

Autor correspondente: Luiz A. N. Anghinoni
E-mail: luizantonio.na@hotmail.com

Resumo

Objetivo: Criação e comparação de modelos de aprendizado profundo a partir de segmentos de eletroencefalogramas (EEG) representados no domínio de tempo e de frequência para a detecção de epilepsia. **Método:** Foram implementados e avaliados dois modelos de Redes Neurais Convolucionais, sendo cada um alimentado por dados de eletroencefalografia em diferentes domínios (tempo e frequência). **Resultados:** Os modelos avaliados apresentaram acurácia média entre 73,37% e 82,08%. O modelo treinado a partir de EEG representado no domínio de frequência atingiu maiores valores para todas as métricas. Com a aplicação do teste estatístico de hipótese U de Mann-Whitney, considerando um nível de significância de 5%, foi evidenciado diferença estatisticamente significativa entre os modelos. **Conclusão:** Os resultados apontam que o modelo treinado com segmentos EEG representados em frequência teve desempenho promissor na detecção de crises epiléticas. Adicionalmente, mesmo que a arquitetura



dos modelos desenvolvidos sejam mais simples em comparação com trabalhos relacionados, foram atingidos resultados competitivos.

Descritores: Epilepsia; Eletroencefalografia; Aprendizado Profundo


Abstract

Objective: Creation and comparison of deep learning models based on electroencephalogram (EEG) segments represented in time and frequency domain for the detection of epilepsy. **Method:** Two Convolutional Neural Network models were implemented and evaluated, each fed by electroencephalography data in different domains (time and frequency). **Results:** The models evaluated showed average accuracy between 73.37% and 82.08%. The model trained from EEG represented in the frequency domain achieved higher values for all metrics. By applying the Mann-Whitney U hypothesis statistical test, considering a significance level of 5%, a statistically significant difference was evidenced between the models. **Conclusion:** The results indicate that the model trained with EEG segments represented in frequency had promising performance in detecting epileptic seizures. Additionally, even though the architecture of the developed models is simpler compared to related works, competitive results were achieved.

Keywords: Epilepsy; Electroencephalography; Deep Learning

Resumen

Objetivo: Creación y comparación de modelos de aprendizaje profundo basados en segmentos de electroencefalograma (EEG) representados en el dominio de tiempo y frecuencia para la detección de epilepsia. **Método:** Se implementaron y evaluaron dos modelos de redes neuronales convolucionales, cada uno alimentado por datos de electroencefalografía en diferentes dominios (tiempo y frecuencia). **Resultados:** Los modelos evaluados mostraron una precisión promedio entre 73,37% y 82,08%. El modelo entrenado a partir de EEG representado en el dominio de la frecuencia logró valores más altos para todas las métricas. Al aplicar la prueba estadística de hipótesis U de Mann-Whitney, considerando un nivel de significancia del 5%, se evidenció diferencia estadísticamente significativa entre los modelos. **Conclusión:** Los resultados indican que el modelo entrenado con segmentos de EEG representados en frecuencia tuvo un



rendimiento prometedor en la detección de ataques epilépticos. Además, aunque la arquitectura de los modelos desarrollados es más simple en comparación con trabajos relacionados, se lograron resultados competitivos.

Descritores: Epilepsia; Electroencefalografía; Aprendizaje Profundo


Introdução

A epilepsia é um distúrbio neurológico caracterizado pela atividade cerebral anormal, que pode causar convulsões, comportamentos incomuns e até a perda de consciência. Esse distúrbio é considerado uma das enfermidades cerebrais mais comuns, afetando cerca de 50 milhões de pessoas em todo o mundo, dos quais aproximadamente 40% não respondem a medicamentos anti-convulsivos ⁽¹⁾.

O diagnóstico da epilepsia é estabelecido com base em informações clínicas, histórico do paciente, observação das crises epilépticas e realização de exames complementares, como as técnicas de neuroimagem ⁽²⁾. Dentre esses exames complementares, exemplos incluem a ressonância magnética, magnetoencefalografia, tomografia por emissão de pósitrons e a eletroencefalografia (EEG) ⁽²⁾.

A eletroencefalografia possui as seguintes vantagens em relação aos demais exames: é um método não invasivo; possui excelente resolução; e possui baixo custo em comparação com outros exames ⁽³⁾. A eletroencefalografia consiste em um método de monitoramento da atividade elétrica cerebral por meio de eletrodos posicionados no couro cabeludo do paciente. Como resultado desse exame, é gerado o eletroencefalograma (EEG), que consiste em uma série temporal, univariada ou multivariada, onde são registrados potenciais elétricos referentes à atividade neurológica ⁽³⁾.

Apesar da relevância do EEG no diagnóstico de enfermidades neurológicas, cada exame de EEG gera uma quantidade abundante de dados que, em conjunto, inviabilizam a análise manual por profissionais da área da saúde, os quais em geral se atêm aos aspectos mais gerais de análise. Além disso, um mesmo padrão de sinais em um EEG pode induzir a opiniões divergentes entre os especialistas, o que evidencia a dificuldade da análise desses sinais, mesmo que por profissionais experientes ⁽⁴⁾.




A literatura investiga diferentes formas de pré-processamento e também de métodos de aprendizado. Porém, há uma ausência de trabalhos que demonstrem quais formas de representação de EEG são mais efetivas na criação de modelos por meio de métodos de aprendizado profundo para auxiliar no diagnóstico da epilepsia. Nesse sentido, este trabalho se propõe a criar e comparar modelos computacionais que explorem segmentos de EEG em diferentes domínios (tempo e frequência), com o objetivo de aprimorar a detecção de crises epiléticas e prover melhor auxílio médico no diagnóstico dessa enfermidade e em processos de tomadas de decisão.

Revisão de Literatura

Com o advento do aprendizado de máquina, diversos trabalhos vêm, ao longo dos anos, apresentando propostas na tentativa de automatizar a detecção ou realizar a predição de crises epiléticas utilizando dados de EEG. Essas abordagens existentes podem ser divididas em duas categorias ⁽⁵⁾. A primeira categoria refere-se a detecção de crises, que tem a finalidade de auxiliar profissionais de saúde no diagnóstico de enfermidades ⁽⁵⁾. A segunda categoria concentra-se na previsão de crises, com o propósito de viabilizar a intervenção precoce para a redução de riscos atrelados às crises ⁽⁵⁾ para melhorar a qualidade de vida do paciente. Para esta revisão de literatura foram considerados somente trabalhos que utilizem a mesma base de dados (apresentada na seção de métodos) e que façam uso de algum modelo de aprendizado profundo a fim de possibilitar um comparativo justo entre o presente trabalho e os estudos analisados na literatura.

Dentre os trabalhos analisados, a principal diferença entre eles encontra-se no domínio em que o EEG é representado e no método utilizado para o treinamento de modelos. Para a aplicação de métodos de aprendizado de máquina, o EEG é comumente representado nos domínios de tempo, de frequência e/ou de tempo-frequência ⁽⁶⁾. Já os principais modelos, no contexto deste trabalho, são comumente treinados redes neurais convolucionais (CNN - *convolutional neural network*) ⁽⁷⁾, redes neurais recorrentes (RNN - *recurrent neural network*) ⁽⁸⁾ ou uma junção desses dois modelos (RCNN - *recurrent convolutional neural network*) ⁽⁹⁾.




Em Jana et al. ⁽¹⁰⁾ é proposto um método de detecção dos segmentos pré-ictais das crises epiléticas. Nos sinais de EEG são utilizados 22 canais, porém, estes são reduzidos de forma otimizada, mantendo a acurácia do modelo. Para o treinamento do modelo foram aplicadas janelas deslizantes de 1, 2, 4 e 8 segundos. Em seguida, esses dados foram utilizados como entrada de uma CNN. Os principais resultados obtidos no trabalho foram a acurácia de 93,10% para a janela de 1 segundo, 93,24% para a de 2 segundos, 98,81% e 99,63% para a de 4 e 8 segundos respectivamente.

Em Sharan et al. ⁽¹¹⁾ foi feito um comparativo entre a utilização de algumas representações de EEG em domínios diferentes. Inicialmente, são selecionados 18 canais comuns entre as amostras de EEG. Em seguida, os dados são segmentados em janelas de 2 segundos e então transformados no domínio de frequência utilizando a transformada rápida de Fourier (FFT) ⁽¹²⁾ e a transformada de Wavelet (WT) ⁽¹³⁾, ambas considerando um corte em frequências maiores que 45 Hz. Desse modo, foram treinados dois modelos CNN, um para os resultados de cada transformada. Como resultado principal, a CNN treinada a partir de dados WT atingiu a maior acurácia, sendo 97,25%.

Em Yao et al. ⁽¹⁴⁾ é proposto um método para detecção de crises epiléticas utilizando dados temporais segmentados em janelas de 23 segundos. Os canais são selecionados manualmente, resultando em um total de 17 canais. Em seguida essas informações foram utilizadas para o treinamento de um modelo RNN. Como resultado principal, o modelo RNN atingiu uma acurácia média de 87.93%.

Em Thodoroff et al. ⁽¹⁵⁾ é proposto um método de detecção de crises epiléticas utilizando dados espaciais, temporais e de frequência. Os dados de EEG são segmentados em janelas de 30 segundos e então transformados no domínio da frequência por meio da transformada rápida de Fourier. Esses espectros de potência resultantes da transformada foram então processados por bandas de frequência tais como: delta e teta (0 a 7 Hz), alfa (7 a 14 Hz) e beta (14 a 49 Hz). Em seguida, uma imagem é gerada somando essas informações à localização espacial dos eletrodos. Por fim, as imagens resultantes foram usadas para a construção de um modelo RCNN. Como resultado, o trabalho obteve uma sensibilidade de 85%.



Sobre os trabalhos relacionados apresentados nesta seção, é importante ressaltar que eles aplicam técnicas de pré-processamento semelhantes, como a seleção dos canais (de forma manual ou por algum algoritmo) e a utilização da janela deslizante para segmentar os dados de EEG. Por fim, nota-se também a versatilidade que as redes convolucionais podem proporcionar para a detecção da epilepsia, podendo ter sua entrada adaptada para dados temporais, espectrais e espaciais ⁽⁶⁻⁷⁾.

Diante da análise de literatura e a falta de comparativos entre redes neurais profundas com diferentes domínio de dados, o presente trabalho realizou a criação de um modelo de CNN para detecção de crises epiléticas utilizando segmentos de EEG representados em dois domínios diferentes (temporal e frequência), a fim de elencar qual representação acarreta no melhor desempenho entre os modelos.

Materiais e Métodos


Base de dados

A base de dados utilizada neste trabalho foi a *CHB-MIT Scalp EEG Database* ⁽¹⁶⁾ da *PhysioNet*. Os exames presentes neste *dataset* foram gerados no Hospital Infantil de Boston. Para a geração dessa base de dados, os pacientes foram monitorados a uma taxa de amostragem de 256 Hz com quantização de 16 bits e os eletrodos foram colocados seguindo o sistema internacional de posicionamento de eletrodos 10–20. O *dataset* contém informações de 22 pacientes. Nessa base de dados, para cada paciente existem entre 9 e 42 amostras de EEG. Cada amostra é composta por 23 ou mais canais.

As informações contidas em cada uma das amostras são organizadas em sumários disponibilizado juntamente com a base de dados, separados por paciente. Esses sumários contém dados importantes referente aos sinais de EEG, como: nome do registro, nome do arquivo, tempo inicial, tempo final, número de convulsões, tempos iniciais de convulsão, tempos finais de convulsão, número de canais e nome dos canais.

Pré-processamento

As gravações de EEG utilizadas desse *dataset* são de tamanhos variados, apresenta desbalanceamento e evidenciam diferentes durações de crises epiléticas.



Dessa forma, foi necessário pré-processar as amostras para garantir que tenham o mesmo comprimento (tempo de duração).


Inicialmente, na base de dados, foram selecionados os sinais de EEG que apresentam atividades ictais (crise epiléptica) com a finalidade de reduzir o desbalanceamento dos dados. Em seguida, é feita a leitura de registros de EEG selecionados. Nessa etapa são mantidos apenas os canais que possuem ocorrência comum em todos os exames, a fim de padronizar a entrada de dados. Os canais mantidos foram: FP1-F7, FP1-F3, FP2-F8, FP2-F4, FZ-CZ, F3-C3, F4-C4, F7-T7, F8-T8, C3-P3, C4-P4, CZ-PZ, T8-P8, T7-P7, P7-O1, P3-O1, P8-O2 e P4-O2. Assim, foram selecionados, no total, 18 canais, sendo os demais canais descartados.

Como os exames possuem durações e tempos de crises diferentes, foi realizada a segmentação dos registros de EEG utilizando uma janela deslizante de 5 segundos sem sobreposição, garantindo que todas as amostras tenham o mesmo tamanho. Essas janelas foram criadas em torno das crises, por serem as regiões de interesse da detecção. A aplicação das janelas nessas regiões também reduz o tempo de execução da segmentação e o uso de memória computacional em comparação a aplicação da segmentação em todo o registro.

A partir dos dados pré-processados, foram construídos dois classificadores por meio do método CNN, sendo um treinado diretamente a partir dos segmentos de EEG (domínio de tempo) e o outro a partir da representação desses dados sequenciais no domínio de frequência. Para a representação dos segmentos de EEG no domínio de frequência, em cada uma das amostras foi aplicada a transformada discreta de Fourier (TDF) ⁽¹²⁾. Dessa forma, para cada segmento, foi obtido um espectro de potência (EP). A TDF pode ser aplicada por meio da Equação 1, onde $X[k]$ é o k -ésimo componente de Fourier, j é a unidade imaginária de números complexos e $2\pi k$ é a frequência angular.

$$X[k] = \sum_{n=0}^{N-1} x[n] \cdot e^{\frac{-j2\pi km}{N}} \quad (1)$$

Os coeficientes X são então utilizados para a geração do EP por meio da operação módulo elevado ao quadrado de cada um desses elementos ($P[k] = |X[k]|^2$).




Como resultado do pré-processamento, obtém-se uma lista de segmentos nos domínios de tempo e de frequência. Para os dados temporais, o formato resultante de cada amostra é de (18, 1280), onde 18 representa o número de canais e 1280 o número de pontos em cada canal, representando o valor de diferença de potencial entre os eletrodos. E, para os dados em frequência, o formato resultante das amostras é de (18, 641), em que 18 representa o número de canais e 641 o valor de EP, que contém componentes de frequência entre 0 Hz e 128 Hz.

Construção de modelos

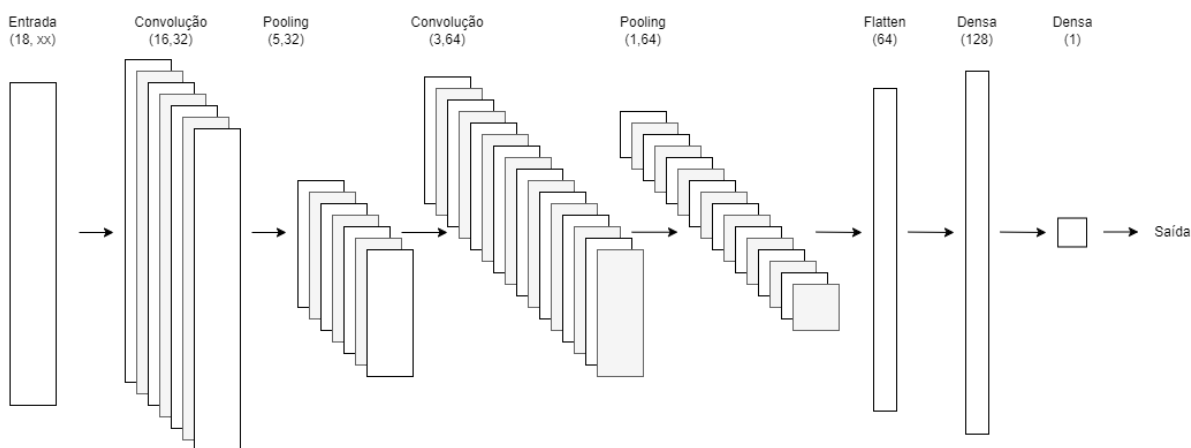
O tipo de rede neural escolhido para este trabalho foi o CNN, devido à versatilidade e por ser a principal opção de escolha observada na revisão de literatura para a implementação de rede profunda. A arquitetura foi a mesma para ambos os domínios de dados, a fim de gerar um comparativo justo entre as redes. Os modelos resultantes do treinamento por meio de CNN são compostos por 8 camadas. Os classificadores resultantes foram obtidos após diversas tentativas de treinamento considerando configurações diferentes. Porém, devido ao longo tempo de execução e o pouco ganho de acurácia, optou-se por manter um modelo mais rápido e simples para auxiliar na detecção de crises epiléticas. A Figura 1 representa graficamente a arquitetura dos modelos propostos neste trabalho, que são compostos pelas seguintes camadas:

- **Entrada:** recebe os segmentos de entrada de dimensão. Para o modelo treinado com dados sequenciais no domínio tempo, a entrada possui dimensão 18×1280 . Para o classificador treinado com segmentos no domínio de frequência, a dimensão da entrada é 18×641 .
- **Convolução:** são responsáveis por extrair características da entrada através da aplicação de filtros de convolução.
- **Pooling:** são utilizadas para reduzir a dimensionalidade dos filtros convolucionais, preservando as melhores características.
- **Flatten:** É a camada usada para converter os dados de entrada da camada anterior em um formato unidimensional para a camada do tipo densa.



- **Densa:** são responsáveis por aprender e representar relações complexas entre características extraídas das camadas anteriores.
- **Saída:** é a saída binária do modelo, informando se o segmento é referente ou não à uma crise epiléptica.


Figura 1 – Arquitetura da CNN



Antes do treinamento, os segmentos são normalizados para melhorar a performance e a acurácia dos modelos. Em seguida, cada um dos dois conjuntos de segmentos (domínios de tempo e de frequência) são divididos em subconjuntos de treino, de validação e de teste. O subconjunto de treino é então balanceado (estratificado) por classe, garantindo que o número de amostras que contenham as crises epilépticas sejam iguais ao número de amostras normais. Por fim, as amostras de treino são embaralhadas, com o objetivo de gerar aleatoriedade para o processo de treinamento.

O número dessas amostras varia a cada treinamento executado, isso ocorre devido aos subconjuntos serem gerados com base nas crises epilépticas (possuem diferentes tamanhos), resultando em diferentes quantidades de segmentos. Para o subconjunto de teste são selecionadas 5 crises aleatórias em cada amostra. E os demais segmentos são usados para treino (80%) e validação (20%). No total são 112 crises, com uma duração total de 8704 segundos.

Por fim, foi realizado o treinamento dos modelos utilizando 100 épocas. Esses parâmetros foram definidos empiricamente observando os valores de acurácia sobre o



subconjunto de validação, onde o modelo temporal passa a aprender efetivamente após a época 50, com isso, chegou-se ao valor de 100.

Avaliação dos modelos

Para a avaliação dos modelos foi utilizado um conjunto de métricas de matriz de confusão comumente utilizadas na literatura. Para o cálculo dessas medidas, a matriz de confusão é composta pelos seguintes parâmetros ⁽¹⁷⁻¹⁸⁾:

- Verdadeiros positivos (Vp): quantidade de segmentos anormais (com crise epiléptica) classificados corretamente.
- Verdadeiros negativos (Vn): quantidade de segmentos normais classificados corretamente.
- Falsos negativos (Fn): quantidade de segmentos anormais classificados incorretamente.
- Falsos positivos (Fp): quantidade de segmentos normais classificados incorretamente.

Dessa forma, a partir da matriz de confusão foram calculadas as seguintes métricas:

- Acurácia (Equação 2): taxa total de segmentos classificados corretamente.

$$Acu = \frac{Vp + Vn}{Vp + Fn + Vn + Fp} \quad (2)$$

- Precisão (Equação 3): em relação a quantidade de todos os segmentos que foram classificados como anormal, essa medida determina a porcentagem dos que foram categorizados corretamente.


$$Pre = \frac{Vp}{Vp + Fp} \quad (3)$$

- Sensibilidade (Equação 4): avalia a capacidade do método de detectar com sucesso resultados classificados como positivos.

$$Sen = \frac{Vp}{Fn + Vp} \quad (4)$$

- Especificidade (Equação 5): avalia a capacidade do método de detectar resultados negativos.

$$Esp = \frac{Vn}{Vn + Fp} \quad (5)$$



- F1-score (Equação 6): é uma média harmônica calculada com base na precisão e na sensibilidade.

$$F1 = \frac{2 \times Acu \times Sen}{Acu + Sen} \quad (6)$$

Além das métricas mencionadas acima, também foram geradas curvas ROC (*Receiver Operating Characteristic*) e a AUC (*Area Under the Curve*), que são utilizadas para demonstrar o desempenho de um modelo de aprendizado por meio da relação da taxa de verdadeiro positivo e da taxa de falso positivo.

Resultados e Discussão


Os experimentos foram executados dez vezes para cada uma das redes utilizando *random subsampling* ⁽¹⁹⁾, a fim de comprovar o poder de generalização dos modelos. Ao final foi calculada a média das métricas resultantes em cada treinamento para obter os valores da Tabela 1.

Tabela 1 – Resultados obtidos referente às métricas de cada modelo.

| Métrica | Modelo temporal (média ± desvio padrão) | Modelo de frequência (média ± desvio padrão) |
|----------------|--|---|
| Acurácia | 73,37% ± 5,48% | 82,08% ± 4% |
| Precisão | 68,45% ± 8,07% | 76,84% ± 10,12% |
| Sensibilidade | 66,70% ± 12,23% | 80,83% ± 10,04% |
| Especificidade | 79,51% ± 4% | 83,76% ± 5,67% |
| F1-score | 69,64% ± 9,04% | 81,23% ± 6,62% |

Conforme apresentado na Tabela 1, é possível notar que o modelo treinado com dados de frequência obteve maiores valores em todas as métricas consideradas na avaliação, constatando que o espectro potência pode melhorar o desempenho na detecção de crises epiléticas em comparação com os dados temporais.

Dentro desses experimentos, foram analisados também quais os maiores e menores valores de acurácia obtidos. O modelo temporal obteve o valor máximo de 83,74% e o mínimo, de 63,04%. E o modelo de frequência obteve valores de acurácia

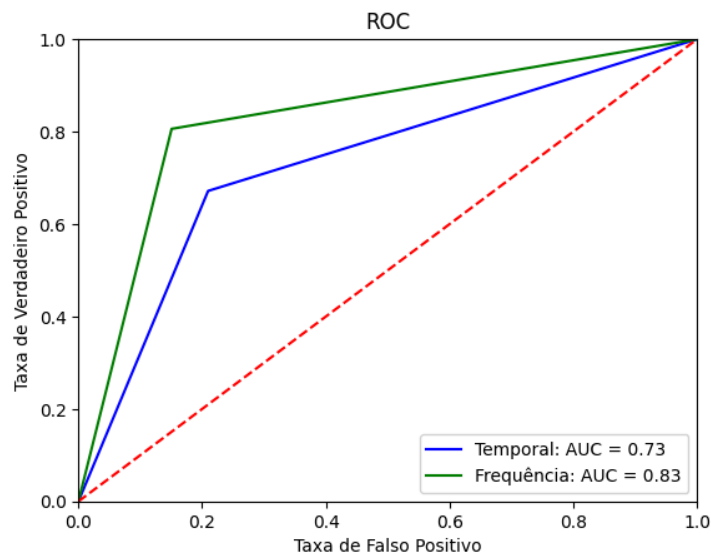


entre 75,00% e 87,43% evidenciando que a alimentação com os dados em frequência gerou um modelo mais consistente. Isso se deve ao fato de que algumas características relevantes dos sinais são evidenciáveis em outro domínio ⁽⁴⁾.


Complementarmente, a Figura 2 apresenta curvas ROC referentes ao desempenho preditivo dos modelos. Nessa figura, também são apresentados os valores AUC.

Nota-se que o modelo treinado com dados em frequência também obteve resultados superiores em relação ao modelo treinado com dados temporais, principalmente em relação às taxas de falsos positivos, mostrando que o modelo de frequência tem menores chances de classificar erroneamente segmentos normais como crises epiléticas. Também, os modelos apresentaram altas taxas de verdadeiro positivo, contribuindo de forma positiva na detecção de crises epiléticas.

Figura 2 – Curvas de ROC e os respectivos valores AUC referentes aos modelos.



Adicionalmente, para a comparação entre os modelos, foi realizado um teste estatístico de hipótese para dados não pareados e não paramétricos. Para isso, foi aplicado o teste U de Mann-Whitney ⁽²⁰⁾ considerando o nível de significância de 5%. Como resultado, no teste foi obtido o p -valor de 0,003, constatando que houve diferença estatisticamente significativa entre os modelos. Desse modo, podemos afirmar, com 95% de certeza, que o modelo de frequência obteve desempenho superior em comparação



com modelo temporal, corroborando que os dados em frequência contém informações essenciais para detecção das crises epiléticas ⁽⁴⁾.

Devido ao número reduzido de camadas, o tempo de treinamento dos modelos foi entre 20 e 30 segundos. Desse modo, a simplificação da arquitetura do modelo, com menos camadas e neurônios, possibilita a redução do tempo de treinamento ⁽²¹⁾.


Conclusão

Este trabalho teve por objetivo a criação e comparação de modelos de CNN com diferentes entradas de dados para a detecção de crises epiléticas. Os modelos foram treinados a partir do *dataset* disponibilizado pela *PhysioNet* gerados a partir de informações reais de EEG. O modelo treinado a partir dos dados em frequência obteve uma acurácia média de 82,08% e máxima de 87,43%, valores considerados próximos aos de trabalhos relacionados ^(10, 14, 15) nesta linha de pesquisa. Mesmo assim, os modelos construídos neste trabalho têm, como principal vantagem, uma quantidade reduzida de camadas e de neurônios. Também, este trabalho possui outras contribuições, tais como: construção e comparação de modelos CNN construídos a partir de EEG representados em dois domínios distintos; condução de teste estatístico de hipótese para comparação dos modelos; e resultados competitivos.


Por fim, para trabalhos futuros, sugere-se: a implementação de modelos de redes neurais de outras arquiteturas (*e.g.*, redes neurais recorrentes, transformers, entre outras); e a implementação de outras formas de representação de EEG (*e.g.*, espectrograma e biespectrograma).

Referências

1. World Health Organization. Epilepsy: a public health imperative. 2019.
2. Shin HW, Jewells V, Hadar E, Fisher T, Hinn A. Review of epilepsy-etiology, diagnostic evaluation and treatment. *Int J Neurorehabilitation*. 2014;1(130):2376-0281.
3. Freeman W, Quiroga RQ. Imaging brain function with EEG: advanced temporal and spatial analysis of electroencephalographic signals. Springer Science & Business Media; 2012 Oct 28.



4. Oliva JT, Rosa JL. Classification for EEG report generation and epilepsy detection. *Neurocomputing*. 2019 Mar 28;335:81-95.
5. Alotaiby TN, Alshebeili SA, Alshawi T, Ahmad I, Abd El-Samie FE. EEG seizure detection and prediction algorithms: a survey. *Journal on Advances in Signal Processing*. 2014:1-21.
6. Craik A, He Y, Contreras-Vidal JL. Deep learning for electroencephalogram (EEG) classification tasks: a review. *Journal of neural engineering*. 2019 Apr 9;16(3):031001.
7. Li Z, Liu F, Yang W, Peng S, Zhou J. A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE transactions on neural networks and learning systems*. 2021 Jun 10;33(12):6999-7019.
8. Yu Y, Si X, Hu C, Zhang J. A review of recurrent neural networks: LSTM cells and network architectures. *Neural computation*. 2019 Jul 1;31(7):1235-70.
9. Xu C, Zhao P, Liu Y, Xu J, S. Sheng VS, Cui Z, Zhou X, Xiong H. Recurrent convolutional neural network for sequential recommendation. In *The world wide web conference 2019* (pp. 3398-3404).
10. Jana R, Mukherjee I. Deep learning based efficient epileptic seizure prediction with EEG channel optimization. *Biomedical Signal Processing and Control*. 2021 Jul 1;68:102767.
11. Sharan RV, Berkovsky S. Epileptic seizure detection using multi-channel EEG wavelet power spectra and 1-D convolutional neural networks. In *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC) 2020 Jul 20* (pp. 545-548).
12. Brigham EO. *The fast Fourier transform and its applications*. Prentice-Hall, Inc.; 1988 Jul 1.
13. Daubechies I. The wavelet transform, time-frequency localization and signal analysis. *IEEE transactions on information theory*. 1990 Sep;36(5):961-1005.
14. Yao X, Li X, Ye Q, Huang Y, Cheng Q, Zhang GQ. A robust deep learning approach for automatic classification of seizures against non-seizures. *Biomedical Signal Processing and Control*. 2021 Feb 1;64:102215.
15. Thodoroff P, Pineau J, Lim A. Learning robust features using deep learning for automatic seizure detection. In *Machine learning for healthcare conference 2016 Dec 10* (pp. 178-190).
16. Guttag J. CHB-MIT Scalp EEG Database. *PhysioNet*. 2010. doi: 10.13026/C2K01R.
17. Monard MC, Baranauskas JA. Conceitos sobre aprendizado de máquina. *Sistemas inteligentes-Fundamentos e aplicações*. 2003;1(1):32.
18. Sokolova M, Lapalme G. A systematic analysis of performance measures for classification tasks. *Information processing & management*. 2009 Jul 1;45(4):427-37.
19. Xu QS, Liang YZ. Monte Carlo cross validation. *Chemometrics and Intelligent Laboratory Systems*. 2001 Apr 16;56(1):1-1.



CBIS'24

XX Congresso Brasileiro de Informática em Saúde
08/10 a 11/10 de 2024 - Belo Horizonte/MG - Brasil

20. Mann HB, Whitney DR. On a test of whether one of two random variables is stochastically larger than the other. *The annals of mathematical statistics*. 1947 Mar 1:50-60.
21. Günther F, Fritsch S. Neuralnet: training of neural networks. *The R Journal*. 2010 Jun 2(1):30-38.