

## APLICAÇÃO DE REDES NEURAIS CONVOLUCIONAIS NA DETECÇÃO DE CRISE EPILÉPTICA POR MEIO DE EEG

Paulo Augusto de Faria<sup>1</sup>; Mauro Luiz Begnini<sup>2</sup>; Marcelo Lucas<sup>3</sup>

<sup>1, 2, 3</sup> Universidade de Uberaba

[paulosanteiro18@gmail.com](mailto:paulosanteiro18@gmail.com)

[marcelo.lucas.eng@gmail.com](mailto:marcelo.lucas.eng@gmail.com)

### Resumo

Epilepsia é uma condição neurológica significativa que afeta milhões de pessoas globalmente, caracterizada por convulsões recorrentes devido a atividades elétricas anormais no cérebro. Este estudo aborda a aplicação de Redes Neurais Convolucionais (CNNs) na detecção de crises epiléticas por meio de eletroencefalogramas (EEG). O objetivo é desenvolver um sistema eficiente e preciso para monitorar e detectar convulsões, auxiliando no tratamento e gerenciamento da epilepsia. Os dados utilizados foram coletados de 24 pacientes, abrangendo 916 horas de EEG contínuo, registrando 173 eventos de convulsão. A metodologia envolveu a pré-processamento de dados para remover ruídos, extração de características, e o uso de CNNs para classificar os sinais de EEG. A sensibilidade do modelo foi de 96%, com uma latência média de 4,6 segundos, destacando sua eficácia em detectar convulsões rapidamente. A adição de dados de ECG melhorou ainda mais o desempenho, reduzindo a latência para 2,7 e diminuindo falsas detecções. A pesquisa destaca a importância de soluções personalizadas devido à variabilidade dos sinais de EEG entre pacientes e a necessidade de métodos de detecção rápida e precisa. O estudo sugere que a combinação de EEG e ECG pode ser uma abordagem promissora para melhorar a detecção de convulsões. Futuras investigações deverão focar na integração de sistemas de detecção em malha fechada em dispositivos embarcados e na colaboração com profissionais de saúde para validar e aprimorar a aplicação clínica desses sistemas.

Palavras-chave: Epilepsia; Redes Neurais Convolucionais (CNNs); Aprendizado de Máquina; Processamento de Sinais.

### 1 Introdução

A epilepsia é o quarto distúrbio cerebral mais grave no mundo, afetando cerca de 50 milhões de

pessoas, superando o número de pacientes com Parkinson, esclerose múltipla e paralisia cerebral combinados. Estima-se que entre 4 e 10 em cada 1000 pessoas no mundo tenham epilepsia ativa, com as Américas apresentando a maior porcentagem. Nos EUA, 3,4 milhões de pessoas, ou 1,2% da população, sofrem de epilepsia, enquanto na Europa essa taxa é de 0,82%. As convulsões, resultado de atividades elétricas cerebrais anormais, são o principal sintoma da epilepsia, variando em duração e frequência e necessitando de monitoramento preciso para diagnóstico e tratamento adequados. A eletroencefalografia (EEG) é o método padrão para registrar essa atividade elétrica, mas suas limitações de tempo de teste podem tornar os dados insuficientes para diagnósticos completos (HENRY,2006).

Para contornar essas limitações, dispositivos de detecção de convulsões portáteis podem ser usados no dia a dia para manter um diário mais detalhado das convulsões, auxiliando no acompanhamento e ajuste de tratamentos. Esses dispositivos precisam ser pequenos, discretos e energeticamente eficientes, utilizando algoritmos sofisticados para operar por longos períodos. Métodos tradicionais de design de sistemas embarcados usam técnicas de processamento de sinal no domínio do tempo (TMSP), transmitindo informações em formato binário para maior eficiência energética (HAYKIN,2009).

Recentemente, as Redes Neurais Convolucionais (CNNs), uma forma avançada de redes neurais usadas na detecção de imagens, têm sido exploradas para a detecção de convulsões. As CNNs, compostas por camadas convolucionais, ReLU, max-pooling e totalmente conectadas, exigem pré-processamento dos sinais EEG para construir matrizes de dados de entrada a partir das características extraídas. A aplicação de algoritmos de aprendizado de máquina, especialmente CNNs, tem mostrado grande

potencial na detecção eficiente de convulsões com base em características no domínio do tempo. Esta pesquisa visa aprimorar o uso dessas técnicas para detectar convulsões de forma mais precisa e eficiente (SHOEB, 2003).

## 2 Materiais e Métodos

A base de dados usada para avaliar o detector de convulsões proposto inclui 916 horas de EEG contínuo, amostrado a 256 Hz, de 23 pacientes pediátricos do Hospital Infantil de Boston e um adulto do Beth Israel Deaconess Medical Center. Durante os registros, ocorreram 173 eventos de convulsões clínicas, identificados por especialistas. Os dados foram segmentados em registros de uma hora, sendo classificados como não convulsivos (sem convulsões) ou de convulsões (com uma ou mais convulsões). Os dados pediátricos estão disponíveis no banco de dados CHB-MIT no site PhysioNet (SHOEB, 2003).

O desempenho do detector foi avaliado em termos de sensibilidade, especificidade e latência. A sensibilidade mede a porcentagem de convulsões corretamente identificadas, a especificidade indica quantas vezes o detector errou ao identificar uma convulsão inexistente em 24 horas, e a latência é o tempo entre o início da convulsão e sua detecção pelo sistema. Utilizou-se um esquema de validação cruzada com registros deixados de fora. A abordagem evitou métodos baseados em épocas para não produzir resultados enganosamente bons.

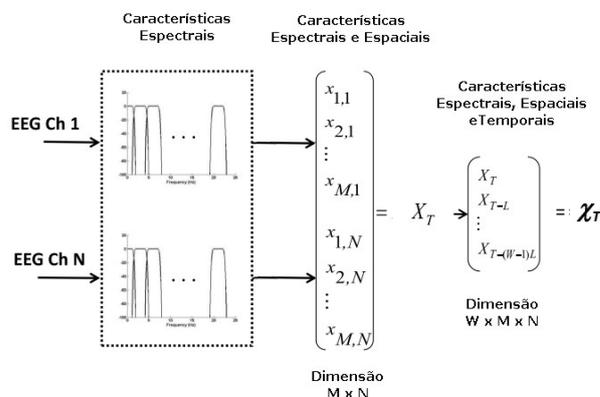
Para estimar a latência e a sensibilidade, o modelo foi treinado com registros não convulsivos e todos menos um registro de convulsão, repetindo o teste para cada registro de convulsão. Para a especificidade, o modelo foi treinado com registros de convulsão e todos menos um registro não convulsivo, registrando detecções falsas em cada rodada.

### 2.1 Detecção de Convulsões Baseada em EEG-ECG

Para incluir informações do ECG no processo de detecção, utilizou-se o vetor de características, que pode ser visto na Figura 1 a seguir, com duas entradas, ou seja, dois sinais de ECG. Os recursos, que são extraídos de épocas de 6 segundos, são a taxa cardíaca média ( $X_1, ECG$ ) e a diferença entre as taxas cardíacas final e inicial dentro de uma época ( $X_2, ECG$ ). Concatenar recursos de EEG e ECG permite que o SVM aprenda automaticamente a relação entre informações espectrais, espaciais e temporais

extraídas do EEG com informações da taxa cardíaca e suas mudanças extraídas do ECG.

**Figura 1** – Estágios de extração de características



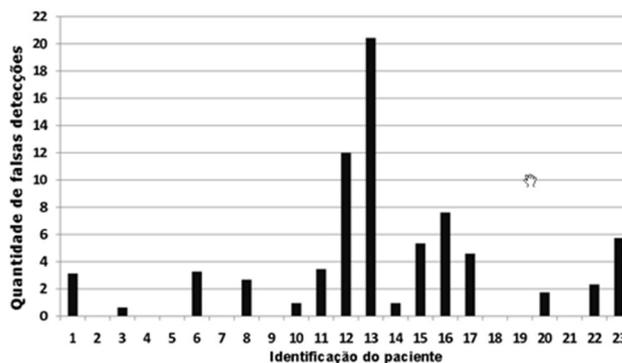
Fonte: Autor

## 3 Resultados

Globalmente, 96% das 173 convulsões de teste foram detectadas pelo detector proposto. A latência média de detecção do início da convulsão foi de 4,6 segundos. Mais especificamente, metade das 173 convulsões de teste foram detectadas dentro de 3 segundos, 71% dentro de 5 segundos e 91% dentro de 10 segundos. Ocorreram falhas ou grande latência de detecção quando uma convulsão de teste apresenta características espaciais ou espectrais significativamente diferentes das convulsões presentes no conjunto de treinamento.

A Figura 2 a seguir apresenta o número de falsas detecções obtidas pelo detector proposto a cada 24 horas para cada um dos 23 pacientes. A taxa média de falsas detecções é de 2 por período de 24 horas. No entanto, para o Paciente 13, o algoritmo declarou 20 falsas detecções por período de 24 horas, devido à presença de um crescimento significativo de atividades que se assemelham ao início da convulsão.

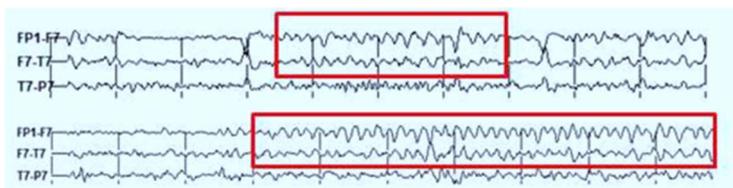
**Figura 2:** Detecções obtida por paciente.



Fonte: Autor

A região marcada na Figura 3 a seguir ilustra uma desses aumentos excessivos que provocou uma falsa detecção, semelhante à atividade de convulsão destacada no quadro inferior da mesma figura. A principal diferença entre os dois é a duração temporal da convulsão. Para aprimorar a especificidade do detector proposto para o Paciente 13, poderíamos modificar o algoritmo para declarar uma convulsão somente quando a atividade suspeita persistir por mais tempo do que o comprimento médio das perturbações rítmicas. No entanto, isso resultaria em um aumento na latência de detecção.

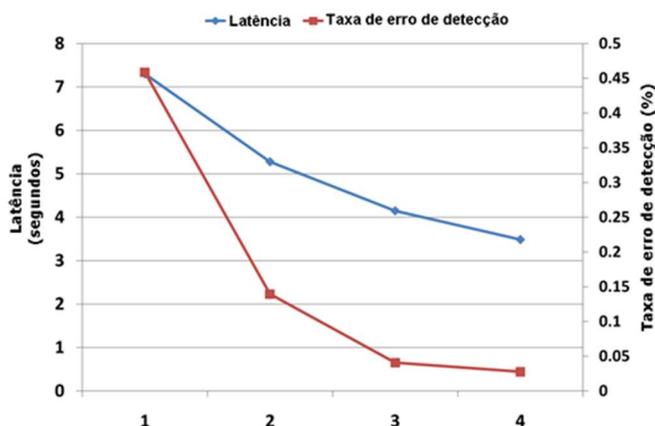
**Figura 3:** Perturbação rítmica e convulsão no EEG do Paciente 13



Fonte: Autor

A Figura 4 abaixo mostra como a latência média de detecção e a taxa de perda diminuem com o aumento do número de convulsões de treinamento. Embora a curva tenha sido derivada a partir de dados de cinco pacientes selecionados aleatoriamente, faz parte do comportamento do detector. Com uma única amostra de convulsão, o detector apresenta uma latência média superior a 7 segundos e perde mais de 45% das convulsões de teste. Já com três convulsões, a latência média fica próxima a 4 segundos e a taxa de perda de convulsões de teste é inferior a 5%.

**Figura 4:** Latência e sensibilidade em função do número de convulsões com um número K de treinamento.

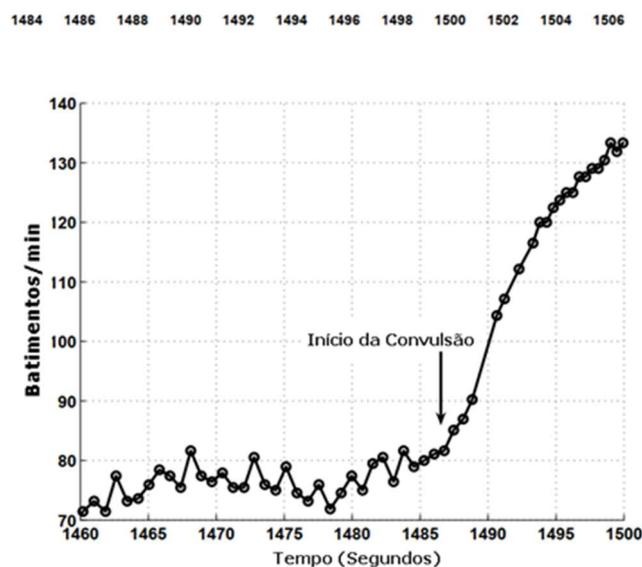


Fonte: Autor

Comparando nosso desempenho com o algoritmo Reveal (Wilson et al., 2004), um detector não específico para o paciente, offline e comercialmente disponível, que utiliza aprendizado de máquina, observamos que o Reveal detectou apenas 61% das convulsões, com uma taxa de falsas detecções de 33 por período de 24 horas, quando avaliado no mesmo conjunto de dados discutido na Seção 2.1. Apesar de ser treinado com um volume maior de dados, a sensibilidade e especificidade do algoritmo Reveal são consideravelmente inferiores aos 97% de sensibilidade e 2 falsas detecções por período de 24 horas que foi relatado.

Foram registradas 10 convulsões e 66 horas de EEG-ECG sincronizados do Paciente 24. A Figura 5 a seguir ilustra uma convulsão típica. O início da convulsão, aos 1486 segundos, refere-se piscadas rápidas, que se manifestaram no EEG como deflexões de alta amplitude no canal FP1-F7. Com o início do piscar dos olhos, a taxa cardíaca do paciente acelerou, como pode ser visto na curva da taxa cardíaca no quadro inferior da Figura 5. Finalmente, aos 1492 segundos, observou-se uma atividade rítmica no canal T4-T6, e a taxa cardíaca do paciente permanece elevada.

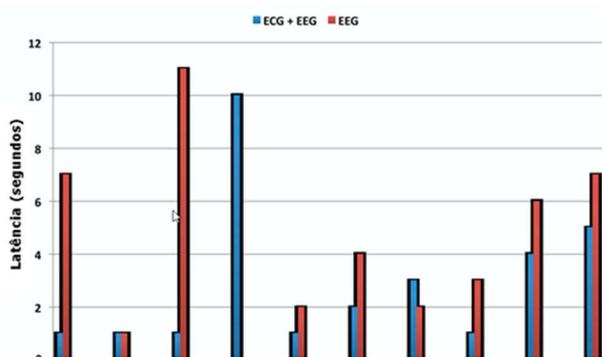
**Figura 5:** Convulsão com início sem atividade rítmica, mas acompanhada por uma aceleração da frequência cardíaca.



Fonte: Autor

Na Figura 6 a seguir, comparou-se o desempenho do detector, quando os vetores de características são montados usando tanto EEG quanto ECG, e quando são montados usando apenas EEG, ela também ilustra a comparação da latência apresentada pelos detectores quando foram utilizadas dez convulsões de teste. O detector que usou apenas EEG teve uma latência média de 4,2 segundos, detectou todas as convulsões exceto a convulsão 4, (que pode ser observada na ausência da barra na mesma figura) e, declarou 9 falsas detecções por período de 24 horas. A adição de informações do ECG melhorou o desempenho. O detector que combinou EEG e ECG teve uma latência média de 2,7 segundos, detectou todas as convulsões e declarou 5 falsas detecções por período de 24 horas.

**Figura 6:** Latência dos detectores que utilizam vetores de características contendo apenas EEG ou ambos EEG e ECG.



Fonte: Autor

#### 4 Discussão

O trabalho desenvolvido alcançou inferências significativas. A integração de dados de EEG (eletroencefalograma) e ECG (eletrocardiograma) melhorou a latência e precisão na detecção de convulsões, reduzindo a latência média para 2,7 segundos quando usados juntos, em comparação a 4,2 segundos usando apenas EEG. As Máquinas de Vetores de Suporte (SVMs) se mostraram eficazes na criação de classificadores específicos para pacientes, permitindo a detecção de convulsões sem necessidade de conhecimento técnico especializado. No entanto, a variabilidade dos sinais de EEG entre pacientes e a necessidade de equilibrar sensibilidade e especificidade continuam sendo desafios, mitigados por estratégias de pré e pós-processamento.

As argumentações que interligam essas inferências às conclusões são fundamentadas em análises detalhadas. A combinação de sinais EEG e ECG não apenas reduziu a latência de detecção, mas também diminuiu o número de falsas detecções por período de 24 horas, indicando que a combinação de diferentes tipos de dados fisiológicos fornece uma representação mais robusta do estado do paciente. A utilização de SVMs destacou a adaptabilidade e precisão do método para diferentes indivíduos, mostrando-se viável e prático para implementação em ambientes clínicos. Apesar dos desafios, a implementação de técnicas avançadas de Machine Learning, combinadas com estratégias de pré e pós-processamento, resultou em sistemas de detecção mais precisos e rápidos.

As contribuições do trabalho estão diretamente alinhadas com o objetivo de melhorar a detecção precoce de convulsões epiléticas utilizando EEG e ECG. As principais contribuições incluem o desenvolvimento de um sistema de detecção eficiente que combina EEG e ECG, demonstrando que SVMs podem ser utilizados de forma eficaz e prática em contextos clínicos. Além disso, a implementação de técnicas de pré-processamento para redução de ruídos e artefatos, assim como estratégias de pós-processamento para melhorar a interpretação dos resultados, destacou-se como essencial para a eficácia dos detectores. Essas contribuições proporcionam uma ferramenta prática e eficaz para ambientes clínicos, alinhando-se com o objetivo de aprimorar a detecção precoce de convulsões.

#### 5 Conclusão

Nesse trabalho foi implementada e avaliada uma técnica usando SVMs para construir classificadores específicos para o paciente que usam sinais de EEG com objetivo de detectar o início de convulsões epiléticas. Acredita-se que o método proposto nesse trabalho seja adequado para uso clínico. Usar o detector não requer expertise em aprendizado de máquina, e a classificação dos dados de treinamento pode ser derivada de informações fornecidas rotineiramente como parte do corpo clínico responsável pelo paciente. Como trabalhos futuros, seria interessante desenvolver um trabalho juntamente com médicos para realizar um estudo buscando, a partir do sistema proposto aqui, o projeto de detectores usando um sistema de detecção em malha fechado que pudesse ser implementado em sistemas embarcados, além do mais seria muito interessante um estudo mais aprofundado do uso da combinação de EEG e ECG na detecção de convulsões epiléticas.

## Referências

CENTERS FOR DISEASE CONTROL AND PREVENTION (CDC). About epilepsy. Disponível em: <https://www.cdc.gov/epilepsy/about/index.htm>. Acesso em: 25 maio 2021.

FISHER, R. S. et al. ILAE Official Report: A practical clinical definition of epilepsy. *Epilepsia*, vol. 55, pp. 475–482, Apr. 2014.

HAYKIN, S. S. *Neural Networks and Learning Machines*, Volume 10. Upper Saddle River, NJ, USA: Prentice Hall, 2009.

HENRY, J. C. *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*, Fifth Edition. *Neurology*, vol. 67, pp. 2092–2092–a, Dec. 2006.

HOCHREITER, S.; SCHMIDHUBER, J. Flat minima. *Neural Computation*, vol. 9, p. 1–42, Jan. 1997.

MPORAS, I., Tsirka, V., ZACHARAKI, E. I., KOUTROUMANIDIS, M., RICHARDSON, M., MEGALOOKONOMOY, V. Seizure detection using EEG and ECG signals for computer-based

monitoring, analysis and management of epileptic patients. *Expert Systems with Applications*, 42, 3227–3233. doi:10.1016/j.eswa.2014.12.010, 2015.

RAMGOPAL, S., THOME-SOUZA, S., JACKSON, M., & KADISH, N. E., SÁNCHEZ FERNÁNDEZ, I., KLEHM, J., BOSL, W., REINSBERGER, C., SCHACHTER, S., & LODDENKEMPER, T. (2014). Seizure detection, seizure prediction, and closedloop warning systems in epilepsy. *Epilepsy & behavior: E&B*, 37,291–307, 2014.

SHI, X. Energy-efficient seizure detection for wearable EEG (Master's thesis). Delft University of Technology, Delft, Netherlands., 2022.

WORLD HEALTH ORGANIZATION (WHO). *Epilepsy*. World Health Organization: WHO, Jun. 2019.

YUAN, F. *CMOS Time-Mode Circuits and Systems*. Boca Raton, FL, USA: CRC Press, 2018.

ZACK, M. M. National and State Estimates of the Numbers of Adults and Children with Active Epilepsy — United States, 2015. *MMWR Morb. Mortal. Wkly. Rep.*, vol. 66, 2017