

# Diagnóstico de epilepsia com o uso do eletroencefalograma e a inteligência artificial: uma revisão sistemática

*Diagnosis of epilepsy using electroencephalography and Artificial Intelligence:  
a systematic review*

PAULO HENRIQUE SILVA  
Discente de Medicina (UNIPAM)  
[paulohenriques0@unipam.edu.br](mailto:paulohenriques0@unipam.edu.br)

KALIL RIBEIRO NUNES  
Discente de Medicina (UNIPAM)  
[kalilnunes@unipam.edu.br](mailto:kalilnunes@unipam.edu.br)

MARILENE RIVANY NUNES  
Professora orientadora (UNIPAM)  
[maryrivany@unipam.edu.br](mailto:maryrivany@unipam.edu.br)

ELCIMAR DOS REIS CAIXETA  
Professor coorientador (UNIPAM)  
[elcimarcaixeta@unipam.edu.br](mailto:elcimarcaixeta@unipam.edu.br)

---

**Resumo:** A epilepsia é um distúrbio neurológico crônico cujo diagnóstico depende, em grande parte, da análise do eletroencefalograma (EEG), processo complexo e sujeito a variabilidade interpretativa. Esta revisão sistemática teve como objetivo identificar os avanços dos modelos de inteligência artificial (IA) aplicados ao EEG para o diagnóstico da epilepsia. Foram analisados estudos publicados entre 2023 e 2024 nas bases PubMed, BVS e EBSCOHost. Ao final, 15 artigos foram incluídos. Os resultados demonstram que modelos baseados em aprendizado de máquina e aprendizado profundo, especialmente arquiteturas híbridas envolvendo redes neurais convolucionais e recorrentes, apresentam elevadas taxas de acurácia e área sob curva (AUC). Apesar dos resultados promissores, persistem desafios relacionados à generalização dos modelos, padronização dos dados e validação clínica. Conclui-se que a IA representa uma ferramenta complementar promissora ao diagnóstico da epilepsia, exigindo, contudo, mais estudos multicêntricos para sua consolidação clínica.

**Palavras-chave:** aprendizado de máquina; eletroencefalografia; epilepsia; inteligência artificial.

**Abstract:** Epilepsy is a chronic neurological disorder whose diagnosis largely depends on the analysis of electroencephalography (EEG), a complex process subject to interpretative variability. This systematic review aimed to identify advances in artificial intelligence (AI) models applied to EEG for the diagnosis of epilepsy. Studies published between 2023 and 2024 were analyzed using the PubMed, BVS, and EBSCOHost databases. In total, 15 articles were included. The results indicate that models based on machine learning and deep learning, particularly hybrid

architectures involving convolutional and recurrent neural networks, demonstrate high levels of accuracy and area under the curve (AUC). Despite these promising findings, challenges remain regarding model generalization, data standardization, and clinical validation. It is concluded that AI represents a promising complementary tool for epilepsy diagnosis; however, further multicenter studies are required for its clinical consolidation.

**Keywords:** machine learning; electroencephalography; epilepsy; artificial intelligence.

---

## 1 INTRODUÇÃO

A epilepsia é um distúrbio neurológico crônico causado pela ocorrência de abruptas descargas elétricas anormais no cérebro, causando crises epiléticas. Esse distúrbio, que afeta milhares de pessoas em todo o mundo, apresenta diversos efeitos adversos na qualidade de vida dos pacientes, incluindo comprometimento cognitivo, diminuição da capacidade de atividades diárias e possível estigmatização social. Até o momento, uma compreensão completa da etiologia da epilepsia não está disponível (Gajic *et al.*, 2015).

O diagnóstico preciso e precoce da epilepsia é essencial para garantir um tratamento eficaz e melhorar a qualidade de vida dos pacientes. Inicialmente, deve-se fazer uma anamnese extensa da história do paciente e realizar a identificação correta das crises, o que pode ser desafiador, especialmente em casos em que os sintomas são sutis ou os registros do eletroencefalograma (EEG) são complexos e difíceis de interpretar (Pressler *et al.*, 2021).

O EEG, enquanto principal ferramenta utilizada no diagnóstico da epilepsia, permite a monitorização da atividade elétrica cerebral e a detecção de padrões característicos das crises epiléticas. Apesar de sua importância clínica, a análise dos resultados de um EEG exige profissionais altamente qualificados e é suscetível a erros de interpretação, devido ao extenso volume de dados e à variabilidade dos sinais cerebrais. Para superar essas limitações, o uso de técnicas de Inteligência Artificial (IA) tem se destacado como uma abordagem promissora, capaz de automatizar e otimizar o processo de análise de EEG (Oto, 2017).

A pesquisa em IA direcionada para o diagnóstico da epilepsia tem focado na detecção automática da doença através de algoritmos de aprendizado de máquina, aprendizado profundo e redes neurais, os quais buscam identificar as ondas característica de atividade epilética em grandes volumes de dados com potencial precisão superior à análise humana convencional (Shoeibi *et al.*, 2021).

Diante desse cenário, esta revisão sistemática visa reunir e analisar criticamente os estudos recentes que exploram a utilização da IA aplicada ao EEG para o diagnóstico de epilepsia. A partir dessa análise, busca-se discutir os avanços alcançados, os desafios ainda existentes e as perspectivas para a implementação dessas tecnologias no contexto clínico.

Este estudo visa identificar os avanços dos modelos de Inteligência Artificial (IA) relacionados ao Eletroencefalograma (EEG) para o diagnóstico de epilepsia, além de apresentar os modelos de IA utilizados no EEG para o diagnóstico de epilepsia; identificar a eficácia dos métodos de IA associado ao EEG para o diagnóstico de epilepsia

e descrever os benefícios e desafios da aplicação da IA no EEG para o diagnóstico de epilepsia.

A IA tem se tornado uma área de pesquisa e aplicação cada vez mais relevante na medicina, e compreender a sua influência nesse campo é de suma importância, visto os seus potenciais benefícios para a sociedade; sabendo que o EEG é uma ferramenta essencial para o diagnóstico da EP, e que tem como principais contrapontos o fato de possuir grande volume de dados e portanto um longo tempo de análise, a necessidade de profissionais especializados para sua avaliação, e a possibilidade de incerteza diagnóstica, o estudo justifica-se ao explorar as modalidades de IA que procuram automatizar o diagnóstico dessa doença, visando aprimorar a acurácia diagnóstica da epilepsia e assim melhorar a qualidade de vida dos pacientes portadores dessa comorbidade.

## 2 METODOLOGIA

Trata-se de uma revisão sistemática da literatura, que consiste em um estudo de revisão que usa métodos explícitos e sistemáticos para reunir e sintetizar descobertas de estudos que abordam uma questão claramente formulada. Para a realização da revisão sistemática, foi preconizado o proposto pela declaração de *Preferred Reporting Items for Systematic reviews and Meta-Analyses* (PRISMA) (Page *et al.*, 2021).

Para tal, a construção do estudo seguiu as seguintes etapas: definição do tema, elaboração da questão de pesquisa, estabelecimento de critérios de busca na literatura e de inclusão e exclusão de artigos; definição das informações a serem extraídas dos artigos selecionados e categorização dos estudos; análise; interpretação dos resultados e apresentação da revisão.

O estudo foi guiado pela pergunta norteadora “Quais são os modelos de IA associados ao EEG para diagnóstico da epilepsia?”. Para direcionar a busca dos artigos, foi adotado o uso dos Descritores em Ciências da Saúde eletroencefalograma: inteligência artificial, aprendizado de máquina, aprendizado profundo, diagnóstico e epilepsia em português; *electroencephalogram, artificial intelligence, machine learning, deep learning, diagnosis*, em inglês.

As bases de dados eletrônicas consultadas foram o Medical Literature Analysis and Retrieval System Online (MEDLINE), por meio da ferramenta de busca PubMed, a Biblioteca Virtual em Saúde (BVS), e o EBSCOHost, que inclui uma série de outras bases de dados em sua pesquisa. Essas bases de dados foram escolhidas pelo alcance científico na área da saúde. A busca foi realizada com vistas a buscar artigos publicados no período de janeiro de 2023 a dezembro de 2024, na língua portuguesa e inglesa. A Tabela 01 mostra a estratégia de pesquisa que foi adotada para cada base de dados consultada.

**Tabela 01:** Estratégia de pesquisa segundo a base de dados eletrônica utilizada

| Base de dados eletrônicas             | Estratégia de pesquisa                                                                                                                                  |
|---------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------|
| PubMed, BVS, EBSCOHost<br>(português) | Eletroencefalograma AND inteligência artificial AND<br>(aprendizado de máquina OR aprendizado profundo OR rede<br>neural) AND diagnóstico AND epilepsia |

|                                    |                                                                                                                                       |
|------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------|
| PubMed, BVS, EBSCOHost<br>(inglês) | Electroencephalogram AND artificial intelligence AND (machine learning OR deep learning OR neural network) AND diagnosis AND epilepsy |
|------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------|

Fonte: autoria própria, 2025.

Foi realizado o levantamento dos artigos seguindo os critérios de inclusão estabelecidos, e os artigos que não apresentaram coerência com o objetivo do estudo e a questão norteadora ou eram duplicados foram excluídos. Na sequência, foi realizada a análise e seleção dos artigos, independentemente, por dois pesquisadores, observando-se o título e resumos dos artigos. Nos casos em que estes não foram suficientes para determinar a elegibilidade da publicação, foi verificada a publicação na íntegra.

Posteriormente estes pesquisadores se encontraram para comparar a amostragem selecionada, discutir as discrepâncias e chegar a um consenso acerca da amostragem dos artigos que iam compor o estudo. Então, os artigos selecionados foram analisados e os dados relevantes para direcionar a análise e discussão da temática proposta foram coletados. Para a coleta de dados foi utilizado um instrumento desenvolvido pelos autores, o qual contempla as seguintes variáveis: ano de publicação, título, autores, delineamento do tipo de estudo, nível de evidência científica do artigo, métodos de IA associados ao EEG, acurácia e AUC.

Para determinar o nível de evidência científica e a força de recomendação para tomada de decisão, foram adotadas as diretrizes metodológicas do sistema *Grading of Recommendations Assessment, Development and Evaluation* (GRADE), disposto no manual de graduação da qualidade da evidência e força de recomendação para tomada de decisão em saúde (Brasil, 2014). Assim, foi possível elencar o nível de evidência científica dos artigos e o grau de recomendação das IAs em realizar sua determinada função.

O GRADE é um sistema universal, transparente e sensível para classificar a qualidade das evidências e a força das recomendações de estudos. O nível de evidência representa a confiança na informação utilizada em apoio a uma determinada recomendação. No sistema GRADE, a avaliação da qualidade da evidência é classificada em quatro níveis: alto, moderado, baixo, muito baixo, conforme mostrado no Quadro 1 (Brasil, 2014).

**Quadro 1:** Níveis de evidências de acordo com o sistema GRADE.

| Nível    | Definição                                                                      | Implicações                                                                                                          | Fonte de informação                                                                                                                                    |
|----------|--------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------|
| Alto     | Há forte confiança de que o verdadeiro efeito esteja próximo daquele estimado. | É improvável que trabalhos adicionais modificarão a confiança na estimativa do efeito.                               | - Ensaios clínicos bem delineados, com amostra representativa.<br>- Em alguns casos, estudos observacionais bem delineados, com achados consistentes*. |
| Moderado | Há confiança moderada no efeito estimado.                                      | Trabalhos futuros poderão modificar a confiança na estimativa de efeito, podendo, inclusive, modificar a estimativa. | - Ensaios clínicos com limitações leves**. - Estudos observacionais bem delineados, com achados consistentes*.                                         |

|             |                                                                                                    |                                                                                                         |                                                                                                                                                                                       |
|-------------|----------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Baixo       | A confiança no efeito é limitada.                                                                  | Trabalhos futuros provavelmente terão um impacto importante em nossa confiança na estimativa de efeito. | - Ensaaios clínicos com limitações moderadas**.<br>- Estudos observacionais comparativos: coorte e caso controle.                                                                     |
| Muito baixo | A confiança na estimativa de efeito é muito limitada. Há importante grau de incerteza nos achados. | Qualquer estimativa de efeito é incerta.                                                                | - Ensaaios clínicos com limitações graves**.<br>- Estudos observacionais comparativos com limitações**.<br>- Estudos observacionais não comparados***.<br>- Opinião de especialistas. |

-\*Estudos de coorte sem limitações metodológicas, com achados consistentes apresentando tamanho de efeito grande e/ou gradiente dose resposta. \*\*Limitações: vieses no delineamento do estudo, inconsistência nos resultados, desfechos substitutos ou validade externa comprometida.

\*\*\*Séries e relatos de caso

Fonte: Brasil, 2014.


Além disso, para definir o nível de confiança de cada determinado modelo de IA, foi priorizada a análise da área sob a curva (AUC) e a característica operacional do receptor (ROC), valores obtidos a partir da comparação dos resultados do programa com avaliações realizadas por médicos em um gráfico com as taxas de verdadeiro-positivo versus falso-positivo, para determinar a diferença de acurácia entre a IA e o médico humano, assim permitindo expressar o nível de precisão das IAs (Topol, 2019).

A análise dos artigos foi realizada pelo método de análise descritiva, possibilitando observar, analisar e correlacionar os dados com a maior precisão possível. Por fim, os artigos selecionados foram organizados e as variáveis, supracitadas, apresentadas em uma tabela descritiva, objetivando sintetizar as informações, bem como propiciar uma melhor visualização dos dados essenciais que merecem destaque.

### 3 RESULTADOS

A profunda busca na literatura por artigos que abordam o tema em questão propiciou encontrar de forma abrangente 127 artigos únicos, publicados entre 2023 e 2024, no entanto, desse montante, apenas 15 artigos foram incluídos ao fim da avaliação pelos autores, sendo representado na Figura 1.

**Figura 1:** Fluxograma da busca e inclusão dos artigos



Fonte: Instrumento de coleta de dados elaborado pelos autores, 2025.

Desse modo, as publicações selecionadas para análise foram estruturadas e descritas no Quadro 2, citando ano de publicação, título e autores dos artigos analisados.

**Quadro 2:** Organização dos artigos por título, autores e ano de publicação.

| Nº | Ano       | Título                                                                                                                                              | Autores                        |
|----|-----------|-----------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------|
| 1  | 2024a     | <i>A scheme combining feature fusion and hybrid deep learning models for epileptic seizure detection and prediction</i>                             | Zhang <i>et al.</i>            |
| 2  | 2023a     | <i>A Shallow Autoencoder Framework for Epileptic Seizure Detection in EEG Signals</i>                                                               | Khan <i>et al.</i>             |
| 3  | 2023      | <i>An automated detection of epileptic seizures EEG using CNN classifier based on feature fusion with high accuracy</i>                             | Chen <i>et al.</i>             |
| 4  | 2024<br>b | <i>An epilepsy diagnosis method based on a transferred alexnet model and eeg signals.</i>                                                           | Zhang <i>et al.</i>            |
| 5  | 2023a     | <i>An Epileptic EEG Detection Method Based on Data Augmentation and Lightweight Neural Network</i>                                                  | Wang <i>et al.</i>             |
| 6  | 2023      | <i>Automated Interpretation of Clinical Electroencephalograms Using Artificial Intelligence.</i>                                                    | Tveit <i>et al.</i>            |
| 7  | 2023<br>b | <i>Automated recognition of epilepsy from EEG signals using a combining space-time algorithm of CNN-LSTM</i>                                        | Wang <i>et al.</i>             |
| 8  | 2024      | <i>Automatic detection of epilepsy from EEGs using a temporal convolutional network with a self-attention layer</i>                                 | Huang <i>et al.</i>            |
| 9  | 2023      | <i>Detection and classification of adult epilepsy using hybrid deep learning approach</i>                                                           | Srinivasan <i>et al.</i>       |
| 10 | 2024      | <i>Detection Method of Epileptic Seizures Using a Neural Network Model Based on Multimodal Dual-Stream Networks</i>                                 | Wang <i>et al.</i>             |
| 11 | 2023      | <i>EEG-based epileptic seizure detection using binary dragonfly algorithm and deep neural network</i>                                               | Yogarajan <i>et al.</i>        |
| 12 | 2023      | <i>Machine learning-based classification of physiological and pathological high-frequency oscillations recorded by stereoelectroencephalography</i> | Li <i>et al.</i>               |
| 13 | 2024      | <i>Nonlinear analysis and recognition of epileptic EEG signals in different stages</i>                                                              | Lu <i>et al.</i>               |
| 14 | 2023<br>b | <i>Robust Epileptic Seizure Detection Using Long Short-Term Memory and Feature Fusion of Compressed Time-Frequency EEG Images</i>                   | Khan <i>et al.</i>             |
| 15 | 2023      | <i>XAI4EEG: spectral and spatio-temporal explanation of deep learning-based seizure detection in EEG time series.</i>                               | Raab; Theissler; Spiliopoulou. |

Fonte: Instrumento de coleta de dados elaborado pelos autores, 2025.

Em seguida, apresentou-se os artigos e as informações contidas em seu texto completo, incluindo tipo de estudo, tamanho da amostra e sua duração e o nível de evidência científica da publicação, representado no Quadro 3.

**Quadro 3:** Distribuição dos artigos de acordo com acurácia, AUC, modelos utilizados, delineamento do estudo, níveis de evidência científica do artigo.

| Nº do artigo | ACC    | AUC         | Modelo IA      | Banco de Dados                     | Nível de Evidência |
|--------------|--------|-------------|----------------|------------------------------------|--------------------|
| 1            | 99,35% | 99,34%      | CNN-GRU-AM     | CHB-MIT (23)                       | Moderado           |
| 2            | 98,85% | -           | kNN            | CHB-MIT (23) + Bonn (25)           | Moderado           |
| 3            | 98,65% | -           | RF + CNN       | Bonn (25) + New Delhi (10)         | Moderado           |
| 4            | 94,78% | -           | TL + AlexNet   | Bonn (25)                          | Moderado           |
| 5            | 98,52% | -           | PCNN + Bi-LSTM | CHB-MIT (23) + Bonn (25)           | Moderado           |
| 6            | 87,97% | 89,0%-96,0% | CNN            | Haukeland (30.493)                 | Alta               |
| 7            | 98,00% | 96,8%       | CNN + LSTM     | Bonn (25)                          | Moderado           |
| 8            | 95,50% | 95,0%       | TCN + AM       | Shenzhen (35); Bonn (25)           | Moderado           |
| 9            | 99,08% | -           | CNN + Bi-LSTM  | CHB-MIT (16)                       | Moderado           |
| 10           | 99,69% | -           | CNN + LSTM     | Bonn (25) + New Delhi (10)         | Moderado           |
| 11           | 100%   | -           | DNN            | Bonn (25)                          | Moderado           |
| 12           | 86,30% | 90,0%       | CNN            | Tiantan (17); Fengtai Hospital (9) | Moderado           |
| 13           | 95,20% | 99,9%       | CNN            | New Delhi (10)                     | Moderado           |
| 14           | 97,00% | -           | RNN + LSTM     | Bonn (25)                          | Moderado           |
| 15           | 90,06% | -           | CNN + SHAP     | Helsinki University (79)           | Moderado           |

Legenda: ACC: Acurácia; AM: Attention mechanism; AUC: Área sob a curva; CNN: Convolutional Neural Network; DNN: Deep neural network; GRU: Gated recurrent unit; kNN: k Nearest Neighbour; LSTM: Long Short-Term Memory; PCNN: Pyramid Convolutional Neural Network; RNN: Recurrent Neural Network; SHAP: SHapley Additive exPlanations; TCN: Temporal convolutional neural network; TL: Transfer Learning.

Fonte: Instrumento de coleta de dados elaborado pelos autores, 2025.

#### 4 DISCUSSÃO

O EEG é um exame essencial no diagnóstico da epilepsia, pois permite identificar padrões característicos da doença por meio do registro da atividade elétrica cerebral, devendo ser realizado em vigília e sono, com técnicas de sensibilização para aumentar sua sensibilidade. A ausência de alterações epileptiformes não exclui o diagnóstico de epilepsia, já que as descargas podem não ocorrer durante o exame ou estar localizadas em áreas profundas não acessíveis aos eletrodos de superfície (Thomas *et al.*, 2021). Assim, os achados devem sempre ser interpretados à luz do quadro clínico. Em casos de suspeita com EEG normal, recomenda-se a repetição do exame, pois a realização de até três registros aumenta significativamente sua positividade, desde que seja conduzido com metodologia adequada e interpretado por profissional experiente (Marchetti, 2024).

A integração da IA no diagnóstico de epilepsia via EEG representa uma mudança de paradigma na neurologia clínica, visando mitigar a subjetividade e a carga de trabalho exaustiva associada à análise manual (Wang *et al.*, 2024). A discussão atual gira em torno da transição de modelos de detecção simples para sistemas complexos de interpretação automatizada que alcançam desempenho equivalente ao de especialistas humanos (Tveit *et al.*, 2023).

Estudos recentes, como o desenvolvimento do modelo SCORE-AI, demonstram que a IA pode não apenas distinguir entre exames normais e anormais, mas também classificar anomalias em categorias clinicamente relevantes, como atividades epileptiformes focais ou generalizadas. O SCORE-AI apresentou uma acurácia média de 88,3%, superando modelos anteriores de detecção de espículas e equiparando-se a especialistas humanos, o que é crucial para reduzir o erro diagnóstico, a causa mais comum de tratamentos inadequados para epilepsia (Tveit *et al.*, 2023). Além disso, técnicas de aprendizado por transferência (*transfer learning*) com modelos como o AlexNet têm sido eficazes para lidar com o problema de amostras pequenas, permitindo que conhecimentos de domínios de imagem sejam aplicados com sucesso ao processamento de sinais de EEG (Zhang *et al.*, 2024b).

A pesquisa desenvolvida por Srinivasan *et al.* (2023) focou na identificação de crises a partir de sinais de EEG multicanal brutos com processamento mínimo. A inovação central consistiu no uso de um Autoencoder de Convolução Profunda 3D (3D-DCAE) para o aprendizado automático de características, eliminando a necessidade de extração manual exaustiva. O modelo híbrido rotulado (LHCAE), que combina esse codificador a um classificador de LSTM, apresentou o melhor desempenho com janelas de sinal de 4 segundos. O sistema atingiu uma acurácia de 99,08% e sensibilidade de 99,21% no dataset CHB-MIT, destacando-se pela redução de parâmetros e eficiência computacional para aplicações em tempo real.

Chen e colaboradores (2023) propuseram uma abordagem fundamentada na fusão e seleção de características multivariadas para o reconhecimento automático de crises epiléticas. O estudo utilizou a *Discrete Wavelet Transform* (DWT) para decompor os sinais em sub-bandas, extraindo medidas de entropia e desvio padrão. O principal achado foi a eficácia do algoritmo RF na seleção das 10 características mais relevantes, o que reduziu a redundância e otimizou o desempenho da CNN. Os resultados demonstraram uma acurácia de 99,9% na base de dados de *Bonn* e alcançaram a marca de 100% de acurácia, sensibilidade e especificidade no conjunto de dados de *New Delhi*, superando modelos tradicionais.

Yogarajan *et al.* (2023) introduziram uma técnica baseada em inteligência de enxame para otimizar a detecção de crises via EEG. A metodologia também empregou a DWT para extrair parâmetros estatísticos do exame. Os resultados revelaram que o sistema foi capaz de atingir 100% de acurácia, sensibilidade e especificidade utilizando apenas um subconjunto de 13% das características originais selecionadas. Este achado ressalta que a seleção inteligente de dados permite que RNN treinem de forma significativamente mais rápida, mantendo a máxima precisão mesmo em conjuntos de dados desequilibrados.

A eficácia dos sistemas de detecção foi significativamente aprimorada pelo uso de modelos híbridos que capturam dependências espaciais e temporais. Entre eles, destacam-se as arquiteturas espaçotemporais, com a combinação de CNN com LSTM ou GRU permite que o sistema “lembre” estados anteriores do sinal, identificando tendências de mudança que modelos independentes ignoram (Wang *et al.*, 2023b; Zhang *et al.* 2024a).

Além disso, métodos como Reconstrução de Espaço de Fase (PSR) e Seção de Poincaré (PS) revelaram que o cérebro passa por estados “pré-cursors” antes de uma

crise real, permitindo a identificação de sinais pré-ictais com acurácia superior a 93% (Lu *et al.*, 2024). O uso de classificadores como o RUSBoost para diferenciar Oscilações de Alta Frequência (HFOs) patológicos de fisiológicos é fundamental para localizar com precisão a zona epileptogênica em cirurgias de epilepsia, evitando o risco de remover áreas funcionais vitais do cérebro (Li *et al.*, 2023).

Para que a IA seja integrada ao cotidiano clínico, há uma necessidade crescente de redes neurais leves (*lightweight*). O uso de Autoencoders Rasos (*Shallow Autoencoders*) e modelos como o PCNN-BiLSTM reduz drasticamente a carga computacional, permitindo a implementação em dispositivos vestíveis (*wearables*) para monitoramento ambulatorial. Esses sistemas são capazes de processar sinais de canal único com alta precisão, o que aumenta o conforto do paciente e viabiliza o acompanhamento prolongado fora do ambiente hospitalar (Khan *et al.*, 2023a; Wang *et al.*, 2023a).

Apesar dos avanços aqui discutidos, existem algumas limitações nesse processo. O próprio exame de EEG possui baixa relação sinal-ruído e é altamente suscetíveis a interferências ambientais e movimentos do paciente, o que pode elevar as taxas de falsos positivos em modelos que não utilizam técnicas robustas de pré-processamento ou aumento de dados (Huang *et al.*, 2024). Além disso, muitos modelos são treinados em bases de dados específicas (como o dataset Bonn ou CHB-MIT), mas falham ao serem aplicados no mundo real com populações diversas ou tipos de crises não representados no treinamento (Wang *et al.*, 2023b). Por fim, a natureza de “*black box*” das IAs, que escapa da capacidade de compreensão humana, gera desconfiança médica. Ferramentas como o XAI4EEG, que utilizam SHAP para visualizar as contribuições espectrais e espaciais de cada decisão do modelo, são fundamentais para que o clínico valide a predição da IA com confiança (Raab; Theissler; Spiliopoulou., 2023).

Os artigos selecionados possuem robustas diretrizes metodológicas, mas, no geral, não apresentaram comparação de eficácia com médicos, não apresentaram valores de AUR/ROC e o banco de dados usado para treinamento da IA e o mesmo utilizado para avaliar/testar o modelo, o que impossibilita a avaliação de *overfitting*, ou seja, quando a análise da IA corresponde muito de perto ou exatamente a um conjunto específico de dados e pode, portanto, não se ajustar a dados adicionais advindos de outros equipamentos em outras localidades, ou prever observações futuras de forma confiável.

## 5 CONCLUSÃO

A aplicação da IA no diagnóstico da epilepsia por meio do EEG representa um avanço promissor na área da neurologia, oferecendo maior precisão, agilidade e suporte à tomada de decisão clínica, porém desafios ainda persistem, como a padronização dos dados, a generalização dos modelos para diferentes populações e a necessidade de validação em ambientes clínicos reais. Assim, embora os resultados atuais sejam encorajadores, mais estudos multicêntricos e com amostras representativas, com múltiplas origens, são essenciais para consolidar o uso da IA como ferramenta complementar no diagnóstico da epilepsia. O futuro aponta para uma integração cada vez mais sólida entre tecnologia e prática médica, visando diagnósticos mais precoces e intervenções mais eficazes.

## REFERÊNCIAS

- BRASIL. Ministério da saúde. Secretaria de ciência, tecnologia e insumos estratégicos. Departamento de ciência e tecnologia. **Diretrizes metodológicas: sistema grade-manual de graduação da qualidade da evidência e força de recomendação para tomada de decisão em saúde**. 2014.
- CHEN, W. *et al.* An automated detection of epileptic seizures EEG using CNN classifier based on feature fusion with high accuracy. **Bmc Medical Informatics and Decision Making**, v. 23, n. 1, p. 96, 2023.
- GAJIC, D. *et al.* Detection of epileptiform activity in EEG signals based on time-frequency and non-linear analysis. **Frontiers in computational neuroscience**, v. 9, n.1, p. 38, 2015.
- HUANG, L. *et al.* Automatic detection of epilepsy from EEGs using a temporal convolutional network with a self-attention layer. **BioMedical Engineering OnLine**, v. 23, n. 1, p. 50, 2024.
- KHAN, G. H. *et al.* A shallow autoencoder framework for epileptic seizure detection in EEG signals. **Sensors**, v. 23, n. 8, p. 4112, 2023a.
- KHAN, Shafi Ullah; JAN, Sana Ullah; KOO, Insoo. Robust epileptic seizure detection using long short-term memory and feature fusion of compressed time–frequency EEG images. **Sensors**, v. 23, n. 23, p. 9572, 2023b.
- LI, Zilin *et al.* Machine learning-based classification of physiological and pathological high-frequency oscillations recorded by stereoelectroencephalography. **Seizure: European Journal of Epilepsy**, v. 113, n. 2, p. 58-65, 2023.
- LU, X. *et al.* Nonlinear analysis and recognition of epileptic EEG signals in different stages. **Journal of Neurophysiology**, v. 132, n. 3, p. 685-694, 2024.
- MARCHETTI, R. L. **Manual Prático de Neuropsiquiatria da Epilepsia**. Rio de Janeiro: Grupo GEN, 2019. *E-book*. ISBN 9788595150836. Brasil, 2024.
- OTO, M. M. The misdiagnosis of epilepsy: appraising risks and managing uncertainty. **Seizure**, v. 44, n. 2, p. 143-146, 2017.
- PRESSLER, R. M. *et al.* The ILAE classification of seizures and the epilepsies: Modification for seizures in the neonate. Position paper by the ILAE Task Force on Neonatal Seizures. **Epilepsia**, v. 62, n. 3, p. 615-628, 2021.

RAAB, Dominik; THEISSLER, Andreas; SPILIOPOULOU, Myra. XAI4EEG: spectral and spatio-temporal explanation of deep learning-based seizure detection in EEG time series. **Neural Computing and Applications**, v. 35, n. 14, p. 10051-10068, 2023.

SHOEIBI, A. *et al.* Epileptic seizures detection using deep learning techniques: a review. **International journal of environmental research and public health**, v. 18, n. 11, p. 5780, 2021.

SRINIVASAN, S. *et al.* Detection and classification of adult epilepsy using hybrid deep learning approach. **Scientific reports**, v. 13, n. 1, p. 17574, 2023.

THOMAS, J. *et al.* Automated adult epilepsy diagnostic tool based on interictal scalp electroencephalogram characteristics: A six-center study. **International journal of neural systems**, v. 31, n. 05, p. 2050074, 2021.

TOPOL, E. J. High-performance medicine: the convergence of human and artificial intelligence. **Nature medicine**, v. 25, n. 1, p. 44-56, 2019.

TVEIT, J. *et al.* Automated interpretation of clinical electroencephalograms using artificial intelligence. **JAMA neurology**, v. 80, n. 8, p. 805-812, 2023.

WANG, B. *et al.* Detection method of epileptic seizures using a neural Network Model based on Multimodal Dual-Stream Networks. **Sensors**, v. 24, n. 11, p. 3360, 2024.

WANG, Chenlong *et al.* An epileptic EEG detection method based on data augmentation and lightweight neural network. **IEEE Journal of Translational Engineering in Health and Medicine**, v. 12, n. 1, p. 22-31, 2023a.

WANG, X. *et al.* Automated recognition of epilepsy from EEG signals using a combining space-time algorithm of CNN-LSTM. **Scientific Reports**, v. 13, n. 1, p. 14876, 2023b.

YOGARAJAN, G. *et al.* EEG-based epileptic seizure detection using binary dragonfly algorithm and deep neural network. **Scientific Reports**, v. 13, n. 1, p. 17710, 2023.

ZHANG, J. *et al.* A scheme combining feature fusion and hybrid deep learning models for epileptic seizure detection and prediction. **Scientific Reports**, v. 14, n. 1, p. 16916, 2024a.

ZHANG, Q.; LI, C.; DING, Y. An epilepsy diagnosis method based on a transferred alexnet model and eeg signals. **Journal of Mechanics in Medicine and Biology**, v. 24, n. 02, p. 2440005, 2024b.