

# Uso de Inteligência Artificial na detecção e mapeamento de Acidente Vascular Cerebral (AVC): Uma revisão sistemática da Literatura

Lara Emanuely da Silva Santos<sup>1</sup>

<sup>1</sup>Instituto Federal de Educação, Ciência e Tecnologia do Maranhão  
Ciência da Computação

2

emanuellysilva@acad.ifma.edu.br

**Abstract.** *Stroke is one of the leading causes of mortality and disability, requiring rapid diagnosis to minimize neurological damage. This study analyzes recent research that applies Artificial Intelligence (AI) techniques for the detection and segmentation of ischemic and hemorrhagic lesions in computed tomography (CT) and magnetic resonance imaging (MRI). The review was conducted using the PubMed, IEEE Xplore, and Scopus databases, totaling 27 articles with models such as CNNs, U-Net, DenseNet, and Vision Transformers. The results indicate that AI can improve diagnostic accuracy and reduce processing time. However, further clinical validation and better integration into hospital workflows are still required.*

**Resumo.** *O acidente vascular cerebral (AVC) é uma das principais causas de mortalidade e incapacidade, exigindo diagnóstico rápido para minimizar danos neurológicos. Este estudo analisa pesquisas recentes que utilizam técnicas de Inteligência Artificial (IA) na detecção e segmentação de lesões isquêmicas e hemorrágicas em exames de tomografia computadorizada (CT) e ressonância magnética (MRI). A revisão foi realizada nas bases PubMed, IEEE Xplore e Scopus, totalizando 27 artigos com modelos como CNNs, U-Net, DenseNet e Vision Transformers. Os resultados indicam que a IA pode aumentar a acurácia diagnóstica e reduzir o tempo de processamento. No entanto, ainda são necessárias validações clínicas e maior integração aos fluxos hospitalares.*

## 1. Introdução

O Acidente Vascular Cerebral (AVC) representa um grave problema de saúde pública global, e ocorre quando há interrupção ou redução no fluxo sanguíneo para o cérebro. Segundo a Organização Mundial da Saúde (WHO, 2025), cerca de 15 milhões de pessoas sofrem AVC anualmente, com aproximadamente um terço evoluindo para óbito e outro terço apresentando sequelas significativas. O diagnóstico rápido é essencial, já que o dano neurológico progride rapidamente sem intervenção adequada. O princípio clínico “*time is brain*” expressa a urgência na identificação precoce e manejo correto do AVC (SHETH *et al.*, 2023).

Diante dessas limitações, torna-se relevante investigar o diagnóstico predominantemente em exames de imagem, como tomografia computadorizada (CT) e ressonância

magnética (MRI), sendo que alterações iniciais podem ser discretas, especialmente em CT, o que dificulta a interpretação por profissionais menos experientes (BOJSEN *et al.*, 2024). Em cenários de alta demanda ou regiões com escassez de especialistas, esta limitação é ainda mais crítica.

Nesse contexto, a Inteligência Artificial (IA) surge como ferramenta complementar, utilizando modelos de deep learning capazes de detectar automaticamente lesões isquêmicas e hemorrágicas, mapear a penumbra isquêmica e classificar regiões vasculares afetadas (LEE *et al.*, 2023). Arquiteturas modernas incluem CNNs customizadas, EnigmaNet, redes com atenção e otimizações inspiradas em algoritmos genéticos aplicadas a *EfficientNet* (SOBHANA *et al.*, 2025; XUE *et al.*, 2025). Soluções de *Edge Computing e Internet of Medical Things* (IoMT) permitem expandir a aplicação de IA para hospitais com infraestrutura limitada (ELSHEIKH *et al.*, 2024). O objetivo deste trabalho é revisar sistematicamente a literatura, avaliando técnicas de IA, modalidades de imagem, desempenho e limitações, e fornecer um panorama crítico sobre seu uso clínico.

## 2. Fundamentação Teórica

### 2.1. AVC e Diagnóstico por Imagens

A detecção precoce do AVC isquêmico é essencial, visto que a isquemia evolui rapidamente para necrose sem intervenção (LEE *et al.*, 2023). Nesse contexto, diferentes modalidades de imagem apresentam vantagens e limitações. A MRI destaca-se pela alta sensibilidade na detecção de alterações isquêmicas hiperagudas, permitindo identificar lesões sutis em estágios iniciais (HUANG, 2024). Em contrapartida, a CT é amplamente utilizada em ambientes de emergência devido à sua rapidez e maior disponibilidade, sendo mais eficiente na detecção de hemorragias (APARNA *et al.*, 2025). Essa diferença evidencia um *trade-off* importante: enquanto a MRI oferece maior precisão diagnóstica, sua menor acessibilidade e maior tempo de aquisição limitam seu uso em cenários críticos. Dessa forma, a escolha da modalidade depende não apenas da acurácia, mas também de fatores operacionais e clínicos.

### 2.2. Inteligência Artificial e Deep Learning

O uso de Inteligência Artificial na análise de imagens médicas tem crescido, com destaque para redes neurais convolucionais (CNNs), amplamente utilizadas em classificação e segmentação (YADAV *et al.*, 2023). Arquiteturas como U-Net tornaram-se referência pela capacidade de preservar informações espaciais relevantes (SINHA *et al.*, 2024; VISWAPRIYA & RAJESWARI, 2024). Modelos mais recentes, como *Vision Transformers*, apresentam potencial em cenários complexos, porém exigem maior volume de dados e poder computacional (GNANABASKARAN *et al.*, 2025; KHALIQ *et al.*, 2025). Assim, há divergências na literatura, sendo que CNNs ainda se mostram mais estáveis em *datasets* reduzidos.

Em suma, a literatura demonstra que técnicas de Inteligência Artificial, especialmente modelos baseados em deep learning, apresentam alto potencial na detecção e segmentação de lesões associadas ao AVC, com destaque para arquiteturas como CNNs e U-Net, além do avanço recente de modelos como *Vision Transformers*. Observa-se também que a escolha da modalidade de imagem, como MRI ou CT, influencia diretamente o desempenho dos modelos, envolvendo um equilíbrio entre precisão diagnóstica e

viabilidade clínica. Apesar dos avanços, persistem limitações relacionadas à disponibilidade de dados, generalização dos modelos e validação em cenários reais. Nesse contexto, este estudo se insere ao realizar uma revisão sistemática da literatura, buscando analisar de forma crítica as técnicas utilizadas, suas aplicações, desempenhos e limitações, contribuindo para uma compreensão mais aprofundada do uso clínico da IA no diagnóstico do AVC.

### 3. Metodologia

#### 3.1. Protocolo de Pesquisa

##### 3.1.1. Questões de Pesquisa

1. Quais técnicas de IA têm sido aplicadas na detecção e mapeamento do AVC?
2. Quais modalidades de imagem (MRI/CT) são utilizadas?
3. Quais métricas, resultados, limitações e desafios são reportados?

##### 3.1.2. Estratégias de Busca

As bases consultadas foram IEEE Xplore, PubMed e ScienceDirect. *String* de busca utilizada:

("Artificial intelligence"OR "deep learning") AND ("stroke") AND ("detection"OR "brain mapping") AND ("MRI")

Período considerado: últimos 5 anos.

##### 3.1.3. Critérios de Inclusão e Exclusão

**Inclusão:** estudos primários, aplicação de IA em AVC, uso de MRI ou CT, métricas quantitativas reportadas (acurácia, sensibilidade, especificidade, Dice).

**Exclusão:** revisões, *surveys*, meta-análises, estudos sem métricas, trabalhos irrelevantes, literatura cinza e idiomas fora de português ou inglês.

#### 3.2. Avaliação da Qualidade

Foram aplicados sete critérios: clareza dos objetivos, contextualização da amostra, contexto clínico, descrição da intervenção, avaliação de desempenho, evidências clínicas e limitações. Cada estudo recebeu pontuação de 0 a 7, sendo 5 considerado de alta qualidade (71%).

#### 3.3. Execução da Pesquisa

A busca inicial retornou 168 estudos. Após triagem de título, resumo, leitura completa e remoção de duplicidades, 27 artigos foram incluídos na análise final.

### 3.4. Ameaças à Validade

As principais ameaças incluem:

- **Viés de publicação:** bases priorizam estudos com resultados positivos.
- **Limitação temporal:** estudos anteriores a 5 anos foram excluídos.
- **Viés linguístico:** apenas inglês e português.
- **Generalização clínica:** maioria dos estudos com *datasets* retrospectivos de centros únicos.
- **Dependência de *datasets* retrospectivos:** pode superestimar desempenho em cenários reais.

## 4. Análise dos Resultados

### 4.1. Técnicas de Inteligência Artificial

A técnica predominante identificada foi o uso de CNNs, devido à sua capacidade de extrair padrões espaciais e texturais complexos em imagens cerebrais, contribuindo para a detecção precoce de lesões sutis. Modelos baseados em U-Net e variantes com mecanismos de atenção apresentaram desempenho consistente em tarefas de segmentação (SINHA *et al.*, 2024; VISWAPRIYA & RAJESWARI, 2024), enquanto redes DenseNet demonstraram melhorias na detecção em MRI ao capturar características mais profundas (VARSHITH *et al.*, 2025). Abordagens mais recentes, como *Vision Transformers*, mostraram capacidade de capturar dependências de longo alcance nas imagens, ao passo que métodos híbridos (CNN+SVM ou algoritmos genéticos) apresentaram vantagens em cenários com *datasets* pequenos ou heterogêneos (GNANABASKARAN *et al.*, 2025; PRATHIMA *et al.*, 2025). De modo geral, observa-se que a escolha da técnica está diretamente relacionada ao tipo e à disponibilidade dos dados.

### 4.2. Modalidades de Imagem Utilizadas

A MRI predominou nas tarefas de segmentação e análise detalhada, devido à sua maior sensibilidade na identificação de alterações isquêmicas. Em contrapartida, a CT mostrou-se mais utilizada em contextos emergenciais, principalmente pela rapidez e disponibilidade. O uso combinado de abordagens multimodais, integrando CT e MRI, tem demonstrado potencial para melhorar a precisão diagnóstica, embora aumente a complexidade dos modelos (AVANEESH *et al.*, 2025).

### 4.3. Métricas de Desempenho

Em tarefas de segmentação, modelos como o EnigmaNet atingiram *Dice Score* superior a 0,90, indicando alta concordância com segmentações manuais. Para classificação e detecção, CNNs customizadas reportaram acurácia superior a 95% (NAIK & VIDYA-SAGAR, 2025; VICKRAM & BHAVANI, 2025). Além disso, valores equilibrados de sensibilidade e especificidade sugerem boa capacidade de identificar casos positivos sem aumento significativo de falsos positivos (SUREKHA *et al.*, 2025), embora esses resultados dependam das características dos *datasets* utilizados.

#### 4.4. Limitações Reportadas

As principais limitações identificadas incluem o tamanho reduzido dos *datasets*, a baixa diversidade populacional e a ausência de validação clínica em cenários reais (CHÓI *et al.*, 2021; AVANEESH *et al.*, 2025; SHETH *et al.*, 2023). Além disso, fatores como qualidade de imagem, presença de ruídos e variações nos protocolos de aquisição podem impactar diretamente o desempenho dos modelos (BOJSEN *et al.*, 2024), indicando desafios para sua aplicação prática.

#### 4.5. Síntese dos Estudos Primários

A Tabela 1 sintetiza os 27 estudos analisados, destacando autor/ano, técnica utilizada, modalidade de imagem, métricas de desempenho e limitações. Os 10 estudos mais relevantes para esta pesquisa estão destacados, permitindo uma visão comparativa das principais abordagens e seus resultados.

**Tabela 1. Síntese dos Estudos Primários**

Autor/Ano	Técnica de IA	Modalidade	Evidência	Métricas	Limitações
Aparna <i>et al.</i> (2025)	DeepLabV3+	CT	Segmentação	Dice, Acc	Sensível a ruído
Avaneesh <i>et al.</i> (2025)	Multimodal DL	MRI + Dados clínicos	Validação clínica	Acc, AUC	Alta complexidade
Ayesha & Sheshadri (2024)	CNN	MRI	Classificação	Acc, Sens	Dataset reduzido
Bojsen <i>et al.</i> (2024)	Revisão sistemática	MRI	Evidência secundária	—	Dependência dos estudos
Choi <i>et al.</i> (2021)	DL + Biossinais	Multimodal	Predição clínica	Acc	Dados limitados
El-Sheikh <i>et al.</i> (2024)	CNN + IoMT	CT	Classificação	Acc, Spec	Sem validação real
Gnanabaskaran <i>et al.</i> (2025)	VGG16 + SVM	MRI	Classificação	Acc	Base pequena
Huang (2024)	CNN	MRI	Segmentação	Dice	Avaliação retrospectiva
Khaliq <i>et al.</i> (2025)	Vision Transformers	Multimodal	Classificação	Acc, F1	Não específico para AVC
Lee <i>et al.</i> (2023)	CNN	MRI	Classificação	Acc, Sens	Base monocêntrica
Liu <i>et al.</i> (2022)	ML aplicado à reabilitação	Multimodal	Avaliação clínica	—	Não focado em detecção
Naik & Vidyasagar (2025)	CNN customizada	MRI	Classificação	Acc > 95%	Dataset restrito
Patil & Govindaraj (2023)	CNN	MRI	Classificação	Acc	Comparação limitada
Prathima <i>et al.</i> (2025)	Algoritmo Genético	MRI	Classificação	Acc	Alto custo computacional
Santos (2024)	Protocolo RSL	—	Metodológico	—	Documento teórico
Sheth <i>et al.</i> (2023)	ML aplicado à imagem	CT/MRI	Análise clínica	—	Discussão conceitual
Shokri <i>et al.</i> (2024)	DL	Multimodal	Predição clínica	AUC	População específica
Sinha <i>et al.</i> (2024)	EnigmaNet (U-Net)	MRI	Segmentação	Dice > 0.90	Retrospectivo
Sobhana <i>et al.</i> (2025)	DL + Edge Computing	MRI	Classificação	Acc	Infraestrutura
Surekha <i>et al.</i> (2025)	Ensemble CNN	MRI	Classificação	Acc, Sens	Base homogênea
Tan & Marvell (2023)	Revisão sistemática	MRI	Evidência secundária	—	Não experimental
Varshith <i>et al.</i> (2025)	DenseNet	MRI	Classificação	Acc > 95%	Falta validação externa
Vickram & Sowndharya (2025)	DL	MRI	Classificação	Acc	Testes limitados
Viswapriya & Rajeswari (2024)	U-Net com atenção	MRI	Segmentação	Dice	Base reduzida
WHO (2025)	Relatório institucional	—	Epidemiológico	—	Dados agregados
Xue <i>et al.</i> (2025)	CNN otimizada	MRI	Segmentação	Dice, Acc	Otimização complexa
Yadav <i>et al.</i> (2023)	CNN escalável	MRI	Classificação	Acc	Pouca diversidade

## 5. Discussão

A análise dos estudos indica que técnicas de deep learning, especialmente CNNs, apresentam desempenho significativo na detecção e segmentação de lesões associadas ao AVC, devido à capacidade de extrair padrões complexos em imagens médicas. Essas abordagens tendem a ser mais eficazes em cenários com grande volume de dados e boa qualidade de imagem, mas podem apresentar limitações em *datasets* reduzidos ou heterogêneos, o que impacta sua generalização em contextos clínicos reais.

Arquiteturas como U-Net destacam-se em tarefas de segmentação por preservar informações espaciais relevantes, apresentando resultados consistentes. Por outro lado, modelos mais recentes, como *Vision Transformers* e abordagens híbridas, demonstram potencial em cenários mais complexos, ao capturar dependências globais nas imagens. No entanto, esses modelos exigem maior poder computacional e grandes volumes de dados, o

que limita sua aplicação prática, evidenciando uma divergência entre desempenho teórico e viabilidade em ambientes hospitalares.

Em relação às modalidades de imagem, a MRI apresenta maior sensibilidade na detecção de alterações isquêmicas precoces, enquanto a CT se destaca pela rapidez e maior disponibilidade em contextos de emergência. Na prática, essa diferença implica que modelos baseados em MRI tendem a oferecer maior precisão diagnóstica, enquanto soluções baseadas em CT são mais viáveis em cenários de tempo crítico. Abordagens multimodais podem aumentar a acurácia, porém elevam a complexidade e os requisitos de infraestrutura.

Apesar dos avanços, limitações como baixa diversidade dos *datasets*, uso predominante de bases retrospectivas e ausência de validação clínica robusta ainda dificultam a aplicação em larga escala. Além disso, fatores como qualidade de imagem e variações nos protocolos de aquisição influenciam diretamente o desempenho dos modelos, podendo comprometer sua confiabilidade em situações reais.

Do ponto de vista prático, a Inteligência Artificial apresenta potencial como ferramenta de apoio ao médico, auxiliando na triagem, detecção precoce e análise de exames. Sua aplicação pode reduzir o tempo de diagnóstico e aumentar a precisão, especialmente em ambientes com alta demanda. No entanto, essas tecnologias ainda não substituem o especialista, sendo utilizadas como suporte à tomada de decisão clínica.

Este estudo teve como objetivo analisar técnicas de IA aplicadas à detecção e mapeamento do AVC. Como contribuição, apresenta uma síntese crítica da literatura recente, organizando as principais abordagens e evidenciando seus desempenhos, limitações e desafios para aplicação clínica.

## 6. Considerações Finais

Esta revisão sistemática permitiu identificar avanços significativos no uso de técnicas de inteligência artificial para detecção e mapeamento do Acidente Vascular Cerebral (AVC) a partir de exames de imagem médica. A análise dos estudos selecionados demonstra que métodos baseados em deep learning, especialmente arquiteturas como U-Net e DenseNet, apresentam desempenho promissor em tarefas de segmentação e classificação de lesões cerebrais. Esses modelos têm se mostrado capazes de identificar padrões complexos em imagens de tomografia computadorizada e ressonância magnética, contribuindo para a detecção precoce do AVC e potencialmente auxiliando profissionais de saúde no processo de diagnóstico e tomada de decisão clínica.

Os resultados observados na literatura também indicam que a ressonância magnética tem sido amplamente utilizada nos estudos analisados devido à sua elevada sensibilidade na identificação de alterações isquêmicas em estágios iniciais da doença. No entanto, a tomografia computadorizada continua desempenhando papel fundamental no contexto clínico, especialmente em situações de emergência, devido à sua rapidez de aquisição e ampla disponibilidade em ambientes hospitalares. Nesse cenário, abordagens que combinam diferentes modalidades de imagem e integram dados clínicos adicionais apresentam potencial significativo para aumentar a precisão diagnóstica e melhorar o suporte à tomada de decisão médica.

Apesar dos avanços identificados, alguns desafios ainda precisam ser superados

para que essas tecnologias possam ser amplamente adotadas na prática clínica. Entre as principais limitações observadas destacam-se a heterogeneidade dos conjuntos de dados utilizados nos estudos, a baixa diversidade populacional das bases disponíveis e a predominância de análises baseadas em dados retrospectivos. Esses fatores podem limitar a capacidade de generalização dos modelos quando aplicados em diferentes contextos clínicos e populações de pacientes.

Diante disso, pesquisas futuras devem priorizar a construção de bases de dados mais amplas, diversificadas e representativas, bem como a realização de estudos clínicos multicêntricos que permitam avaliar o desempenho dos modelos em condições reais de uso. Além disso, o desenvolvimento de modelos mais robustos, interpretáveis e integrados aos sistemas hospitalares representa um passo fundamental para consolidar o uso da inteligência artificial como ferramenta de apoio confiável no diagnóstico precoce e no manejo clínico do Acidente Vascular Cerebral.

## 7. Referências

### Referências

- APARNA, T. e. a. (2025). Enhanced stroke detection in ct imaging via deeplabv3+ and multi-scale feature learning. In *2025 IEEE International Conference on Advanced Visual and Signal-Based Systems, Genebra*. IEEE.
- AVANEESH, C.; GOUD, P. R. K. (2025). Ai-driven multimodal prognosis in stroke: integrating neuroimaging and longitudinal clinical data. In *2025 International Conference on Biomedical Engineering, Genebra*. IEEE.
- AYESHA, N.; SHESHADRI, H. S. (2024). Deep learning technique for detecting and analysing ischemic stroke using mri images. In *2024 IEEE ICDCOT, Genebra*. IEEE.
- BOJSEN, J. A. e. a. (2024). Artificial intelligence for mri stroke detection: a systematic review and meta-analysis. *Insights into Imaging*, 15:160.
- CHOI, Y.-A. e. a. (2021). Deep learning-based stroke disease prediction system using real-time bio signals. *Sensors*, 21(13):4269.
- EL-SHEIKH, M. M. e. a. (2024). Enhancing acute ischemic stroke diagnosis using iomt and deep learning technologies. Technical report, Galala University, Cairo, Egito.
- GNANABASKARAN, A. e. a. (2025). An intelligent framework for early detection of brain strokes using vgg16 and svm. In *2025 IEEE ICECCC, Genebra*. IEEE.
- HUANG, R. (2024). Leveraging cnn for automated lesion detection in stroke mri scans. In *2024 IEEE ICC, Genebra*. IEEE.
- KHALIQ, A. e. a. (2025). Ai-powered medical diagnosis: Vision transformers and perceiver io for multi-disease detection. *Computational Biology and Chemistry*, page 108586.
- LEE, K.-Y. e. a. (2023). Automatic detection and vascular territory classification of hyperacute staged ischemic stroke. *Scientific Reports*, 13:404.
- LIU, K.; YIN, M. C. Z. (2022). Research and application advances in rehabilitation assessment of stroke. *Journal of Zhejiang University. Science B*, 23(8).

- NAIK, Y.; VIDYASAGAR, K. B. (2025). Early detection of brain strokes from mr images using a customized cnn. In *2025 IEEE ICDSIS, Genebra*. IEEE.
- ORGANIZAÇÃO MUNDIAL DA SAÚDE (2025). Global health estimates.
- PATIL, A.; GOVINDARAJ, S. (2023). An ai enabled framework for mri-based data analytics for efficient brain stroke detection. In *2023 IEEE ACCAI, Genebra*. IEEE.
- PRATHIMA, C. e. a. (2025). A novel approach for early brain stroke detection using genetic algorithm. In *2025 IEEE ICDT, Genebra*. IEEE.
- SANTOS, L. E. S. (2024). Protocolo rsl: uso de inteligência artificial na detecção e mapeamento de AVC. Documento de protocolo.
- SHETH, S. A. e. a. (2023). Machine learning and acute stroke imaging. *Journal of NeuroInterventional Surgery*, 15(2).
- SHOKRI, M. J. e. a. (2024). Decoding stroke patterns: a novel deep learning approach to atrial fibrillation risk stratification. In *2024 IEEE DICTA, Genebra*. IEEE.
- SINHA, S. e. a. (2024). Enigmanet: a novel attention-enhanced segmentation framework for ischemic stroke lesion detection in brain mri. *IEEE Access*, 12.
- SOBHANA, M. e. a. (2025). Edge computing for brain stroke detection using deep learning techniques. In *2025 IEEE ICOECA, Genebra*. IEEE.
- SUREKHA, Y. e. a. (2025). Advanced stroke prediction leveraging mri data with an ensemble cnn framework. In *2025 IEEE ICOECA, Genebra*. IEEE.
- TAN, K.; MARVELL, Y. A. (2023). Early ischemic stroke detection using deep learning: a slr. In *2023 IEEE iSemantic, Genebra*. IEEE.
- VARSHITH, S. V. e. a. (2025). Brain stroke detection using densenet algorithm. In *2025 IEEE GINOTECH, Genebra*. IEEE.
- VICKRAM, A. S.; SOWNDHARYA, B. B. (2025). Mri slice assisted ischemic-stroke detection using deep-learning scheme. In *2025 IEEE ICEARS, Genebra*. IEEE.
- VISWAPRIYA, S. E.; RAJESWARI, D. (2024). Attentive feature segmentation model for stroke detection on mri images. In *2024 IEEE BITCON, Genebra*. IEEE.
- XUE, X. e. a. (2025). An efficient deep learning network for brain stroke detection using salp shuffled shepherded optimization. *Scientific Reports*, 15:33516.
- YADAV, P. K. e. a. (2023). Mri based automatic brain stroke detection using cnn models improved with model scaling. In *2023 IEEE ICPCSN, Genebra*. IEEE.