

Segmentação de Acidente Vascular Cerebral Hemorrágico via Extração Hierárquica de Características e Contornos Ativos

Elene F. Ohata^{*§}, Hector L. M. Moreira^{†§}, Aldísio G. Medeiros^{‡§}, Suane P. P. da Silva^{†§},
José Daniel de A. Santos^{†§}, Atslands R. da Rocha^{*} e Pedro P. Rebouças Filho^{*†§}

^{*}Programa de Pós-Graduação em Engenharia de Teleinformática (PPGETI)

Universidade Federal do Ceará, Fortaleza, Ceará, Brazil

[†]Programa de Pós-Graduação em Ciências da Computação (PPGCC),

Instituto Federal do Ceará, Fortaleza, Ceará, Brasil

[‡]Universidade Federal do Ceará (UFC), Itapajé, Ceará, Brasil

[§]Laboratório de Processamento de Imagens, Sinais e Computação Aplicada (LAPISCO), Fortaleza, Brasil

Email do autor correspondente: pedrosarf@ifce.edu.br

Abstract—Hemorrhagic stroke remains a leading cause of mortality and disability worldwide, demanding accurate and timely diagnosis. This study proposes a hybrid segmentation method combining Convolutional Neural Networks (CNNs) with Active Contours to delineate hemorrhagic lesions in brain CT scans. The approach extracts hierarchical representations through a multi-scale CNN inspired by Cross Stage Partial (CSP) blocks and enhances interpretability via contextual activation maps. These maps guide both the internal energy and initialization of the active contour, yielding anatomically coherent segmentations. Quantitative evaluation on public and private datasets demonstrates the model's robustness and precision, with specificity, precision, and sensitivity of 99.96%, 96.41%, and 92.02%, respectively. Compared to state-of-the-art methods, the proposed architecture achieved competitive performance with improved anatomical consistency and reduced reliance on manual input. These findings support the method's potential for clinical decision support in stroke diagnosis.

Resumo—O acidente vascular cerebral (AVC) hemorrágico figura entre as principais causas de mortalidade e incapacitação no mundo, exigindo diagnóstico preciso e célere. Este estudo propõe um método híbrido de segmentação que combina Redes Neurais Convolucionais (RNC) com Contornos Ativos para a delimitação de lesões hemorrágicas em exames de tomografia computadorizada (TC) do crânio. A abordagem realiza extração hierárquica de características por meio de uma RNC multiescalar baseada em blocos *Cross Stage Partial* (CPS) e incorpora mapas de ativação contextual para guiar a energia interna e a inicialização do contorno ativo, promovendo segmentações morfolologicamente coerentes. A avaliação quantitativa em bases públicas e privadas demonstrou a robustez e precisão do modelo, especificidade de 99,96%, precisão de 96,41% e sensibilidade de 92,02%. Em comparação com métodos do estado da arte, a arquitetura proposta apresentou desempenho competitivo, com maior consistência anatômica e menor dependência de intervenção manual, demonstrando seu potencial como ferramenta de apoio ao diagnóstico clínico.

I. INTRODUÇÃO

Segundo a Organização Mundial de Saúde (OMS), as doenças cardiovasculares estão entre as principais causas de mortalidade global [1], com destaque para o acidente vascular

cerebral (AVC), reconhecido como um grave problema de saúde pública. Sua ocorrência está relacionada a fatores como predisposição genética, obesidade, sedentarismo e estresse [2].

Embora que o AVC seja uma emergência médica, seu diagnóstico precoce possibilita recuperação funcional significativa. Para isso, utilizam-se principalmente tomografia computadorizada (TC) e ressonância magnética (RM). A RM oferece melhor contraste de tecidos moles, enquanto a TC é mais acessível e rápida [3].

Nesse contexto, segmentação de lesões em exames de imagem é fundamental para o prognóstico clínico, permitindo monitorar a progressão da doença e avaliar a resposta ao tratamento. No entanto, a segmentação manual é laboriosa e depende da experiência subjetiva do especialista, o que pode comprometer a consistência dos resultados [4].

Dada a urgência no diagnóstico do tipo de lesão, sistemas de suporte à decisão clínica, como os de Diagnóstico Assistido por Computador (do inglês, *Computer-Aided Diagnosis* – CAD), aliados ao conhecimento dos especialistas, têm se tornado cada vez mais utilizados, contribuindo para reduzir o tempo gasto na análise dos exames [5].

Diante do exposto, e visando contribuir com o avanço das pesquisas na área, o presente trabalho propõe um método automático de segmentação de AVC hemorrágico baseado na combinação de Redes Neurais Convolucionais (RNC), para extração hierárquica de informações de exames de TC, com Métodos de Contornos Ativos.

O restante deste trabalho está organizado como se segue: a Seção II descreve a metodologia empregada para a obtenção dos resultados. A Seção III apresenta e discute os resultados experimentais. Por fim, a Seção IV traz as conclusões do estudo, bem como direções para trabalhos futuros.

II. METODOLOGIA

Esta seção apresenta a metodologia adotada, incluindo o método proposto, os conjuntos de dados empregados e as

configurações experimentais. A Figura 1 ilustra o processo, desde a leitura da imagem até a segmentação final por contornos ativos, com destaque para a extração do mapa de ativação contextual (MAC) e a definição do ponto de inicialização (PI) da curva.

A. Segmentação Multiescalar utilizando uma RNC

1) *Extração Hierárquica de Características como Energia Externa*: Esta subseção apresenta a extração multiescalar de características visuais utilizando uma RNC, responsável por modelar a energia externa com base em representações hierárquicas da imagem.

a) *Extração hierárquica de características*: A etapa inicial realiza a extração hierárquica de características visuais por meio de uma arquitetura convolucional profunda baseada em blocos *Cross Stage Partial* (CSP), que combinam caminhos residuais e conexões diretas para reduzir redundância e melhorar a eficiência computacional. Para tal, a imagem de entrada $x \in \mathbb{R}^{H \times W}$ é processada ao longo de múltiplos estágios, nos quais cada nível $s \in \{1, 2, \dots, S\}$ aplica uma operação de subamostragem seguida de um bloco CSP:

$$F_s = \text{CSPBlock}_s(\text{Downsample}(F_{s-1})), \quad F_0 = x. \quad (1)$$

Cada bloco CSP divide o tensor de entrada em duas partes: uma submetida a convoluções residuais e outra mantida intacta, sendo ambas posteriormente combinadas por concatenação:

$$\text{CSPBlock}(z) = \text{Concat}(\text{ConvResidual}(z_1), z_2). \quad (2)$$

O conjunto de mapas gerado $\mathcal{F} = \{F_1, F_2, \dots, F_S\}$ constitui a base hierárquica de representações que será explorada nas etapas subsequentes de fusão multiescalar e modelagem da energia externa.

b) *Fusão multiescalar com agregação bidirecional*: A partir dos mapas hierárquicos \mathcal{F} , a etapa seguinte realiza a fusão multiescalar das representações por meio de um fluxo bidirecional: descendente, que propaga abstrações contextuais, e ascendente, que reintegra detalhes espaciais refinados, favorecendo a segmentação precisa de bordas e estruturas finas.

A fusão multiescalar é conduzida de forma recursiva. O fluxo descendente, definido na Equação 3, propaga informações contextuais dos níveis mais profundos para os mais rasos, combinando os mapas F_s com versões reamostradas de \tilde{F}_{s+1} por meio da função ϕ e convoluções 3×3 . Outrossim, a interpolação bilinear utilizada na operação $\text{Upsample}(\cdot)$ assegura a compatibilidade espacial entre os níveis adjacentes, permitindo uma unificação adequada.

$$\tilde{F}_s = \phi(F_s, \text{Upsample}(\tilde{F}_{s+1})). \quad (3)$$

$$\hat{F}_{s+1} = \psi(\tilde{F}_{s+1}, \text{Downsample}(\tilde{F}_s)). \quad (4)$$

Em seguida, o fluxo ascendente reforça os níveis superiores com detalhes espaciais refinados, combinando \tilde{F}_{s+1} com a versão subamostrada de \tilde{F}_s por meio da função ψ . A representação final \tilde{F}_{s+1} integra abstrações semânticas e fidelidade espacial, contribuindo para uma segmentação precisa.

c) *Construção do campo de energia externa*: A representação multiescalar final $\tilde{F}_1 \in \mathbb{R}^{H \times W \times C}$ é projetada em um mapa escalar $Z \in \mathbb{R}^{H \times W}$ por meio de uma convolução 1×1 , seguida da aplicação da função sigmoide para gerar o mapa de probabilidade $P \in [0, 1]^{H \times W}$. Cada elemento P_{ij} representa a confiança do modelo na presença da estrutura-alvo no pixel (i, j) , conforme definido na Equação 5:

$$P_{ij} = \sigma(Z_{ij}) = \frac{1}{1 + e^{-Z_{ij}}}. \quad (5)$$

O mapa de probabilidade $P(x, y)$ constitui a saída inicial da segmentação e serve como base para o refinamento por CA. O campo de energia externa é definido como $E_{\text{ext}}(x, y) = -P(x, y)$, conduzindo o contorno para regiões de alta probabilidade. Então, essa definição faz com que tais regiões atuem como poços de energia, enquanto a força de atração correspondente é dada pelo gradiente espacial da probabilidade, $\vec{F}_{\text{ext}}(x, y) = \nabla P(x, y)$.

Para ampliar a estabilidade da evolução da curva e realçar transições estruturais, P é suavizado por uma convolução gaussiana G_σ antes do cálculo do gradiente. A energia externa regularizada é então definida pela Equação 6:

$$E_{\text{ext}}^{\text{reg}}(x, y) = -|\nabla(G_\sigma * P)(x, y)|^2, \quad (6)$$

produzindo um campo contínuo com gradientes sensíveis às bordas. Essa integração entre predição semântica e deformação geométrica resulta em uma segmentação refinada, explicável e morfologicamente consistente.

2) *Energia Interna: Estruturação Geométrica a Partir da Ativação Contextual*: Esta subseção descreve a modelagem da energia interna a partir de informações contextuais extraídas da rede, a fim de guiar o contorno ativo com base em padrões funcionais relevantes.

a) *Extração do mapa de ativação contextual*: Visando ampliar a interpretabilidade do método e incorporar informações funcionais à evolução do contorno ativo, foi adotada uma abordagem inspirada na EigenCAM [6], baseada em análise espectral dos MACs da rede. Então, ao invés de interpretar diretamente a anatomia segmentada, o objetivo é identificar padrões internos que mais contribuíram para a resposta da rede nas regiões de maior confiança. O resultado é um mapa contínuo de ativação contextual, utilizado para modelar a energia interna do contorno.

Sejam $F \in \mathbb{R}^{H' \times W' \times C}$ os mapas de ativação gerados pela última camada convolucional, e $\hat{M} \in \{0, 1\}^{H' \times W'}$ a binarização do campo de energia externa, define-se o vetor de ativação local para cada pixel (i, j) como:

$$\mathbf{f}_{ij} = [F^{(1)}_{ij}, F^{(2)}_{ij}, \dots, F^{(C)}_{ij}]^\top \in \mathbb{R}^C. \quad (7)$$

Considerando o conjunto $\Omega = \{(i, j) \mid \hat{M}_{ij} = 1\}$ como o suporte espacial definido pela binarização do campo de energia externa, calcula-se a matriz de covariância empírica das ativações:

$$\Psi = \frac{1}{|\Omega|} \sum_{(i, j) \in \Omega} \mathbf{f}_{ij} \mathbf{f}_{ij}^\top. \quad (8)$$

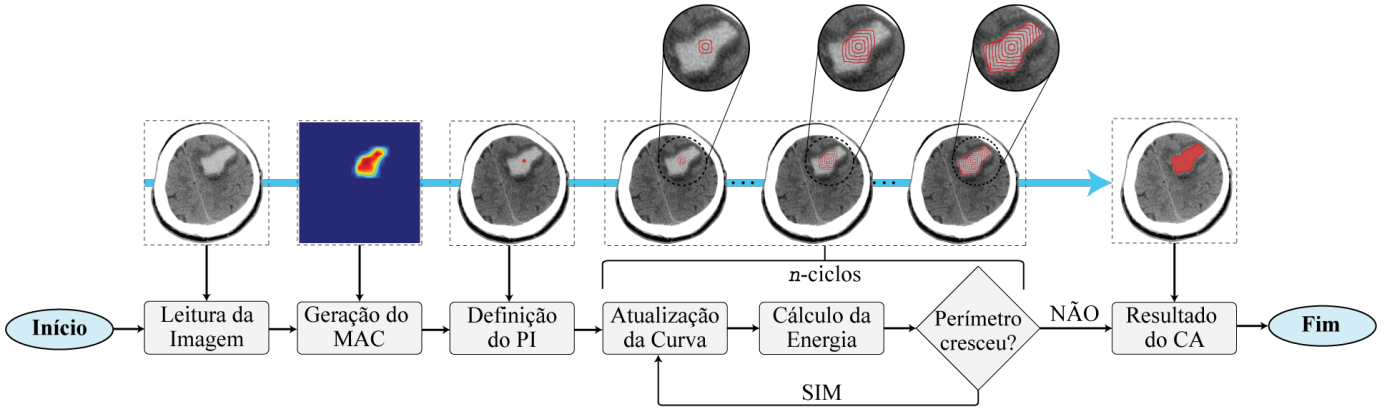


Figura 1: Etapas de execução do método proposto.

A decomposição espectral de Ψ fornece os autovalores e autovetores, sendo $\Psi = Q\Lambda Q^\top$. O primeiro autovetor $q_1 \in \mathbb{R}^C$, associado ao maior autovalor, define a direção dominante de variação das ativações. Com base nisso, constrói-se o MAC $A \in \mathbb{R}^{H' \times W'}$ por projeção dos vetores f_{ij} ao longo de q_1 , restrita ao suporte Ω :

$$A_{ij} = \begin{cases} \langle f_{ij}, q_1 \rangle, & \text{se } (i, j) \in \Omega \\ 0, & \text{caso contrário} \end{cases}. \quad (9)$$

Então, A é normalizado via min-max para o intervalo $[0, 1]$, resultando em $\tilde{A} \in [0, 1]^{H' \times W'}$, que representa a estimativa contínua da relevância funcional aprendida pela rede. Esse mapa contextual \tilde{A} serve de base para a extração das representações estruturais utilizadas na modelagem da energia interna do CA.

b) Determinação do ponto de inicialização da curva:

O contorno ativo é inicializado por meio de uma coordenada estimada via média ponderada sobre a região segmentada \hat{M} , utilizando o MAC \tilde{A} como peso, conforme a Equação 10. Essa estimativa integra informações geométricas e funcionais aprendidas, permitindo a definição de um contorno circular inicial com raio r (Equação 11).

$$x^* = \frac{\sum_{(i,j) \in \Omega} j \cdot \tilde{A}_{ij}}{\sum_{(i,j) \in \Omega} \tilde{A}_{ij}}, \quad y^* = \frac{\sum_{(i,j) \in \Omega} i \cdot \tilde{A}_{ij}}{\sum_{(i,j) \in \Omega} \tilde{A}_{ij}}. \quad (10)$$

$$C_0(t) = \begin{bmatrix} x^* + r \cdot \cos(t) \\ y^* + r \cdot \sin(t) \end{bmatrix}, \quad t \in [0, 2\pi). \quad (11)$$

Essa curva é discretizada em N pontos igualmente espaçados e serve como estrutura inicial para a evolução conduzida pelas energias internas e externas, promovendo uma segmentação morfologicamente consistente e orientada.

c) Modelagem da energia interna e evolução do contorno: A evolução do contorno ativo é guiada por uma equação de movimento que combina forças interna, externa e de expansão contextual, ponderadas por coeficientes que modulam sua influência na deformação da curva. A força de expansão, denominada Força Balão Contextual, é adaptada com base na ativação contextual aprendida.

O contorno ativo é representada por uma função suave $\mathbf{v}(s) = [x(s), y(s)]$, $s \in [0, 1]$, que parametriza os pontos ao longo da borda. A energia interna associada à curva é dada por:

$$\mathcal{E}_{\text{int}}(\mathbf{v}) = \int_0^1 \left[\alpha \left| \frac{d\mathbf{v}}{ds} \right|^2 + \beta \left| \frac{d^2\mathbf{v}}{ds^2} \right|^2 \right] ds, \quad (12)$$

onde α controla a tensão entre pontos, e β regula a rigidez da curva, promovendo suavidade e continuidade geométrica.

A evolução da curva no tempo é então conduzida pela Equação 13, que combina a força interna derivada de \mathcal{E}_{int} , a força externa \vec{F}_{ext} baseada na segmentação probabilística, e uma força de expansão adaptativa \vec{F}_{fbc} , modulada pela ativação contextual:

$$\frac{\partial \mathbf{v}(s, t)}{\partial t} = w_1 \cdot \vec{F}_{\text{int}}(\mathbf{v}) + w_2 \cdot \vec{F}_{\text{ext}}(\mathbf{v}) + w_3 \cdot \vec{F}_{\text{fbc}}(\mathbf{v}). \quad (13)$$

Os pesos w_1 , w_2 e w_3 controlam a contribuição relativa de cada termo. Essa formulação permite que a curva evolua de forma sensível à geometria, à probabilidade segmentada e à relevância funcional aprendida.

A Força Balão Contextual é modulada ponto a ponto pelo valor da ativação contextual \tilde{A} , de modo que a evolução da curva é mais acentuada nas regiões mais relevantes, dados por:

$$\vec{F}_{\text{fbc}}(\mathbf{v}) = \lambda \cdot \tilde{A}(x, y) \cdot \vec{n}. \quad (14)$$

Assim, a curva é atualizada iterativamente até convergência, com critério de parada baseado em variação média entre instantes consecutivos. O resultado final é uma fronteira refinada, ajustada com precisão à morfologia da estrutura de interesse, consolidando a integração entre inferência semântica, evidência funcional e deformação geométrica regularizada.

B. Conjuntos de Dados de AVC Hemorrágico

Este estudo empregou dois conjuntos públicos para o treinamento da RNC e um conjunto privado para avaliação do método proposto, garantindo diversidade experimental e maior robustez na validação. Na Figura 2, são apresentados exemplos das imagens provenientes das bases públicas e do conjunto privado utilizado na avaliação do método proposto.




Figura 2: Exemplares de cada uma das bases de dados utilizadas no treinamento e avaliação do método proposto.

Para cada uma das imagens de cada base, havia uma máscara binária correspondente, previamente delimitada por um ou mais especialistas, sendo considerada o padrão-ouro (do inglês, *ground truth* – GT) para a tarefa de segmentação. A seguir, apresentam-se breves descrições de cada conjunto

1) *Brain CT Images with Intracranial Hemorrhage Masks*: Proposto em [7], é composto por 82 exames (46 de homens e 36 de mulheres) de TC. As imagens foram disponibilizadas em formato JPEG com dimensões de 650×650 pixels [8].

2) *Brain Hemorrhage Segmentation Dataset (BHSD)* [9], composto por 192 volumes com anotações em nível de pixel e apresenta uma classificação de hemorragia intracraniana (ICH) em cinco categorias: hematoma epidural (EDH), a hemorragia intraparenquimatosa (IPH), a hemorragia intraventricular (IVH), a hemorragia subaracnoidea (SAH) e o hematoma subdural (SDH).

3) *Conjunto de Dados Privado*: Constituído por 100 imagens axiais de TC de crânio de pacientes com AVC hemorrágico, adquiridas em parceria com o Hospital do Coração de Fortaleza, utilizando tomógrafo GE Optima CT660. As imagens estão em formato DICOM, com resolução de 512×512 pixels e 16 bits de profundidade.

C. Treinamento da Rede Neural Convolutacional

O treinamento da RNC foi realizado exclusivamente sobre os conjuntos públicos. Foram definidas até 1000 épocas como limite máximo de treinamento. No entanto, empregou-se o critério de parada antecipada, o qual monitora a métrica de validação (IoU) e interrompe o processo caso não haja melhora significativa por 50 épocas consecutivas. Essa estratégia garantiu eficiência computacional, encerrando o treinamento em pontos ótimos de convergência. A taxa de aprendizado inicial

foi fixada em 1×10^{-3} , com agendamento automático de ajuste durante o treinamento. Utilizou-se o otimizador Adam, com peso de decaimento de 5×10^{-4} e tamanho de lote igual a 12.

III. RESULTADOS E DISCUSSÕES

Esta seção apresenta os resultados da aplicação do método proposto na segmentação de regiões associadas ao AVC em imagens de TC de crânio. Todos os experimentos foram conduzidos em um ambiente local, utilizando uma máquina com processador Intel Core i7-12700H de 12ª geração (2,3 GHz), 16 GB de memória RAM DDR4 e uma GPU NVIDIA GeForce RTX 3050 com 4 GB de memória dedicada. A avaliação quantitativa, sintetizada na Tabela I, baseada em seis métricas amplamente utilizadas [10]–[13]: especificidade (Spe), precisão (Pre), sensibilidade (Sen), coeficiente de Dice (Dic), índice de Jaccard (Jac) e distância de Hausdorff (Hau).

Desse modo, a Spe, com valor médio de $99,96\% \pm 0,03$, evidencia a capacidade do método em evitar falsos positivos, garantindo a preservação de regiões não patológicas, um aspecto crítico em contextos clínicos. Além disso, a Pre, de $96,41\% \pm 2,13$, demonstra que a maioria dos pixels identificados como pertencentes à lesão corresponde corretamente à região-alvo, indicando baixa ocorrência de predições espúrias.

Tabela I: Resultados quantitativos da segmentação de AVC em imagens de TC de crânio. Os valores estão expressos como média \pm desvio padrão.

Métrica	Valor (%)
Spe	$99,96 \pm 0,03$
Pre	$96,41 \pm 2,13$
Sen	$92,02 \pm 3,63$
Dic	$94,11 \pm 2,17$
Jac	$88,95 \pm 3,76$
Hau	$5,60 \pm 3,64$

Ainda, a Sen, com valor de $92,02\% \pm 3,63$, indica que o método consegue recuperar grande parte da região de interesse, enquanto o equilíbrio entre Pre e Sen se reflete nos altos índices de Dic ($94,11\% \pm 2,17$) e Jac ($88,95\% \pm 3,76$), confirmando a efetiva sobreposição entre as segmentações preditas e o GT. Esses resultados evidenciam a capacidade do modelo em capturar com precisão a forma e a extensão das lesões, aspecto essencial para aplicações médicas.

Do mesmo modo, a métrica de Hau, com valor médio de $5,60 \pm 3,64$, indica baixo erro máximo na distância entre os contornos preditos e os de referência, sugerindo bordas mais suaves e compatíveis com as anotações manuais. Essa precisão na delimitação é crucial em aplicações que demandam identificação precisa de fronteiras anatômicas.

Em síntese, os resultados da Tabela I evidenciam o elevado desempenho do método proposto em termos de consistência, pureza da predição, abrangência da lesão, fidelidade morfológica e precisão de contorno. A baixa variabilidade entre as métricas reforça a robustez e a confiabilidade da abordagem frente à heterogeneidade dos dados clínicos.

A. Análise Qualitativa da Segmentação

Esta seção apresenta uma análise qualitativa de três casos representativos de AVC em exames de TC de crânio,

abrangendo diferentes padrões morfológicos e localizações anatômicas. Os exemplos, ilustrados na Figura 3, evidenciam a capacidade do método proposto em segmentar estruturas complexas, complementando a avaliação quantitativa.

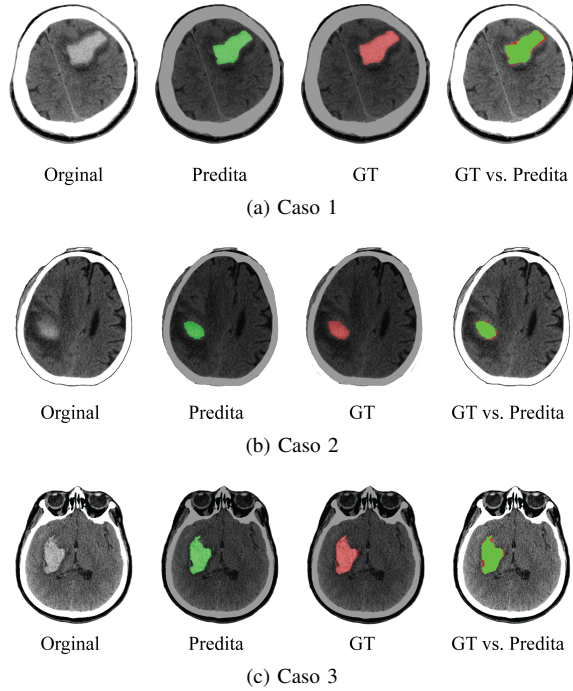


Figura 3: Composição visual comparativa entre as lesões reais e preditas pelo método proposto em diferentes cenários.

a) *Caso 1 – Hemorragia Frontal Direita*: Neste caso, a lesão foi segmentada com elevada correspondência em relação à máscara de referência, tanto em localização quanto em extensão. A sobreposição revela concordância morfológica substancial, com discreta subsegmentação periférica em áreas de menor contraste, evidenciando a eficácia do método em cenários com alto contraste entre lesão e parênquima encefálico adjacente.

b) *Caso 2 – Lesão de Baixo Contraste no Hemisfério Esquerdo*: A Tabela II apresenta uma comparação quantitativa entre o método proposto e diversas abordagens previamente reportadas na literatura, todas avaliadas sobre o mesmo dataset de imagens de tomografia computadorizada de crânio com foco na segmentação de regiões associadas ao AVC.

Em casos de lesões pequenas e de baixo contraste, a predição apresenta subsegmentação leve, cobrindo apenas a região de maior evidência visual. Apesar disso, o contorno preserva coerência anatômica, evidenciando as limitações do método em cenários de baixo contraste e destacando a ativação contextual como mecanismo compensatório.

c) *Caso 3 – Hemorragia Temporal Extensa*: Neste caso, o método proposto segmenta adequadamente lesões extensas e irregulares, mesmo na presença de artefatos de alta densidade. A predição mantém a conformação anatômica da hemorragia, com discrepâncias pontuais nas bordas, demonstrando robustez

frente a variações clínicas. Contudo, padrões hipodensos e fronteiras difusas ainda requerem refinamentos adicionais.

B. Comparação com Métodos do Estado da Arte

A Tabela II apresenta uma comparação entre o método proposto e diversas abordagens previamente reportadas na literatura, todas avaliadas sobre o mesmo dataset de imagens de TC de crânio. O uso comum da base de dados garante equidade na comparação e confere validade à análise de desempenho entre os diferentes métodos.

Tabela II: Comparação de métodos na segmentação de AVC.

Método	Spe	Pre	Sen
OPS [14]	99,85±0,13	84,00±8,00	95,28±5,73
FPLS [11]	99,94±0,09	99,11±0,09	83,34±8,72
HMLS [12]	99,92±0,03	97,64±16,14	78,70±9,40
CDAC-X [13]	99,96±0,0004	96,70±3,76	90,86±8,04
Proposto	99,96±0,03	96,41±2,13	92,02±3,63

Observa-se que o método proposto apresentou desempenho superior ou comparável às principais abordagens da literatura em múltiplas métricas de avaliação. Destaca-se pela Acurácia de 99,87%±0,05, sendo o único entre os métodos comparados a reportar explicitamente esse indicador, o que reforça sua confiabilidade global. A Spe (99,96%±0,03) encontra-se entre as mais elevadas da tabela, igualando-se ao método CDAC-X [13] e superando demais abordagens como HMLS [12] e OPS [14], evidenciando sua eficácia na redução de falsos positivos, aspecto crítico em aplicações clínicas.

Além disso, os valores obtidos de Pre e Sen (96,41% ± 2,13 e 92,02% ± 3,63, respectivamente) indicam um equilíbrio robusto entre pureza e abrangência da segmentação, superando métodos como FPLS [11] e HMLS [12], e aproximando-se dos resultados do CDAC-X [13], demonstrando a competitividade da proposta em diferentes critérios de desempenho.

O método proposto apresentou desempenho competitivo em termos de Pre (96,41% ± 2,13), superando a maioria dos métodos comparados. Quanto à Sen (92,02% ± 3,63), o modelo também se destacou frente a abordagens como FPLS [11] e HMLS [12], indicando melhor cobertura das regiões afetadas. O equilíbrio entre essas métricas reforça a confiabilidade clínica da segmentação, ao combinar precisão diagnóstica com ampla cobertura da lesão.

O método proposto apresenta desempenho competitivo em termos de Pre (96,41% ± 2,13) e Sen (92,02% ± 3,63), superando a maioria dos métodos comparados. A elevada capacidade de recuperação da região-alvo, aliada à baixa taxa de falsos positivos, evidencia o equilíbrio entre Pre e Sen, reforçando a confiabilidade clínica do modelo.

Além dos resultados quantitativos, destaca-se que o método proposto supera diversas limitações técnicas presentes nos trabalhos analisados. Especificamente, elimina a necessidade de anotações manuais para guiar a segmentação (como no CDAC [13] e OPS [14]), evita a utilização de limiares fixos e empíricos para a inicialização da curva (como no FPLS [11] e HMLS [12]), e incorpora, de forma integrada, representações contextuais e estruturais extraídas automaticamente. Essa combinação permite uma segmentação mais

robusta e generalizável, mesmo em cenários com anatomias variantes ou presença de ruído.

Em suma, os resultados obtidos evidenciam a competitividade do modelo proposto. A integração sinérgica entre segmentação multiescalar, evidência estrutural e inicialização inteligente posiciona a abordagem como uma alternativa altamente promissora para aplicações clínicas que demandam segmentação automática com alto grau de precisão, reprodutibilidade e independência de intervenção.

IV. CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho apresentou uma abordagem orientada à segmentação biomédica que explora informações contextuais e estruturais para guiar de forma precisa a evolução de contornos ativos. A proposta se destaca pela integração de múltiplas fontes de informação, incluindo padrões espaciais relevantes, promovendo uma condução morfologicamente coerente e adaptativa da curva de segmentação.

A metodologia proposta combina forças internas e externas para guiar a evolução da curva de segmentação. A energia externa, derivada de representações multiescalares, fornece suporte estrutural, enquanto a energia interna, baseada em descritores geométricos, assegura uma evolução localizada e coerente com a anatomia da lesão. Essa integração reduz sensibilidade a inicializações e ruídos e favorece interpretações compatíveis com padrões clínicos.

A abordagem foi avaliada em imagens de TC do crânio para segmentação de lesões encefálicas, apresentando desempenho superior às abordagens comparadas. O método alcançou acurácia de $99,87\% \pm 0,05$, especificidade de $99,96\% \pm 0,03$, precisão de $96,41\% \pm 2,13$ e sensibilidade de $92,02\% \pm 3,63$. Os resultados demonstram a eficácia do contorno ativo orientada por evidência na delimitação precisa das lesões, mesmo em cenários com baixa heterogeneidade de intensidade e ruído.

A análise qualitativa reforçou a eficácia da proposta, evidenciando que a evolução da curva a partir de pontos relevantes derivados da ativação permite que a segmentação seja ajustada de forma localizada e coerente, evitando desvios para regiões de menor importância clínica. O processo demonstrou ser particularmente eficaz em imagens com contraste heterogêneo, morfologia complexa ou presença de opacidades.

Outrossim, entre os aprimoramentos já em andamento destacam-se a avaliação do desempenho computacional do método para verificar sua viabilidade em ambientes clínicos, sua adaptação para a segmentação de múltiplas regiões de interesse, como em exames pulmonares, e a validação da abordagem em domínios distintos como pele, mama e retina, visando ampliar seu potencial de aplicação.

Os resultados preliminares indicam que a combinação de diferentes níveis de representação favorece uma segmentação robusta, mesmo em cenários clínicos complexos. Embora ainda em desenvolvimento, a abordagem demonstra aplicabilidade promissora, contribuindo para soluções mais transparentes e eficazes no suporte à decisão médica.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) – Código de Financiamento 001. Além disso, Pedro Pedrosa Rebouças Filho reconhece o patrocínio do Conselho Nacional de Pesquisa e Desenvolvimento (CNPq) por meio do Processo 301455/2022-8 e da Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico (FUNCAP) pelo apoio financeiro por meio dos processos 08/2023 e 09/2023.

REFERÊNCIAS

- [1] World Health Organization (WHO), "Stroke (cerebrovascular accident)," <https://www.emro.who.int/health-topics/stroke-cerebrovascular-accident/index.html>, 2025, accessed: 2025-07-23.
- [2] S. Yalçın and H. Vural, "Brain stroke classification and segmentation using encoder-decoder based deep convolutional neural networks," *computers in biology and medicine*, vol. 149, p. 105941, 2022.
- [3] N. Schmitt, Y. Mokli, C. Weyland, S. Gerry, C. Herweh, P. Ringleb, and S. Nagel, "Automated detection and segmentation of intracranial hemorrhage suspect hyperdensities in non-contrast-enhanced ct scans of acute stroke patients," *European radiology*, vol. 32, no. 4, pp. 2246–2254, 2022.
- [4] L. Liu, S. Chen, F. Zhang, F.-X. Wu, Y. Pan, and J. Wang, "Deep convolutional neural network for automatically segmenting acute ischemic stroke lesion in multi-modality mri," *Neural Computing and Applications*, vol. 32, no. 11, pp. 6545–6558, 2020.
- [5] M. T. Guimarães, A. G. Medeiros, J. S. Almeida, M. F. y Martín, R. Damaševičius, R. Maskeliūnas, C. L. C. Mattos, and P. P. Rebouças Filho, "An optimized approach to huntington's disease detecting via audio signals processing with dimensionality reduction," in *2020 International Joint Conference on Neural Networks (IJCNN)*. IEEE, 2020, pp. 1–8.
- [6] M. B. Muhammad and M. Yeasin, "Eigen-cam: Class activation map using principal components," in *2020 international joint conference on neural networks (IJCNN)*. IEEE, 2020, pp. 1–7.
- [7] M. Hssayeni, "Computed tomography images for intracranial hemorrhage detection and segmentation (version 1.0.0)," <https://doi.org/10.13026/w8q8-ky94>, 2019, rRID:SCR_007345.
- [8] A. Goldberger, L. Amaral, L. Glass, J. Hausdorff, P. C. Ivanov, R. Mark, and H. E. Stanley, "Physiobank, physiotoolkit, and physionet: Components of a new research resource for complex physiologic signals," *Circulation [Online]*, vol. 101, no. 23, pp. e215–e220, 2000.
- [9] B. Wu, "Brain Hemorrhage Segmentation Dataset (BHSD)," 2023, accessed: 2025-09-07. [Online]. Available: <https://huggingface.co/datasets/Wendy-Fly/BHSD>
- [10] E. d. S. Rebouças, A. M. Braga, R. M. Sarmento, R. C. Marques, and P. P. Rebouças Filho, "Level set based on brain radiological densities for stroke segmentation in ct images," in *2017 IEEE 30th International Symposium on Computer-Based Medical Systems*. IEEE, 2017, pp. 391–396.
- [11] E. de Souza Rebouças, F. N. S. De Medeiros, R. C. P. Marques, J. V. S. Chagas, M. T. Guimarães, L. O. Santos, A. G. Medeiros, and S. A. Peixoto, "Level set approach based on parzen window and floor of log for edge computing object segmentation in digital images," *Applied Soft Computing*, vol. 105, p. 107273, 2021.
- [12] A. M. Braga, R. C. Marques, F. N. Medeiros, J. F. R. Neto, A. G. Bianchi, C. M. Carneiro, and D. M. Ushizima, "Hierarchical median narrow band for level set segmentation of cervical cell nuclei," *Measurement*, vol. 176, p. 109232, 2021.
- [13] S. P. P. d. Silva, R. F. Ivo, C. B. Barroso, J. C. N. Fernandes, T. F. Portela, A. G. Medeiros, P. H. F. d. Sousa, H. Song, and P. P. Rebouças Filho, "Context-driven active contour (cdac): A novel medical image segmentation method based on active contour and contextual understanding," *Sensors*, vol. 25, no. 9, p. 2864, 2025.
- [14] P. P. Rebouças Filho, A. C. da Silva Barros, J. S. Almeida, J. Rodrigues, and V. H. C. de Albuquerque, "A new effective and powerful medical image segmentation algorithm based on optimum path snakes," *Applied Soft Computing*, vol. 76, pp. 649–670, 2019.