



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE TELEINFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TELEINFORMÁTICA
DOUTORADO EM ENGENHARIA DE TELEINFORMÁTICA

DOUGLAS DE ARAÚJO RODRIGUES

***SEMANTIC MULTI-REGION ACTIVE CONTOUR (SEMAC): UMA ABORDAGEM
SEMÂNTICO-GEOMÉTRICA PARA SEGMENTAÇÃO DE MULTIRREGIÕES***

FORTALEZA

2025

DOUGLAS DE ARAÚJO RODRIGUES

*SEMANTIC MULTI-REGION ACTIVE CONTOUR (SEMAC): UMA ABORDAGEM
SEMÂNTICO-GEOMÉTRICA PARA SEGMENTAÇÃO DE MULTIRREGIÕES*

Tese apresentada ao Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de doutor em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas.

Orientador: Prof. Dr. Pedro Pedrosa Rebouças Filho.

Coorientadora: Prof. Dr. Suane Pires Pinheiro da Silva.

FORTALEZA

2025

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

R612s Rodrigues, Douglas de Araújo.
SEmantic Multi-Region Active Contour (SEMAC): uma abordagem semântico-geométrica para segmentação de multirregiões / Douglas de Araújo Rodrigues. – 2025.
117 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Teleinformática, Fortaleza, 2025.

Orientação: Prof. Dr. Pedro Pedrosa Rebouças Filho.

Coorientação: Profa. Dra. Suane Pires Pinheiro da Silva.

1. Contornos Ativos. 2. Campo de Evidência. 3. Segmentação Multirregiões. 4. Lesões de Pele. 5. Células Sanguíneas. I. Título.

CDD 621.38

DOUGLAS DE ARAÚJO RODRIGUES

*SEMANTIC MULTI-REGION ACTIVE CONTOUR (SEMAC): UMA ABORDAGEM
SEMÂNTICO-GEOMÉTRICA PARA SEGMENTAÇÃO DE MULTIRREGIÕES*

Tese apresentada ao Programa de Pós-Graduação em Engenharia de Teleinformática do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de doutor em Engenharia de Teleinformática. Área de Concentração: Sinais e Sistemas.

Aprovada em: 27 de Novembro de 2025

BANCA EXAMINADORA

Prof. Dr. Pedro Pedrosa Rebouças
Filho (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Suane Pires Pinheiro da
Silva (Coorientadora)
Instituto Federal de Educação, Ciência e
Tecnologia do Ceará (IFCE)

Prof. Dr. Victor Hugo Costa de Albuquerque
Universidade Federal do Ceará (UFC)

Prof. Dr. Ajalmar Rêgo da Rocha Neto
Universidade Federal do Ceará (UFC)

Prof. Dr. Amauri Holanda de Souza Júnior
Instituto Federal de Educação, Ciência e
Tecnologia do Ceará (IFCE)

Prof. Dr. Josias Guimarães Batista
Instituto Federal de Educação, Ciência e
Tecnologia do Estado do Ceará (IFCE)

AGRADECIMENTOS

A Deus, pela presença constante, pela luz que guiou meu caminho e pela serenidade necessária para enfrentar cada etapa desta trajetória.

Em especial à minha família — especialmente Florinda Helena e Wilton Rodrigues — pelo amor, paciência e apoio incondicional. E um agradecimento especial ao Alysson Mendes, que fez parte importante dessa caminhada.

Ao meu orientador, Prof. Dr. Pedro Pedrosa Rebouças Filho, registro minha profunda admiração e reconhecimento pela orientação segura, pelo comprometimento e pela generosidade intelectual. À minha coorientadora, Prof^a. Dra. Suane Pires Pinheiro da Silva, expresso sincera gratidão pela disponibilidade, pelas contribuições valiosas e pelo incentivo constante ao longo do desenvolvimento desta tese.

Ao Laboratório de Processamento de Imagens, Sinais e Computação Aplicada (LAPISCO), pela infraestrutura, pelo ambiente colaborativo e pelas trocas de conhecimento que enriqueceram de forma significativa esta jornada acadêmica. Aos colegas, amigos e colaboradores que contribuíram direta ou indiretamente para esta caminhada, seja por meio de discussões técnicas, sugestões construtivas ou simples gestos de encorajamento. Agradeço especialmente aos colegas Aldísio Medeiros, Roberto Fernandes, João Carlos, Solon Peixoto, Pedro Yuri e Mabiú Moura, pelo companheirismo e pelas discussões produtivas que tornaram este percurso mais leve e inspirador.

À CAPES, pelo apoio financeiro com a manutenção da bolsa de auxílio. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Por fim, agradeço a todos que acreditaram nesta pesquisa e compartilharam comigo o valor da persistência, da curiosidade e do compromisso com o avanço do conhecimento científico.

Depois do medo, vem o mundo.

(Clarice Lispector)

RESUMO

A segmentação de imagens é essencial na análise e interpretação visual, sobretudo em aplicações que exigem precisão geométrica e robustez diante da variabilidade de forma, textura, contraste e artefatos. Este trabalho propõe o *SEmantic Multi-Region Active Contour* (SEMAC), um método de segmentação baseado em contornos ativos, cuja formulação multicontorno permite obter múltiplas regiões a partir de um único contorno inicial. Essa estrutura faz com que o contorno se divida e se adapte dinamicamente quando o campo energético identifica múltiplos núcleos ou regiões de interesse, resultando em uma segmentação multirregional consistente. O modelo deriva da formulação clássica dos *Active Contour Model* (ACM), mas redefine sua energia externa com base em um campo de evidência semântica, responsável por orientar a evolução adaptativa dos contornos em um domínio energético contínuo. Essa energia supervisionada substitui o gradiente fotométrico tradicional, sintetizando contrastes e padrões estruturais em múltiplas escalas e assegurando estabilidade numérica mesmo em cenários complexos. O campo de evidência é obtida a partir de pares de imagem-referência, que fornecem ao modelo um mapeamento contínuo refletindo a distribuição espacial de evidências semânticas, tornando-o mais informativo e robusto a diversas variações. A avaliação experimental abrangeu três conjuntos de dados: um sintético, voltado à análise sob variações de forma, ruído e densidade; e dois clínicos, com imagens dermatoscópicas de lesões cutâneas e microscópicas de células sanguíneas. As métricas de desempenho (Acurácia, Precisão, Sensibilidade, Especificidade, *Intersection over Union* (IoU), *Dice Similarity Coefficient* (Dice) e *Matthews Correlation Coefficient* (MCC)) foram complementadas por análises qualitativas de regularidade e estabilidade morfológica. Os resultados demonstram que o SEMAC alcança desempenho competitivo em relação a métodos clássicos e supervisionados de referência, mantendo consistência e eficiência computacional. O modelo consolida uma abordagem contínua e multirregional inspirada na dinâmica de múltiplos contornos ativos, integrando aprendizado semântico e evolução geométrica em uma estrutura interpretável e estável, adequada à segmentação de imagens complexas.

Palavras-chave: contornos ativos; campo de evidência; segmentação multirregiões; lesões de pele; células sanguíneas.

ABSTRACT

Image segmentation is essential for visual analysis and interpretation, especially in applications that require geometric precision and robustness against variability in shape, texture, contrast, and artifacts. This work proposes the SEMAC, a segmentation method based on active contours whose multi-contour formulation enables the extraction of multiple coherent regions from a single initial contour. This structure allows the contour to divide and adapt dynamically when the energy field identifies multiple nuclei or regions of interest, resulting in consistent multiregional segmentation. The model derives from the classical ACM formulation but redefines its external energy based on a semantic evidence field, which guides the adaptive evolution of contours within a continuous energy domain. This supervised energy replaces the traditional photometric gradient, synthesizing contrasts and structural patterns at multiple scales and ensuring numerical stability even in complex scenarios. The evidence field is obtained from reference image pairs, providing the model with a continuous mapping that reflects the spatial distribution of semantic evidence, making it more informative and robust to photometric variations. The experimental evaluation encompassed three datasets: a synthetic one, aimed at analyzing variations in shape, noise, and density; and two clinical ones, comprising dermatoscopic images of skin lesions and microscopic images of blood cells. The performance metrics (Accuracy, Precision, Sensitivity, Specificity, Intersection over Union (IoU), Dice Similarity Coefficient (Dice) e Matthews Correlation Coefficient (MCC)) were complemented by qualitative analyses of regularity and morphological stability. The results demonstrate that the SEMAC achieves competitive performance compared to classical and state-of-the-art supervised methods, while maintaining consistency and computational efficiency. The model establishes a continuous and multiregional approach inspired by the dynamics of multiple active contours, integrating semantic learning and geometric evolution within an interpretable and stable framework suitable for the segmentation of complex images.

Palavras-chave: active contours; semantic evidence field; multi-region segmentation; skin lesions; blood cells.

LISTA DE FIGURAS

Figura 1	– Representação esquemática do melanoma cutâneo.	28
Figura 2	– Ilustração esquemática da análise de uma amostra de sangue.	29
Figura 3	– Evolução contrátil de um contorno ativo. A curva inicial desloca-se em direção à borda do objeto, guiada pelas forças externas, até atingir o equilíbrio energético em $x+1$	34
Figura 4	– Vizinhança de busca para o ponto de controle $c[s]$ no modelo de contornos ativos (ACM). O ponto central (em preto) avalia diferentes posições dentro da janela pontilhada (em azul), selecionando aquela que minimiza a energia local.	35
Figura 5	– Esquema de uma arquitetura <i>Encoder–Decoder</i> . O <i>Encoder</i> comprime os mapas de características, a Ponte processa a informação de mais alto nível, e o <i>Decoder</i> reconstrói a saída, recuperando a resolução espacial.	41
Figura 6	– Fluxo de processamento do método SEMAC. À esquerda, exemplos intermediários nos três conjuntos de dados (sintético, lesões cutâneas e células sanguíneas). À direita, o fluxograma com as etapas de construção do campo de evidência, evolução dos contornos, ramificação controlada e estabilização geométrica.	44
Figura 7	– Analogia visual entre o domínio fotométrico e o domínio do campo de evidência a partir de uma amostra do conjunto de dados BBBC041Seg. De forma conceitual, é ilustrada a transição do espaço de intensidades para um espaço contínuo de coerência semântico-geométrica, proposto pelo SEMAC.	49
Figura 8	– Representação do cálculo do ângulo local θ_k entre nós consecutivos de um contorno ativo paramétrico. O detalhamento ilustra a relação geométrica entre os pontos \mathbf{x}_{k-1} , \mathbf{x}_k e \mathbf{x}_{k+1}	52
Figura 9	– Evolução multi-região orientada pelo campo de forças. Os vetores em verde indicam a direção de movimento dos nós, guiando o contorno para regiões de menor potencial e assegurando a estabilização das fronteiras. À direita de cada linha temporal é exibido o detalhamento de uma região específica, onde se observa a atuação local das forças e a suavização progressiva das arestas.	54

Figura 10 – Sequência de evolução e divisão topológica do contorno. A primeira coluna mostra a detecção de interseção entre segmentos do contorno; na segunda, exibe-se uma ampliação da região. Por fim, formam-se dois contornos independentes, cada um delimitando uma região distinta, evidenciando a capacidade do SEMAC em lidar com múltiplas regiões de forma autônoma.	55
Figura 11 – Amostras sintéticas com bordas lineares, bordas irregulares e alta densidade.	57
Figura 12 – Amostras sintéticas com bordas ideais, bordas irregulares e alta densidade.	58
Figura 13 – Detalhe ampliado de um objeto sintético com bordas modificadas, evidenciando microerosões e deformações locais que simulam variações morfológicas naturais.	59
Figura 14 – Exemplos de imagens do conjunto <i>International Skin Imaging Collaboration</i> (ISIC) 2018.	61
Figura 15 – Exemplos do conjunto de dados BBBC041Seg, composto por imagens microscópicas de células sanguíneas.	63
Figura 16 – Matriz de confusão para segmentação binária, destacando os casos de acerto (verde) e erro (vermelho). A região de interesse e a região de fundo são comparadas entre a máscara de referência e a segmentação predita, originando os quatro elementos fundamentais: Verdadeiro Positivo (VP), Verdadeiro Negativo (VN), Falso Positivo (FP) e Falso Negativo (FN).	64
Figura 17 – Relação entre o processo de segmentação e a matriz de confusão, destacando os quatro desfechos possíveis (VP, FP, VN e FN) e as métricas derivadas.	66
Figura 18 – Representação esquemática das métricas de similaridade Dice e IoU, que avaliam a sobreposição entre as regiões <i>A</i> (padrão-ouro) e <i>B</i> (predição).	69
Figura 19 – Distribuição conjunta das métricas de segmentação nos seis cenários sintéticos avaliados.	76
Figura 20 – Evolução dos contornos ativos em dados sintéticos com bordas regulares, mostrando amostras sem modificações artificiais. As curvas verdes indicam o contorno evolutivo em diferentes iterações, evidenciando convergência estável e coerência geométrica.	78

Figura 21 – Evolução dos contornos ativos em dados sintéticos com bordas regulares, mostrando amostras com modificações artificiais. As curvas verdes indicam o contorno evolutivo em diferentes iterações, evidenciando convergência estável e coerência geométrica.	79
Figura 22 – Evolução do processo de segmentação em dados sintéticos com bordas irregulares. As amostras exibem condições sem modificações artificiais. As curvas verdes representam o contorno ativo ao longo das iterações, demonstrando convergência uniforme e preservação da geometria das bordas.	79
Figura 23 – Evolução do processo de segmentação em dados sintéticos com bordas irregulares e modificações artificiais. Observa-se a capacidade do método em manter estabilidade e coerência mesmo sob perturbações locais e sobreposição de fronteiras.	80
Figura 24 – Evolução dos contornos ativos em dados sintéticos com alta densidade de objetos. As curvas verdes representam o contorno evolutivo ao longo das iterações, evidenciando estabilidade e preservação das fronteiras entre regiões adjacentes.	81
Figura 25 – Evolução dos contornos ativos em dados sintéticos com alta densidade de objetos e modificações artificiais na imagem. Observa-se a capacidade do método em manter estabilidade e coerência mesmo sob perturbações locais e sobreposição de fronteiras.	81
Figura 26 – Visualização qualitativa da segmentação em duas amostras sintéticas.	83
Figura 27 – Visualização qualitativa da segmentação em duas amostras sintéticas com bordas irregulares, com e sem modificações na imagem.	84
Figura 28 – Visualização qualitativa da segmentação em duas amostras sintéticas com alta densidade de objetos, com e sem modificações na imagem.	85
Figura 29 – Distribuição das métricas de desempenho na segmentação de lesões cutâneas por meio de <i>boxplots</i> . Cada <i>boxplot</i> representa a dispersão dos valores obtidos nas imagens do conjunto de teste.	90

Figura 30 – Evolução do processo de segmentação em imagens de pele pelo SEMAC. Cada linha corresponde a uma amostra distinta, enquanto as colunas representam diferentes estágios iterativos. Observa-se a progressiva adaptação das curvas de contorno (em verde) desde a inicialização retangular até a convergência final às bordas reais da lesão.	92
Figura 31 – Visualização qualitativa de duas amostras de lesões cutâneas. Para cada caso, são apresentadas: (i) a imagem original; (ii) a sobreposição do <i>Ground Truth</i> (GT); (iii) a segmentação predita pelo SEMAC; e (iv) a sobreposição entre a GT e a predição.	94
Figura 32 – Distribuição das métricas de desempenho na segmentação de células sanguíneas por meio de <i>boxplots</i> . Cada boxplot representa a variação dos valores obtidos nas imagens do conjunto de teste.	98
Figura 33 – Evolução do processo de segmentação em imagens de células sanguíneas bem espaçadas, utilizando o SEMAC. Observa-se a adaptação suave das curvas de contorno (em verde) desde a inicialização retangular até a convergência final sobre as fronteiras reais, evidenciando a precisão na delimitação individual das células.	100
Figura 34 – Evolução do processo de segmentação em imagens de alta densidade celular pelo SEMAC. Nota-se a capacidade do método em preservar estabilidade topológica e coerência geométrica mesmo sob sobreposição e proximidade entre células, assegurando separação consistente das fronteiras.	101
Figura 35 – Visualização qualitativa de duas amostras de células sanguíneas.	102
Figura 36 – Desempenho do SEMAC em uma imagem dermatoscópica caracterizada por baixo contraste, bordas irregulares e variação interna de tonalidade. (a–b) Evolução progressiva do contorno ativo sobre a lesão, com o campo de forças adaptativo ajustando-se às transições sutis de intensidade; (c) GT fornecido por especialistas, utilizado como referência; (d) Aderência do método às fronteiras reais mesmo em regiões com transições suaves e ruído de textura.	104

Figura 37 – Evolução local dos contornos ativos em imagem microscópica de sangue periférico, ilustrando o processo de divisão topológica e a estabilização subsequente: (a) aproximação de duas fronteiras dentro de uma mesma vizinhança energética; (b) interseção e divisão automática; (c) início da evolução independente dos contornos recém-divididos; (d) estabilização local sobre as respectivas fronteiras de interesse. 106

Figura 38 – Evolução multirregião em imagem microscópica de sangue, ilustrando a atuação dos vetores de força adaptativos após a divisão topológica. O SEMAC conduz a contração e a estabilização dos contornos de forma autônoma, mantendo separação estável entre fronteiras adjacentes. As colunas à direita mostram ampliações das áreas destacadas, evidenciando a orientação local das forças e sua redução progressiva até o equilíbrio final. 108

LISTA DE TABELAS

Tabela 1 – Resumo das seis condições sintéticas utilizadas para avaliação do método.	57
Tabela 2 – Distribuição das imagens entre treino, validação e teste para cada conjunto de dados.	72
Tabela 3 – Resultados médios e desvios padrão das métricas gerais e de correlação em dados sintéticos sob diferentes condições geométricas e fotométricas.	74
Tabela 4 – Resultados médios e desvios padrão das métricas de similaridade em dados sintéticos sob diferentes condições geométricas e fotométricas.	74
Tabela 5 – Resultados comparativos em métricas quantitativas para segmentação em imagens de pele.	87
Tabela 6 – Resultados comparativos em métricas de similaridade para segmentação em imagens de pele.	89
Tabela 7 – Resultados comparativos em métricas quantitativas para segmentação em imagens de células sanguíneas.	95
Tabela 8 – Resultados comparativos em métricas de similaridade para segmentação em imagens de células sanguíneas. O estudo de Depto <i>et al.</i> (2021) avaliou diversos métodos de segmentação aplicados ao mesmo conjunto de dados de células sanguíneas, possibilitando uma comparação direta de desempenho entre as abordagens.	96

LISTA DE ABREVIATURAS E SIGLAS

ABACM	<i>Adaptive Balloon Active Contour Method</i>
Acc	Acurácia
ACM	<i>Active Contour Model</i>
ANN	Rede Neural Artificial
BR	<i>Background Region</i>
CAD	<i>Computer-Aided Diagnosis</i>
CNNs	<i>Convolutional Neural Networks</i>
CR	Crescimento de Regiões
Dice	<i>Dice Similarity Coefficient</i>
DL	<i>Deep Learning</i>
DNN	Rede Neural Profunda
Espec	Especificidade
FCN	<i>Fully Convolutional Networks</i>
FGAC	<i>Fast Morphological Geodesic Active Contour</i>
FN	Falso Negativo
FP	Falso Positivo
FPLS	<i>FLog Parzen Level Set</i>
GAC	<i>Geodesic Active Contour</i>
GPU	<i>Graphics Processing Unit</i>
GT	<i>Ground Truth</i>
IA	Inteligência Artificial
IoU	<i>Intersection over Union</i>
ISIC	<i>International Skin Imaging Collaboration</i>
MCC	<i>Matthews Correlation Coefficient</i>
PDI	Processamento Digital de Imagens
Prec	Precisão
ReLU	Unidade Linear Retificada
ROI	<i>Region of Interest</i>
SEMAC	<i>SEmantic Multi-Region Active Contour</i>
Sens	Sensibilidade

SR	<i>Segmented Region</i>
VC	Visão Computacional
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Motivação	19
1.2	Estado da Arte	20
1.3	Objetivos	23
1.3.1	<i>Objetivo Geral</i>	23
1.3.2	<i>Objetivos Específicos</i>	24
1.4	Produção Científica	24
1.5	Organização da Tese	25
2	FUNDAMENTAÇÃO TEÓRICA	27
2.1	Condições Médicas Abordadas	27
2.1.1	<i>Lesões Cutâneas</i>	27
2.1.2	<i>Células Sanguíneas</i>	28
2.2	Segmentação de Imagens	29
2.2.1	<i>Segmentação por Similaridade</i>	30
2.2.2	<i>Segmentação por Descontinuidade</i>	32
2.3	Modelos de Contornos Ativos	33
2.4	Redes Neurais Profundas	36
2.4.1	<i>Fundamentos do Aprendizado Profundo</i>	37
2.4.1.1	<i>Redes Neurais Artificiais</i>	37
2.4.1.2	<i>Redes Convolucionais</i>	39
2.4.2	<i>Segmentação Baseada em Aprendizado Profundo</i>	40
3	ABORDAGEM SEMÂNTICO-GEOMÉTRICA PARA SEGMENTAÇÃO DE MULTIRREGIÕES	42
3.1	<i>SEmantic Multi-Region Active Contour (SEMAMC)</i>	42
3.1.1	<i>Energia Externa Baseada em Campo de Evidência Semântica</i>	43
3.1.2	<i>Contração Paramétrica e Ramificação Multirregião dos Contornos Ativos</i>	50
3.2	Conjuntos de Dados	56
3.2.1	<i>Cenário Especialista: Conjunto de Dados Sintéticos</i>	56
3.2.2	<i>Cenário Generalista: Conjunto de Dados Heterogêneo</i>	60
3.2.2.1	<i>Imagens Dermatoscópicas</i>	60

3.2.2.2	<i>Imagens Microscópicas de Células Sanguíneas</i>	61
3.3	Métricas de Avaliação para Segmentação	62
3.3.1	Métricas Baseadas em Classificação	65
3.3.1.1	<i>Acurácia</i>	65
3.3.1.2	<i>Especificidade</i>	66
3.3.1.3	<i>Sensibilidade</i>	67
3.3.1.4	<i>Precisão</i>	67
3.3.1.5	<i>Coefficiente de Correlação de Matthews (MCC)</i>	68
3.3.2	Métricas Baseadas em Similaridade	69
3.3.2.1	<i>Índice de Jaccard</i>	69
3.3.2.2	<i>Coefficiente de Similaridade de Dice</i>	70
3.4	Procedimentos de Treinamento	71
4	RESULTADOS E DISCUSSÕES	73
4.1	Cenário Especialista	73
4.1.1	<i>Resultados Quantitativos</i>	74
4.1.2	<i>Resultados Qualitativos</i>	77
4.2	Cenário Generalista	86
4.2.1	<i>Segmentação de lesões cutâneas</i>	86
4.2.1.1	<i>Resultados Quantitativos</i>	87
4.2.1.2	<i>Resultados Qualitativos</i>	91
4.2.2	<i>Segmentação de Células Sanguíneas</i>	95
4.2.2.1	<i>Resultados Quantitativos</i>	95
4.2.2.2	<i>Resultados Qualitativos</i>	98
4.3	Análise Geral dos Resultados do SEMAC	103
4.3.1	<i>Desempenho do SEMAC em Bordas Complexas, Baixo Contraste e Ruído</i>	103
4.3.2	<i>Evolução dos Múltiplos Contornos Ativos e Divisão entre Múltiplas Regiões</i>	105
4.3.3	<i>Estabilização Independente e Coerência entre Regiões Próximas</i>	105
4.3.4	<i>Validação do Campo de Evidência e da Proposta Multirregional</i>	107
5	CONCLUSÕES E TRABALHOS FUTUROS	110
5.1	Trabalhos Futuros	112
	REFERÊNCIAS	113

1 INTRODUÇÃO

O avanço da Inteligência Artificial (IA) e da Visão Computacional (VC) tem redefinido a forma como dados visuais são analisados. Essas tecnologias possibilitam a extração de informações estruturadas, isto é, representações quantitativas e semanticamente organizadas de elementos visuais, como formas, texturas, bordas e padrões espaciais, a partir de contextos visuais cada vez mais complexas. No campo da saúde, em particular, elas auxiliam especialistas na tomada de decisões mais rápidas e assertivas (Obuchowicz *et al.*, 2025), contribuindo para aumentar a precisão diagnóstica, otimizar protocolos terapêuticos e oferecer novas ferramentas de apoio clínico (Rong; Liu, 2024). Nesse cenário, a comunidade científica tem direcionado esforços permanentes para o aprimoramento de algoritmos de análise de imagem em diferentes domínios, com o objetivo de torná-los mais robustos, acessíveis e eficientes (Pinto-Coelho, 2023).

Entre as aplicações relevantes estão os sistemas de *Computer-Aided Diagnosis* (CAD), ou Diagnóstico Auxiliado por Computador, que integram técnicas de Processamento Digital de Imagens (PDI) e IA para auxiliar especialistas na interpretação de exames. Esses sistemas seguem um fluxo que inclui aquisição, pré-processamento, segmentação, pós-processamento, extração de atributos e classificação de padrões (Gonzalez; Woods, 2018).

A segmentação de imagens consiste em isolar os objetos de interesse, sejam eles células, lesões cutâneas, estruturas anatômicas ou outros padrões visuais específicos ao domínio analisado, permitindo que os algoritmos concentrem suas análises nas regiões mais relevantes (Pham *et al.*, 2000; Mittal *et al.*, 2022; Yu *et al.*, 2023). Uma segmentação bem executada tende a reduzir a complexidade computacional, aprimorar a extração de características e aumentar a confiabilidade das métricas derivadas, sobretudo quando aplicada a sistemas de análise automatizada. Apesar dos avanços recentes, a delimitação precisa das fronteiras ainda é comprometida por variações de contraste, ruídos e artefatos, bem como pela alta diversidade morfológica dos objetos, o que mantém a segmentação de imagens complexas como um dos desafios centrais da área.

As abordagens clássicas, como a limiarização e a Crescimento de Regiões (CR), baseiam-se em propriedades de intensidade e conectividade dos *pixels*. Esses métodos apresentam desempenho satisfatório em condições controladas, mas tendem a falhar em contextos com iluminação não uniforme, presença de ruído ou fronteiras de baixo contraste, nas quais a distinção entre regiões torna-se ambígua. Em resposta a essas limitações, surgiram os ACM,

que formulam a segmentação como um problema de minimização de energia (Caselles *et al.*, 1997; Vasconcelos *et al.*, 2018). Dentro dessa família, as abordagens variacionais se destacam por estabelecer um modelo matemático rigoroso, em que o contorno evolui para um estado de equilíbrio energético, conduzido por forças internas que impõem suavidade e externas que o atraem para as fronteiras da imagem. Mesmo com o avanço de modelos como o de Chan–Vese (Chan; Vese, 2001), que ampliou a robustez a gradientes locais e ruídos, a eficácia dessas técnicas ainda depende fortemente da condição inicial e das propriedades fotométricas da imagem.

O advento do *Deep Learning* (DL), ou Aprendizagem Profunda, introduziu um novo paradigma para a análise de imagens, permitindo que as *Convolutional Neural Networks* (CNNs), ou Redes Neurais Convolucionais, aprendessem representações hierárquicas e discriminativas diretamente a partir dos dados. Arquiteturas como a U-Net e suas derivações consolidaram-se como referência em tarefas de segmentação, sobretudo no contexto biomédico (Ronneberger *et al.*, 2015; Wu *et al.*, 2022). Apesar de seu desempenho expressivo, esses modelos ainda enfrentam limitações conhecidas, como a exigência de grandes volumes de dados anotados, a sensibilidade a variações morfológicas e a perda de coerência geométrica em estruturas complexas, o que tem impulsionado o desenvolvimento de abordagens híbridas que conciliem aprendizado semântico e regularização geométrica.

A combinação entre método clássicos e Rede Neural Profunda (DNN) tem sido investigada como uma estratégia promissora para explorar propriedades complementares de ambas as abordagens. Esses métodos híbridos buscam integrar a estabilidade geométrica e o controle de forma característicos dos clássicos com a capacidade de abstração e generalização das redes profundas (Lei *et al.*, 2018; Okur *et al.*, 2023). De modo geral, essa linha de pesquisa procura conciliar a interpretabilidade e o rigor matemático dos modelos variacionais com a flexibilidade e o poder de representação do aprendizado profundo, avançando em direção a soluções mais robustas e semanticamente consistentes para a segmentação de imagens.

É nesse contexto que este trabalho propõe o método *SEmantic Multi-Region Active Contour* (SEMAC), um modelo que integra representações aprendidas à formulação variacional dos contornos ativos, estendendo-a para um cenário de múltiplos contornos interdependentes voltado à segmentação de múltiplas regiões. O método sintetiza contrastes, formas e relações morfológicas em um campo de evidência contínuo que orienta a evolução das curvas. A segmentação é formulada em duas etapas complementares: (i) a definição supervisionada de uma nova forma de energia externa, representada por um campo de evidência semântica que guia o

processo evolutivo, e (ii) a evolução contrátil multirregional de contornos paramétricos, regulada por coerência geométrica e conduzida até o equilíbrio energético. Essa integração permite que as curvas evoluam de modo adaptativo em direção às fronteiras de interesse, preservando continuidade morfológica e permitindo a separação natural de múltiplas regiões coerentes em um único processo.

O SEMAC unifica coerência geométrica e consistência semântica em um único método, no qual um contorno inicial contrai de forma contínua e, por meio de ramificações controladas, se divide para abranger múltiplas regiões de interesse. Essa formulação preserva as relações espaciais entre regiões adjacentes e mantém a continuidade das fronteiras, mesmo em contextos de alta complexidade visual. O SEMAC é avaliado em três contextos experimentais, envolvendo conjuntos de dados sintéticos, dermatoscópicos e citológicos, com análises quantitativas e qualitativas baseadas em métricas consolidadas de segmentação, verificando sua robustez, capacidade de generalização e coerência geométrica.

1.1 Motivação

A precisão na segmentação de estruturas visuais constitui um requisito essencial em aplicações biomédicas, uma vez que pequenas imprecisões podem comprometer etapas subsequentes de análise quantitativa, diagnóstico assistido ou controle de qualidade. No domínio clínico, o melanoma cutâneo constitui um dos maiores desafios da oncologia moderna (Boyle *et al.*, 2004). Embora represente uma fração menor entre os cânceres de pele, é responsável pela maioria dos óbitos, totalizando mais de 55 mil mortes anuais em todo o mundo (Schadendorf *et al.*, 2018). A detecção precoce é fundamental para o sucesso terapêutico, mas a ampla variabilidade morfológica das lesões (em forma, textura e coloração) torna o diagnóstico dependente da experiência do especialista. Nesse contexto, a segmentação automática de lesões cutâneas surge como uma ferramenta essencial para padronizar a análise e reduzir a subjetividade clínica, permitindo extrair medidas quantitativas reproduzíveis associadas à progressão das lesões.

De forma análoga, a análise de imagens microscópicas ocupa posição de destaque em diversas áreas da saúde e da biotecnologia, sendo amplamente utilizada no diagnóstico de patologias e no desenvolvimento farmacêutico. O isolamento preciso de núcleos celulares é indispensável para tarefas como contagem, classificação e extração de biomarcadores, uma vez que suas propriedades morfológicas refletem o estado fisiológico e patológico dos tecidos (Singha; Bhowmik, 2022). Entretanto, a automação robusta desse processo ainda enfrenta

barreiras significativas, como heterogeneidade de coloração, sobreposição de estruturas e ruído de aquisição (Narotamo *et al.*, 2019), fatores que comprometem a definição das fronteiras e dificultam a padronização das análises.

Esses cenários biomédicos exemplificam contextos visuais que compartilham desafios estruturais, como elevada variabilidade morfológica, presença de artefatos de imagem e a necessidade de preservar a coerência geométrica entre regiões adjacentes. Tais limitações evidenciam que ainda são restritas as abordagens capazes de integrar, de forma efetiva, a interpretação semântica aprendida com a estabilidade geométrica dos modelos variacionais. É nesse contexto que se insere o presente trabalho, ao propor o método *SEmantic Multi-Region Active Contour* (SEMAC), que combina o aprendizado supervisionado de campos de evidência com a evolução contrátil de múltiplos contornos ativos, possibilitando a segmentação simultânea de múltiplas regiões de interesse em diferentes tipos de imagem.

1.2 Estado da Arte

Ao longo das últimas décadas, a segmentação de imagens tem sido abordada sob diferentes perspectivas metodológicas, acompanhando a evolução dos paradigmas de processamento e análise visual, impulsionada pelo aumento do poder computacional, pela ampla disponibilidade de conjuntos de dados e pelas novas demandas de precisão impostas por aplicações emergentes. Inicialmente, predominavam técnicas clássicas de PDI, como limiarização, detecção de bordas e morfologia matemática (Gonzalez; Woods, 2018; Serra, 1982; Canny, 1986; Otsu, 1979), baseadas em propriedades locais de intensidade e conectividade dos *pixels*. Essas abordagens, embora eficientes em contextos controlados e de baixa variabilidade, têm apresentado desempenho limitado em cenários mais complexos, nos quais fatores como iluminação heterogênea, texturas irregulares e sobreposição de objetos desafiam sua capacidade de generalização.

A busca por métodos mais adaptativos levou ao surgimento dos modelos baseados em energia, como os ACM, introduzidos por Kass *et al.* (1988). Nesses modelos, o contorno de um objeto é representado como uma curva elástica sujeita a forças internas e externas que controlam, respectivamente, a suavidade da forma e a atração às bordas da imagem. Essa formulação introduziu uma abordagem dinâmica para a segmentação, em que o equilíbrio entre regularização geométrica e aderência às fronteiras passou a ser ajustado continuamente durante a evolução do contorno. Posteriormente, o modelo *Geodesic Active Contour* (GAC), proposto por Caselles *et al.* (1997), aprimorou a detecção de fronteiras de baixo gradiente ao incorporar a distância

geodésica no espaço de gradientes. Já o modelo *Chan–Vese* (Chan; Vese, 2001) ampliou essa formulação ao substituir a dependência direta de gradientes por critérios de homogeneidade de intensidade, tornando a segmentação mais robusta em regiões com baixo contraste ou transições suaves.

A evolução dos modelos variacionais deu origem a formulações mais flexíveis, como o *Fast Morphological Geodesic Active Contour* (FGAC) (Vasconcelos *et al.*, 2018) e o *FLog Parzen Level Set* (FPLS) (Rebouças *et al.*, 2021), que apresentaram resultados expressivos em imagens dermatoscópicas (Mendonça *et al.*, 2015). Esses métodos incorporaram operações morfológicas e estimativas de densidade para lidar de forma mais robusta com variações de textura, iluminação e contornos irregulares, mantendo alto poder descritivo e interpretabilidade. Ainda assim, sua eficácia está condicionada à escolha e ao ajuste das funções de energia que regem o processo de evolução, as quais nem sempre conseguem representar adequadamente a diversidade estrutural presente nas imagens. Essa limitação direciona a pesquisa para a formulação de modelos que integrem informações semânticas aprendidas ao processo variacional, buscando maior adaptabilidade e consistência em cenários visuais complexos.

Paralelamente, outra vertente metodológica ganhou destaque na ciência contemporânea com o avanço do DL, que ampliou significativamente as possibilidades da segmentação de imagens ao permitir que redes convolucionais aprendessem representações hierárquicas diretamente dos dados. Arquiteturas derivadas da U-Net consolidaram o aprendizado supervisionado como padrão de referência, alcançando resultados notáveis em diferentes domínios visuais. Entretanto, mesmo com sua expressividade, essas redes tendem a perder coerência geométrica em estruturas de forma irregular e dependem fortemente de grandes volumes de dados anotados. Essas limitações reforçam a relevância de abordagens que integrem aprendizado semântico e regularização geométrica, princípio que fundamenta o método proposto neste trabalho.

Em dermatoscopia, modelos recentes como a GFANet (Qiu *et al.*, 2023), FAT-Net (Wu *et al.*, 2022), ADF-Net (Huang *et al.*, 2024) e ASP-VMUNet (Bao *et al.*, 2025) obtiveram resultados expressivos nos conjuntos de dados de lesões cutâneas ISIC e PH2, ao integrarem estratégias avançadas de atenção e aprendizado multiescala. A GFANet utiliza decodificadores progressivos para refinar as fronteiras das lesões, enquanto a FAT-Net combina convoluções e transformadores para capturar simultaneamente detalhes locais e contexto global. O ADF-Net emprega um duplo codificador (CNNs e *Transformer*) com atenção focal, buscando equilibrar a representação semântica e o contraste interno das lesões. Por sua vez, a ASP-VMUNet aprimora

a análise multiescala por meio de convoluções atours paralelas e deslocamentos de amostragem, ampliando a sensibilidade a variações de forma e textura.

Essas arquiteturas representam avanços relevantes no refinamento das fronteiras e na integração de informações multiescala. Contudo, os próprios autores destacam que, apesar do uso de mecanismos de atenção reversa e transformadores visuais, essas redes ainda enfrentam dificuldades em manter coerência geométrica e consistência estrutural em contextos reais. Situações com baixo contraste, ruído de fundo ou alta variabilidade morfológica frequentemente resultam em fusões indevidas, deformações de fronteiras ou perda de estabilidade entre regiões adjacentes.

Qiu et al. (Qiu *et al.*, 2023) relatam que a GFANet tende a perder consistência global quando aplicada a bases com distribuições distintas. Wu et al. (Wu *et al.*, 2022) observam que a FAT-Net apresenta falhas na diferenciação de fronteiras sob baixo contraste. Huang et al. (Huang *et al.*, 2024) apontam que o ADF-Net permanece sensível a ruídos e inconsistências na fusão entre características locais e globais. De forma semelhante, Bao et al. (Bao *et al.*, 2025) destacam que a ASP-VMUNet reduz a precisão em imagens com variação cromática acentuada e aumenta a complexidade computacional conforme cresce o número de filtros atours.

Essas constatações indicam que, embora as arquiteturas profundas tenham ampliado a capacidade de representação semântica, elas ainda carecem de mecanismos que assegurem estabilidade geométrica e coerência morfológica nas fronteiras segmentadas. Essa limitação impacta diretamente a integridade das regiões delimitadas e a confiabilidade das medidas extraídas, especialmente em aplicações médicas e biomédicas que exigem precisão e reprodutibilidade.

De modo análogo, na segmentação de células sanguíneas, os desafios tornam-se ainda mais complexos devido às características intrínsecas das imagens microscópicas, como a sobreposição de estruturas, a coloração heterogênea e o baixo contraste entre as bordas celulares e o fundo. Diversas variantes da U-Net foram avaliadas nesse contexto, incluindo a U-Net++ (Zhou *et al.*, 2018), R2U-Net (Alom *et al.*, 2018), Attention U-Net (Oktay *et al.*, 2018) e FCN (Long *et al.*, 2015). Embora apresentem bom desempenho global, análises qualitativas revelam limitações persistentes, como a fusão de estruturas adjacentes, a perda de definição em bordas de baixo contraste e a supersegmentação em regiões densamente coradas. Esses comportamentos refletem uma limitação recorrente das arquiteturas puramente convolucionais, cuja ausência de mecanismos explícitos de controle geométrico faz com que o processo de segmentação dependa apenas da resposta local dos filtros convolucionais, resultando em fronteiras

instáveis e contornos morfologicamente inconsistentes.

Essas limitações evidenciam a necessidade de métodos capazes de integrar representação aprendida e coerência geométrica, preservando a consistência semântica ao longo da segmentação. Nos últimos anos, algumas abordagens híbridas começaram a explorar a combinação entre aprendizado profundo e formulações energéticas, mas ainda de forma restrita e voltada a casos específicos. Persistem desafios conceituais e práticos relacionados à integração efetiva entre a dinâmica física dos contornos ativos e os campos de evidência, sobretudo em cenários multirregionais com elevada variabilidade morfológica e interdependência entre estruturas.

O estado da arte atual revela, portanto, uma dupla lacuna: a ausência de uma formulação que una de maneira consistente os princípios geométricos e semânticos da segmentação, e a carência de métodos capazes de lidar, de forma estável, com a evolução simultânea de múltiplas regiões em um mesmo domínio energético. Motivado por esse cenário, o presente trabalho propõe o método *SEmantic Multi-Region Active Contour* (SEMAC), que integra campos de evidência semântica à modelagem física dos contornos ativos, estabelecendo um elo conceitual entre os domínios geométrico e semântico da segmentação. Essa formulação híbrida busca unir a estabilidade e interpretabilidade dos modelos variacionais à adaptabilidade e expressividade das redes profundas, permitindo segmentações contínuas, coerentes e morfologicamente consistentes em contextos de alta complexidade visual e múltiplas regiões de interesse.

1.3 Objetivos

Os objetivos deste trabalho estão organizados em um objetivo geral e um conjunto de objetivos específicos que orientam o desenvolvimento, a validação e a análise do método proposto. O objetivo geral define a meta central da pesquisa, enquanto os objetivos específicos descrevem as etapas metodológicas para sua realização.

1.3.1 Objetivo Geral

Desenvolver o método *SEmantic Multi-Region Active Contour* (SEMAC), um método de segmentação que integra campos de evidência semântica à formulação variacional dos contornos ativos paramétricos. O método propõe uma reformulação da energia externa dos contornos ativos, representada por um campo de evidência, e uma dinâmica de evolução multicontorno capaz de gerar segmentações multirregião a partir de um único contorno inicial. A

abordagem busca assegurar coerência geométrica, consistência semântica e estabilidade evolutiva, permitindo que cada contorno se divida, evolua e estabilize de forma independente conforme a estrutura da imagem.

1.3.2 Objetivos Específicos

Para alcançar o objetivo geral, propõem-se os seguintes objetivos específicos:

- Projetar e implementar o SEMAC, combinando aprendizado supervisionado de campos de evidência com a modelagem física e variacional dos contornos ativos paramétricos;
- Formular uma energia externa aprendida para o modelo de contornos ativos para multirregiões, definida a partir de um campo de evidência semântica supervisionado, capaz de orientar a contração dos contornos em regiões com alta variabilidade de contraste, textura e forma;
- Propor um mecanismo de evolução multicontorno no qual um único contorno inicial evolui adaptativamente sobre o campo energético e, à medida que novas regiões de evidência são identificadas, divide-se em contornos secundários que passam a evoluir e estabilizar-se de forma independente, resultando em uma segmentação multirregião sem necessidade de múltiplas inicializações;
- Definir critérios de parada individuais e adaptativos para cada contorno, assegurando estabilização independente mesmo em regiões de limites difusos ou baixa separabilidade;
- Analisar o comportamento evolutivo do modelo sob diferentes condições experimentais, verificando sua robustez frente a ruído, baixo contraste e variações morfológicas;
- Avaliar a coerência geométrica e a consistência semântica das segmentações realizadas pelo SEMAC obtidas em imagens clínicas de lesões cutâneas e células sanguíneas;
- Comparar o desempenho do SEMAC com métodos clássicos e abordagens supervisionadas, em contextos dermatoscópico e microscópico, por meio de métricas quantitativas e análises qualitativas das fronteiras segmentadas;

1.4 Produção Científica

Durante o período de realização deste doutorado, foram desenvolvidos os seguintes artigos científicos:

1. *Journal of Real-Time Image Processing - A new approach for the detection of pneumonia*

- in children using CXR images based on an real-time IoT system* - Qualis A2 (ENG. IV);
2. *Conference on Graphics, Patterns and Images* - Sistema de Detecção e Classificação de Resíduos Sólidos com Computação em Borda Usando *Deep Learning*; - Qualis A3 (CC);
 3. *Conference on Graphics, Patterns and Images* – Avaliação de OCR Embarcado para Dispositivos Móveis: Desempenho, Privacidade e Usabilidade - Qualis A3 (CC);
 4. *Measurement - Automated Flow for Vickers Hardness Measurement with Deep Learning Techniques* - Qualis A1 (ENG. IV) - (Submetido).
 5. *Sensors - Semantic Multi-Region Active Contour (SEMAC): A Semantic-Geometric Approach for Multi-Region Segmentation* - Qualis A1 (ENG. IV) - (Submetido).

1.5 Organização da Tese

Esta tese está estruturada de forma a apresentar, de maneira gradual e integrada, os fundamentos conceituais, o desenvolvimento metodológico e a validação experimental do método proposto. A organização segue uma progressão lógica, conduzindo o leitor desde os aspectos introdutórios e motivacionais até a consolidação dos resultados e conclusões finais.

O Capítulo 1 introduz o tema, contextualizando o problema da segmentação de imagens e destacando sua relevância científica e aplicada. São discutidas as limitações das abordagens clássicas, as lacunas existentes na literatura e as oportunidades de avanço que motivaram o desenvolvimento do presente trabalho. Além disso, são apresentados os objetivos gerais e específicos, bem como a produção científica realizada durante o período do doutorado.

O Capítulo 2 reúne a base teórica necessária à compreensão do estudo, abordando os principais conceitos e técnicas de segmentação de imagens, desde os métodos baseados em limiarização e contornos até os métodos contemporâneos fundamentados em aprendizado profundo. São detalhados os princípios dos modelos de contornos ativos, suas formulações energéticas e variações, além das abordagens de redes neurais convolucionais e arquiteturas *encoder-decoder*.

O Capítulo 3 descreve minuciosamente a metodologia desenvolvida do *SEmantic Multi-Region Active Contour* (SEMAC). São apresentadas a formulação matemática do modelo, a definição das forças internas e externas, e o processo de construção dos campos de evidência semântica. Também é detalhado o mecanismo de integração dessas evidências à dinâmica dos contornos ativos, que permite a segmentação simultânea e adaptativa de múltiplas regiões de interesse, mantendo coerência geométrica e consistência morfológica ao longo da evolução.

O Capítulo 4 apresenta e discute os resultados experimentais obtidos em diferentes conjuntos de dados, abrangendo tanto cenários sintéticos quanto clínicos. São realizadas análises quantitativas e qualitativas do desempenho do método proposto em comparação com abordagens de referência, considerando métricas consolidadas e avaliações visuais da estabilidade e regularidade dos contornos. O capítulo também inclui uma análise geral e interpretativa sobre o comportamento do SEMAC.

Por fim, o Capítulo 5 apresenta a síntese das conclusões, destacando as contribuições teóricas e práticas alcançadas. São discutidas as implicações do método para o avanço da segmentação de imagens biomédicas, bem como suas limitações atuais e as possíveis extensões que poderão ampliar sua aplicabilidade e desempenho em cenários mais complexos.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta os fundamentos necessários ao desenvolvimento do método proposto. Inicialmente, descrevem-se os contextos clínicos de aplicação (lesões cutâneas e células sanguíneas) e a motivação para segmentação automática. Em seguida, revisam-se os principais métodos de segmentação, dos baseados em similaridade e descontinuidade aos modelos de contornos ativos. Por fim, discutem-se conceitos de aprendizado profundo, com ênfase em arquiteturas convolucionais e no papel de representações aprendidas para a segmentação.

2.1 Condições Médicas Abordadas

São apresentadas as condições médicas escolhidas como estudos de caso para aplicação do método proposto. O objetivo é evidenciar seu uso em cenários reais e seu potencial para apoiar o diagnóstico, por meio da segmentação automática de regiões de interesse a partir de anotações de especialistas.

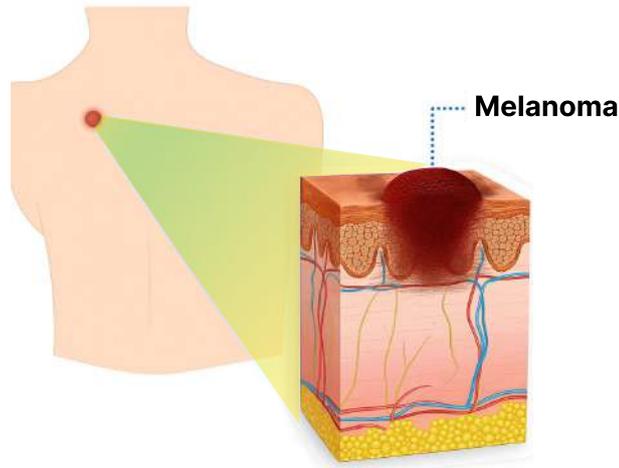
2.1.1 Lesões Cutâneas

O câncer de pele é uma das doenças malignas mais incidentes no mundo e se divide em duas categorias principais: melanoma e não melanoma. Embora o melanoma represente uma fração menor dos casos, é responsável pela maioria das mortes associadas à doença (Boyle *et al.*, 2004; Dildar *et al.*, 2021). Ele tem origem na proliferação descontrolada dos melanócitos, células produtoras de pigmento localizadas nas camadas média e superficial da epiderme. A Figura 1 ilustra essa localização anatômica, destacando a região afetada pelo melanoma. As taxas de incidência e mortalidade variam entre regiões geográficas, influenciadas por fatores ambientais e genéticos, mas a detecção precoce permanece como o fator mais determinante para o sucesso terapêutico e a sobrevivência dos pacientes (Schadendorf *et al.*, 2018).

A dermatoscopia é atualmente o principal exame clínico auxiliar para avaliação de lesões pigmentadas. O método utiliza um dispositivo óptico iluminado que amplia a visualização das estruturas internas da pele, permitindo identificar padrões morfológicos indicativos de malignidade (Mendonça *et al.*, 2015). O diagnóstico definitivo, entretanto, ainda depende da análise histopatológica obtida por biópsia, procedimento invasivo que fornece a confirmação da natureza da lesão.

A heterogeneidade das lesões cutâneas, marcada por variações de forma, textura,

Figura 1 – Representação esquemática do melanoma cutâneo.



Fonte: Adaptado de Rebouças *et al.* (2021).

coloração e contraste, torna o diagnóstico um desafio mesmo para especialistas experientes. Essa variabilidade, associada à necessidade de avaliações rápidas e reprodutíveis, motivou o desenvolvimento de técnicas computacionais capazes de apoiar a identificação e a delimitação precisa das lesões em imagens dermatoscópicas (Dildar *et al.*, 2021).

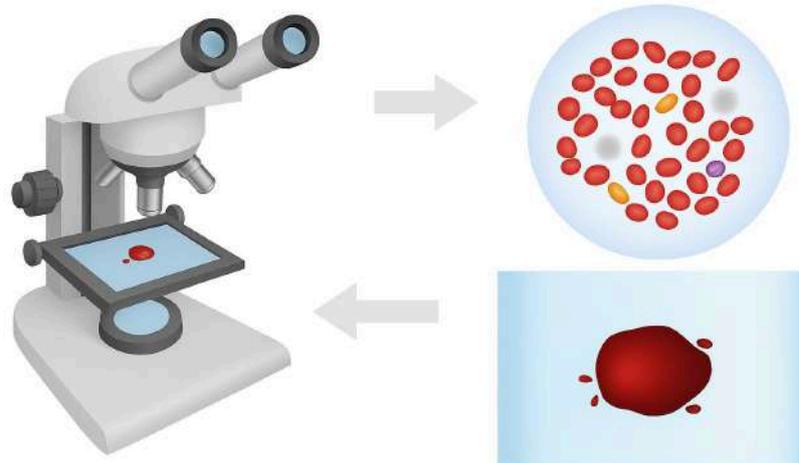
2.1.2 Células Sanguíneas

O exame de células sanguíneas é um procedimento de baixo custo e alta relevância clínica, amplamente utilizado na investigação e no acompanhamento de diversas doenças (Nierhaus *et al.*, 2013). A análise morfológica de hemácias, responsáveis pelo transporte de oxigênio, leucócitos, que atuam na defesa imunológica, e plaquetas, essenciais à coagulação, fornece informações valiosas sobre o estado geral do paciente e auxilia na detecção de distúrbios como anemias, leucemias e infecções.

A microscopia óptica aplicada a esfregaços sanguíneos continua sendo o método mais empregado para essa avaliação. O processo envolve a preparação de uma fina camada de sangue em lâmina de vidro, corada com reagentes específicos, o que permite a observação e caracterização das células sob o microscópio de luz. A Figura 2 apresenta de forma esquemática as etapas desse procedimento, destacando como o método tradicional possibilita a visualização detalhada das estruturas celulares.

Embora amplamente difundido, o método depende fortemente da experiência do examinador, o que pode gerar variações interpretativas e inconsistências, especialmente em contextos de alta demanda. Nesse cenário, a segmentação automática e precisa das células no

Figura 2 – Ilustração esquemática da análise de uma amostra de sangue.



Fonte: Elaborado pelo autor.

campo microscópico torna-se uma etapa essencial para automatizar tarefas como contagem, classificação e identificação de alterações morfológicas, impactando diretamente a acurácia diagnóstica.

Apesar dos avanços em processamento de imagens e aprendizado profundo, a segmentação automática de células sanguíneas ainda representa um desafio considerável. A diversidade morfológica das células, as frequentes sobreposições entre estruturas e as variações decorrentes do preparo dos esfregaços aumentam a complexidade do problema. Além disso, muitos estudos utilizam bases de dados restritas ou focadas em tipos celulares específicos, o que limita a capacidade de generalização dos modelos propostos para cenários clínicos mais amplos.

2.2 Segmentação de Imagens

A segmentação de imagens é uma das etapas mais importantes em VC, pois constitui a base para a análise e interpretação do conteúdo visual. Seu objetivo é dividir a imagem em uma ou mais regiões de interesse, de modo que cada uma apresente homogeneidade segundo um critério específico, como intensidade, textura ou forma, permitindo a análise individual de cada componente. Essa etapa é essencial para a extração de atributos relevantes que servirão de suporte às fases posteriores de reconhecimento, classificação e tomada de decisão. Em termos práticos, segmentar uma imagem significa atribuir um rótulo a cada *pixel* com base em suas propriedades locais e em sua relação com os vizinhos.

Segundo a abordagem clássica de Gonzalez e Woods (2018), as técnicas de segmentação podem ser agrupadas em duas categorias principais, de acordo com as propriedades

analisadas nos *pixels*. A primeira categoria corresponde aos métodos baseados em similaridade, que agrupam *pixels* com características semelhantes, formando regiões internamente homogêneas. A segunda categoria abrange os métodos baseados em descontinuidade, que identificam variações abruptas nos níveis de intensidade entre *pixels* adjacentes, sendo amplamente empregados na detecção de limites de objetos, como nas técnicas de detecção de bordas e contornos.

2.2.1 Segmentação por Similaridade

A segmentação por similaridade fundamenta-se na hipótese de que os elementos pertencentes a um mesmo objeto ou região compartilham propriedades visuais semelhantes, como intensidade, cor ou textura. O objetivo é agrupar *pixels* que apresentem homogeneidade segundo um critério predefinido, de forma a construir regiões internamente consistentes e externamente distintas. Entre as abordagens clássicas dessa categoria destacam-se a limiarização e o crescimento de regiões, ambas diretamente relacionadas à distribuição de intensidades dos *pixels* e à conectividade espacial.

A limiarização consiste em estabelecer um ou mais valores de referência (*limiares*) que separam a imagem em regiões distintas de acordo com o nível de intensidade. Essa técnica é particularmente eficaz quando o histograma da imagem apresenta picos bem definidos, correspondentes às regiões de interesse. No caso mais simples, em que apenas duas regiões são consideradas, o processo é denominado binarização, formalmente expresso pela Equação (2.1), em que L representa o limiar de decisão:

$$B(x,y) = \begin{cases} 1, & \text{se } I(x,y) > L, \\ 0, & \text{caso contrário.} \end{cases} \quad (2.1)$$

Quando múltiplos limiares são empregados, o processo é denominado *multilimiarização*, permitindo subdividir o domínio de intensidade da imagem em diferentes intervalos, conforme ilustrado na Equação (2.2):

$$E(x,y) = \begin{cases} 0, & 0 \leq I(x,y) < L_1, \\ 1, & L_1 \leq I(x,y) < L_2, \\ 2, & L_2 \leq I(x,y) \leq L_{\max}, \end{cases} \quad (2.2)$$

em que $E(x, y)$ representa a imagem rotulada, L_1 e L_2 são os limiares que definem os intervalos de intensidade e L_{\max} é a intensidade máxima do domínio (por exemplo, 255 em imagens de 8 bits). Essa estratégia é especialmente útil em contextos com múltiplos objetos ou tecidos que apresentam propriedades radiológicas distintas, permitindo associar faixas de intensidade a classes específicas.

A limiarização pode ser classificada em três tipos: global, local e adaptativa. Na limiarização global, um único limiar é aplicado a toda a imagem, assumindo iluminação homogênea. Na versão local, o limiar é calculado em pequenas janelas, ajustando-se a variações regionais de brilho e contraste. Já a limiarização adaptativa emprega estatísticas locais (como média, variância ou desvio padrão) para determinar dinamicamente o limiar em função das condições de cada região. Entre os métodos clássicos, destaca-se o algoritmo de Otsu (Otsu, 1979), que seleciona automaticamente o limiar ótimo pela maximização da variância interclasses, apresentando bom desempenho em imagens com histogramas bimodais.

Apesar de amplamente utilizada, a limiarização apresenta limitações notáveis em imagens com iluminação desigual, ruído elevado ou objetos de tonalidade heterogênea. Pequenas variações de intensidade podem causar fragmentação das regiões segmentadas ou fusão indevida entre classes distintas, o que compromete a precisão estrutural da segmentação. Para contornar essas limitações, técnicas baseadas em regiões e conectividade espacial foram introduzidas.

O método de CR constitui uma dessas alternativas, fundamentando-se na análise local da vizinhança dos *pixels*. O processo inicia-se a partir de um ou mais *pixels* semente, selecionados manual ou automaticamente, e expande-se iterativamente pela agregação de vizinhos que satisfaçam um critério de homogeneidade, como a diferença absoluta de intensidade inferior a um limiar δ , formalmente expressa por:

$$|I(x_i, y_i) - I(s_x, s_y)| < \delta, \quad (2.3)$$

em que (s_x, s_y) representa o *pixel* semente. A escolha das sementes e do critério de agregação é determinante para a qualidade da segmentação, podendo resultar em sobresegmentação (divisão excessiva de regiões) ou subsegmentação (fusão indevida de estruturas) se mal ajustadas. Em imagens biomédicas, essas dificuldades são agravadas por fatores como ruído, variação de coloração e sobreposição de tecidos.

Extensões desse paradigma incluem a transformada *watershed*, amplamente empregada na segmentação de imagens médicas. O *watershed* interpreta a imagem como uma

superfície topográfica, na qual as regiões homogêneas correspondem a bacias de drenagem. A partir dos gradientes de intensidade, as fronteiras entre bacias definem as linhas de separação dos objetos. Embora eficiente para realçar estruturas anatômicas, o método é sensível ao ruído e frequentemente conduz à supersegmentação, exigindo filtragens ou marcadores externos para refinar o resultado (Beucher; Meyer, 1993).

2.2.2 Segmentação por Descontinuidade

Diferentemente dos métodos baseados em similaridade, a segmentação por descontinuidade identifica regiões a partir de variações abruptas de intensidade entre *pixels* vizinhos. O princípio central é que as bordas de um objeto correspondem a locais de transição acentuada nos níveis de cinza, onde há uma mudança brusca na intensidade ou no gradiente da imagem.

Uma formulação clássica é dada pela convolução bidimensional entre a imagem $I_{l \times c}$ e uma máscara $M_{3 \times 3}$, conforme a Equação (2.4):

$$V = M_{3 \times 3} * I_{l \times c}, \quad (2.4)$$

em que $*$ representa o operador de convolução. A escolha da máscara determina o tipo de descontinuidade a ser destacada, permitindo evidenciar pontos, linhas ou bordas em diferentes direções (Gonzalez; Woods, 2018).

Entre os operadores clássicos estão Roberts, Prewitt e Sobel, que estimam numericamente as derivadas parciais da imagem. O operador de Sobel, por exemplo, confere maior peso aos *pixels* centrais, o que o torna mais robusto ao ruído. Já o operador de Prewitt utiliza pesos uniformes, favorecendo simplicidade e menor custo computacional.

Embora amplamente utilizados, esses métodos apresentam limitações em imagens reais, especialmente nas biomédicas, onde as bordas costumam ser suaves ou pouco contrastadas. Nesses casos, o gradiente pode gerar bordas fragmentadas ou múltiplas respostas falsas. Para reduzir esses efeitos, aplica-se com frequência uma filtragem gaussiana prévia à detecção, abordagem que fundamenta o detector de Canny (Canny, 1986). Esse método combina suavização, cálculo de gradiente e supressão de não máximos, produzindo bordas mais finas e contínuas.

2.3 Modelos de Contornos Ativos

Os ACM, ou *Active Contour Models*, representam um avanço significativo na segmentação de imagens por introduzirem uma formulação baseada em energia para delinear automaticamente os limites de um objeto (Kass *et al.*, 1988). Nesses modelos, o contorno é representado como uma curva deformável que se ajusta progressivamente às bordas da imagem, buscando o equilíbrio entre suavidade e aderência às estruturas de interesse. Cada ponto da curva evolui iterativamente até atingir uma configuração de mínima energia, moldando-se à forma do objeto de maneira semelhante a uma fita elástica que se deforma conforme as forças que atuam sobre ela (REBOUÇAS FILHO *et al.*, 2011).

O *Snake*, proposto por Kass *et al.* (1988), é o modelo paramétrico clássico dos contornos ativos. A curva é descrita por uma função contínua $c(s) = [x(s), y(s)]$, onde $s \in [0, 1]$ parametriza os pontos do contorno. A minimização da energia total determina o formato final da curva, conforme a Equação (2.5):

$$E = \int_0^1 \{E_{\text{int}}[c(s)] + E_{\text{ext}}[c(s)]\} ds, \quad (2.5)$$

em que E_{int} é o termo de energia interna, responsável por impor regularidade geométrica, e E_{ext} é o termo de energia externa, derivado das propriedades da imagem e responsável por atrair o contorno às bordas.

O termo interno é composto por duas forças principais: uma de *continuidade*, que regula a distância entre pontos sucessivos e evita o alongamento excessivo, e outra de *curvatura*, que mantém a suavidade da curva e evita deformações abruptas (Nixon; Aguado, 2012; REBOUÇAS FILHO *et al.*, 2011). Esse termo é expresso pela Equação (2.6):

$$E_{\text{int}}[c(s)] = \alpha \left| \frac{dc}{ds} \right|^2 + \beta \left| \frac{d^2c}{ds^2} \right|^2, \quad (2.6)$$

em que α controla a tensão (elasticidade) e β a rigidez (resistência à curvatura). Esses parâmetros ajustam o grau de flexibilidade da curva, equilibrando suavidade e aderência às bordas.

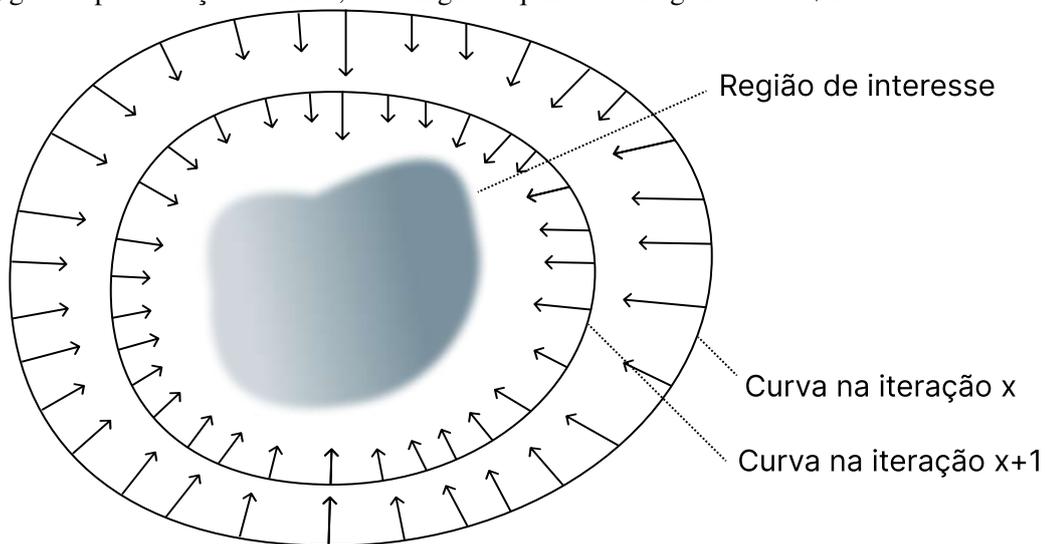
Já o termo externo é derivado das informações visuais da imagem e pode ser definido de forma composta, combinando diferentes forças atrativas ponderadas:

$$E_{\text{ext}}[c(s)] = w_{\text{line}}E_{\text{line}}[c(s)] + w_{\text{grad}}E_{\text{grad}}[c(s)] + w_{\text{term}}E_{\text{term}}[c(s)], \quad (2.7)$$

em que E_{line} está relacionado à intensidade local (atração por linhas ou regiões escuras), E_{grad} representa o gradiente da imagem (atração por bordas) e E_{term} captura terminação e curvaturas de contorno (REBOUÇAS FILHO *et al.*, 2011). Comumente, aplica-se um filtro Gaussiano G_{σ} antes do cálculo do gradiente, reduzindo ruídos e suavizando variações abruptas de intensidade.

A dinâmica do contorno durante o processo de minimização de energia é ilustrada na Figura 3. Nesse exemplo, observa-se a contração progressiva da curva inicial até que ela se estabilize na fronteira da região de interesse, ponto de equilíbrio entre as forças internas e externas.

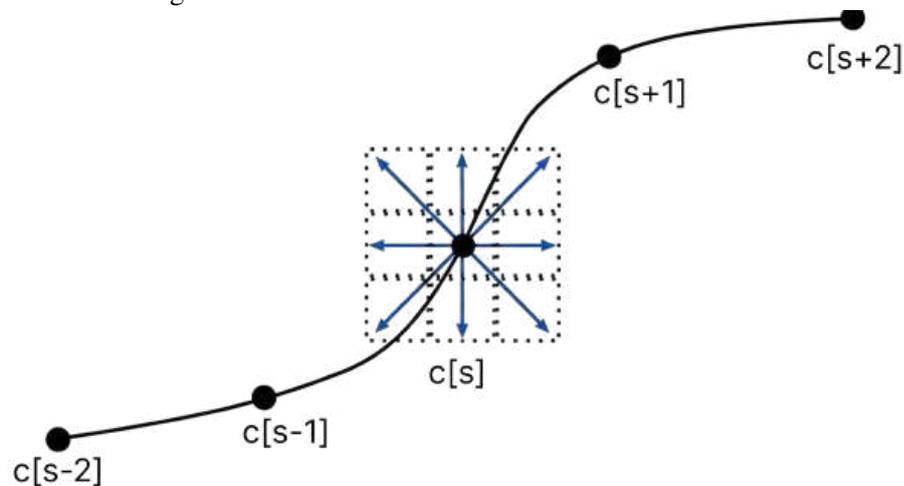
Figura 3 – Evolução contrátil de um contorno ativo. A curva inicial desloca-se em direção à borda do objeto, guiada pelas forças externas, até atingir o equilíbrio energético em $x+1$.



Fonte: Elaborado pelo autor.

A curva é discretizada em um conjunto de pontos de controle conectados entre si, e a energia é avaliada ponto a ponto. Em cada iteração, cada ponto $c[s]$ analisa sua vizinhança local, geralmente composta por oito vizinhos, e desloca-se para a posição que minimiza a energia local (Figura 4). O aumento do tamanho da vizinhança amplia as possibilidades de solução, mas também eleva o custo computacional. A Figura 4 ilustra o processo iterativo de busca por equilíbrio energético.

Figura 4 – Vizinhança de busca para o ponto de controle $c[s]$ no modelo de contornos ativos (ACM). O ponto central (em preto) avalia diferentes posições dentro da janela pontilhada (em azul), selecionando aquela que minimiza a energia local.



Fonte: Elaborado pelo autor, adaptado de REBOUÇAS FILHO *et al.* (2011).

Essa estrutura confere ao modelo *snake* uma natureza autoajustável, capaz de adaptar-se a diferentes geometrias de bordas, mesmo em presença de ruídos moderados. Entretanto, sua representação explícita impede a manipulação de múltiplas regiões simultaneamente e dificulta eventos como divisões ou fusões de contornos. Essas limitações motivaram o surgimento de variações e extensões do modelo clássico, como o *Adaptive Balloon Active Contour Method* (ABACM) (FILHO *et al.*, 2014), que introduz um termo interno adaptativo capaz de otimizar a dinâmica de contração e expansão dos contornos. Diferentemente do modelo balão proposto por Cohen (1991), em que a pressão é uniforme ao longo da curva, o termo adaptativo utiliza informações geométricas e topológicas locais para ajustar, em cada ponto, a intensidade e a direção da força de pressão. Essa força é calculada a partir das posições dos nós vizinhos e da forma global da curva, permitindo deslocamentos independentes, porém coerentes com a geometria local das bordas. Tal mecanismo é particularmente eficaz em regiões homogêneas, nas quais o gradiente da imagem é fraco e as forças externas tendem a se anular, assegurando que a curva continue se movendo em direção às fronteiras de interesse. Como resultado, o modelo evita a degeneração da curva e mantém a convergência mesmo em cenários complexos — como estruturas ramificadas, tubulares ou com concavidades pronunciadas —, tornando-se robusto a diferentes inicializações e adequado à segmentação de múltiplas regiões. Além disso, o uso dinâmico de inserção e remoção de nós durante a evolução preserva o espaçamento paramétrico uniforme, prevenindo colapsos topológicos e reduzindo o tempo de convergência.

Inspirado por esses avanços, o método proposto nesta tese estende a formulação clássica dos contornos ativos ao incorporar um campo de evidência semântica aprendido, capaz de orientar a evolução paramétrica por meio de informações contextuais de alto nível e permitir a segmentação simultânea de múltiplas regiões de forma estável e coerente.

2.4 Redes Neurais Profundas

As redes neurais profundas são responsáveis por grande parte dos avanços recentes em IA, com aplicações expressivas em VC, reconhecimento de padrões e processamento de linguagem natural. Diferentemente das redes neurais artificiais anteriores, arquiteturas com maior profundidade aprendem automaticamente características discriminativas de alta complexidade, reduzindo a necessidade de engenharia manual de atributos (LeCun *et al.*, 2015; Goodfellow *et al.*, 2016). Os fundamentos e o desenvolvimento histórico que viabilizaram esse salto são discutidos na Seção 2.4.1.

Essas redes impulsionaram de forma decisiva o desempenho de sistemas de reconhecimento e análise de imagens, nos quais padrões de textura, forma e estrutura podem ser representados de maneira robusta e eficiente.

O trabalho de Krizhevsky *et al.* (2017) apresentou a AlexNet, uma CNNs profunda que superou abordagens convencionais em tarefas de classificação de imagens no desafio ImageNet, ao combinar múltiplas camadas convolucionais com funções de ativação Unidade Linear Retificada (ReLU), regularização por *dropout* e aceleração em *Graphics Processing Unit* (GPU). Essa arquitetura estabeleceu um novo paradigma para o treinamento de redes profundas, demonstrando a eficácia do aprendizado hierárquico de características visuais em larga escala.

A partir desse avanço, diversas arquiteturas foram desenvolvidas, entre elas as Redes Residuais (He *et al.*, 2015), que introduziram conexões de atalho para facilitar o fluxo do gradiente em modelos muito profundos, reduzindo o problema de degradação de desempenho.

Além da classificação, redes profundas tornaram-se centrais em segmentação semântica. As *Fully Convolutional Networks* (FCN), ou Redes Totalmente Convolucionais (Long *et al.*, 2015), estabeleceram as bases para arquiteturas do tipo *encoder-decoder*, posteriormente refinadas pela U-Net (Ronneberger *et al.*, 2015) e pela SegNet (Badrinarayanan *et al.*, 2016).

Modelos como a U-Net (Ronneberger *et al.*, 2015) e a SegNet (Badrinarayanan *et al.*, 2016) estabeleceram as bases como referências em segmentação biomédica, por integrarem informações contextuais e detalhes locais por meio de conexões entre camadas simétricas.

Esses desenvolvimentos consolidaram o domínio das redes profundas na análise visual de dados, abrindo espaço para métodos que incorporam mecanismos de atenção e aprendizado contextual que orientam processos variacionais, favorecendo maior interpretabilidade e generalização.

2.4.1 Fundamentos do Aprendizado Profundo

O DL é uma vertente do aprendizado de máquina que emprega arquiteturas com múltiplas camadas para modelar funções altamente não lineares, aprendendo representações hierárquicas dos dados: camadas iniciais capturam padrões locais de baixa abstração, enquanto camadas mais profundas codificam conceitos de nível superior (LeCun *et al.*, 2015; Goodfellow *et al.*, 2016).

Historicamente, o campo das redes neurais artificiais surgiu com o Perceptron, proposto por Rosenblatt (1958), o primeiro modelo computacional capaz de realizar classificações lineares. Suas limitações em lidar com problemas não linearmente separáveis, descritas por Minsky e Papert (1969), levaram a um período de estagnação na área. A retomada do interesse ocorreu com a formulação do algoritmo de retropropagação do erro por Rumelhart *et al.* (1986), que tornou viável o treinamento eficiente de redes multicamadas, expandindo a aplicabilidade desses modelos.

O avanço do aprendizado profundo nas últimas décadas foi impulsionado por três fatores principais: (i) o aumento da disponibilidade de grandes bases de dados, (ii) a evolução do hardware, especialmente o uso de GPU, e (iii) o desenvolvimento de funções de ativação e algoritmos de otimização mais estáveis, capazes de mitigar problemas como o gradiente desvanecido (LeCun *et al.*, 2015; Goodfellow *et al.*, 2016). A combinação desses elementos tornou o aprendizado profundo um componente essencial para aplicações contemporâneas, incluindo a análise e segmentação de imagens médicas.

2.4.1.1 Redes Neurais Artificiais

As Rede Neural Artificial (ANN) constituem a base conceitual do aprendizado profundo, inspirando-se no funcionamento biológico dos neurônios para modelar funções não lineares e complexas. Uma rede neural é composta por unidades elementares interconectadas, denominadas neurônios artificiais, organizadas em camadas e conectadas por pesos ajustáveis. Cada neurônio realiza uma combinação linear das entradas e aplica uma transformação não

linear denominada função de ativação, conforme a Equação (2.8):

$$z = \sum_{i=1}^n w_i x_i + b, \quad y = \phi(z), \quad (2.8)$$

em que x_i representa as entradas, w_i os pesos sinápticos, b o viés e $\phi(\cdot)$ a função de ativação. Essa formulação permite que a rede aprenda representações complexas dos dados e realize aproximações universais de funções contínuas, conforme demonstrado pelo teorema da aproximação universal (Hornik *et al.*, 1989; Haykin, 2009).

As funções de ativação desempenham papel fundamental ao introduzirem não linearidade e estabilidade no processo de aprendizado. Entre as mais utilizadas destacam-se a sigmoide, a tangente hiperbólica e a ReLU (Glorot *et al.*, 2011), cuja simplicidade e eficiência computacional mitigam o problema do gradiente desvanecido em redes profundas.

O treinamento da ANN é realizado por meio do algoritmo de retropropagação do erro (*backpropagation*) (Rumelhart *et al.*, 1986), que ajusta os pesos de forma iterativa segundo o gradiente descendente da função de custo $J(\theta)$. Em cada iteração, o erro calculado na camada de saída é propagado para as camadas anteriores, permitindo o ajuste coordenado dos parâmetros. Esse processo é computacionalmente intensivo, mas possibilita a modelagem de relações altamente não lineares entre entradas e saídas.

A capacidade de generalização de uma rede neural depende do número de camadas e neurônios, da função de ativação e das técnicas de regularização utilizadas. Desafios clássicos, como o sobreajuste e o desaparecimento de gradientes, foram mitigados com o desenvolvimento de estratégias como o *dropout*, que reduz a coadaptação entre neurônios, e a normalização em lote (*batch normalization*), que estabiliza a distribuição das ativações durante o treinamento. Além disso, otimizadores baseados em momento adaptativo, como Adam e RMSProp, contribuíram para acelerar a convergência e melhorar a estabilidade do aprendizado.

O avanço do hardware, especialmente o uso massivo de GPU, associado à disponibilidade de grandes conjuntos de dados e ao aprimoramento dos algoritmos de otimização, permitiu a expansão das redes neurais para arquiteturas cada vez mais profundas e especializadas. Esse movimento culminou na consolidação das redes neurais profundas (DNN), que hoje constituem o núcleo das abordagens modernas em visão computacional, reconhecimento de padrões e segmentação de imagens.

2.4.1.2 Redes Convolucionais

As CNNs representam uma das arquiteturas mais transformadoras da área de aprendizado profundo, tendo revolucionado o campo da visão computacional ao combinar princípios de percepção visual humana com propriedades matemáticas da convolução (LeCun *et al.*, 1998; Krizhevsky *et al.*, 2017). O diferencial central das CNNs é a exploração da estrutura espacial das imagens por meio de conexões locais e do compartilhamento de pesos, o que reduz significativamente o número de parâmetros e aumenta a capacidade de generalização.

A operação de convolução bidimensional entre uma imagem $I \in \mathbb{R}^{H \times W}$ e um filtro $K \in \mathbb{R}^{p \times q}$ é definida pela Equação (2.9):

$$S(i, j) = \sum_{m=0}^{p-1} \sum_{n=0}^{q-1} I(i+m, j+n) K(m, n), \quad (2.9)$$

em que $S(i, j)$ corresponde à resposta convolucional no ponto (i, j) . Essa operação atua como um extrator de características locais, detectando bordas, texturas e formas, enquanto preserva a relação espacial entre os *pixels*. As camadas convolucionais são geralmente seguidas por operações de *pooling*, que reduzem a dimensionalidade espacial, e por camadas de ativação não lineares, como a ReLU, que introduzem capacidade discriminativa.

As primeiras CNNs modernas foram introduzidas por LeCun *et al.* (1998), com a LeNet-5, aplicada ao reconhecimento de dígitos manuscritos. No entanto, foi com a AlexNet, proposta por Krizhevsky *et al.* (2017), que as redes convolucionais alcançaram notoriedade, ao vencerem de forma expressiva o desafio ImageNet. Essa arquitetura explorou múltiplas camadas convolucionais, regularização por *dropout* e aceleração por GPU, demonstrando o potencial das CNNs em larga escala.

Posteriormente, arquiteturas mais profundas e eficientes, como a VGGNet, a Inception (Szegedy *et al.*, 2015) e a ResNet (He *et al.*, 2015), introduziram avanços estruturais que permitiram o treinamento de modelos com centenas de camadas sem degradação significativa do desempenho. A ResNet, em particular, inovou ao empregar conexões residuais (*skip connections*) que facilitaram o fluxo do gradiente e viabilizaram o aprendizado em profundidade extrema.

Esses modelos estabeleceram a base para o desenvolvimento de arquiteturas especializadas em segmentação, como as FCN (Long *et al.*, 2015), a U-Net (Ronneberger *et al.*, 2015) e a SegNet (Badrinarayanan *et al.*, 2016). Nessas arquiteturas, a convolução é utilizada não apenas para classificação, mas também para reconstrução espacial e predição densa, permitindo

a geração de máscaras precisas que delimitam regiões de interesse em imagens médicas. A posterior incorporação de modelos baseados em atenção a esse paradigma consolidou as CNNs como a base da segmentação semântica moderna.

2.4.2 Segmentação Baseada em Aprendizado Profundo

O aprendizado profundo modificou profundamente o campo da segmentação de imagens ao integrar extração de características, modelagem contextual e classificação em um processo unificado de otimização (Litjens *et al.*, 2017). Essa abordagem eliminou a necessidade de operadores manuais e permitiu o aprendizado direto das representações relevantes para a tarefa, alcançando resultados mais consistentes e generalizáveis mesmo diante de variações de forma, contraste e textura (Ronneberger *et al.*, 2015; Chen *et al.*, 2018).

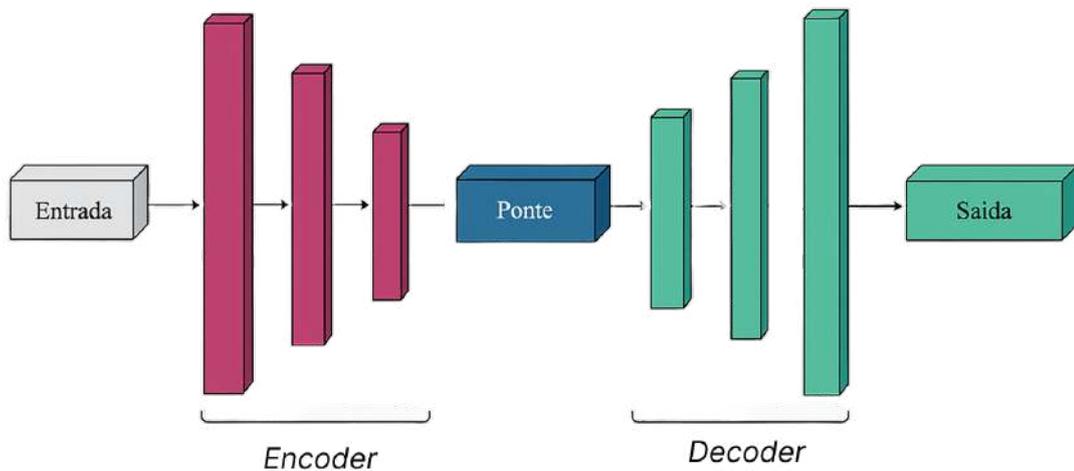
As redes neurais convolucionais (CNNs) são a base desse avanço, possibilitando o aprendizado hierárquico de representações visuais. Nas primeiras camadas, são capturados padrões locais simples, como bordas e texturas, enquanto nas camadas mais profundas surgem abstrações mais complexas, que descrevem formas e relações espaciais entre regiões. Esse comportamento hierárquico tornou viável a segmentação densa (*pixel-wise*) de alta precisão em diferentes contextos biomédicos, industriais e naturais.

Entre as arquiteturas mais influentes destacam-se as do tipo *encoder-decoder*, nas quais uma sub-rede de codificação (*encoder*) comprime as informações da imagem em um espaço de características reduzido, e uma sub-rede de decodificação (*decoder*) reconstrói a segmentação por meio de operações de *upsampling*. Essa estrutura, representada na Figura 5, permite a recuperação progressiva de detalhes espaciais enquanto mantém o contexto global da cena (Badrinarayanan *et al.*, 2016; Ronneberger *et al.*, 2015).

A U-Net (Ronneberger *et al.*, 2015) consolidou esse paradigma ao introduzir conexões de atalho (*skip connections*) entre níveis equivalentes do *encoder* e do *decoder*, combinando informações de baixo e alto nível. Desde então, uma série de variações e aprimoramentos foram desenvolvidos com o objetivo de otimizar a recuperação de detalhes espaciais, a generalização e a eficiência computacional.

A U-Net++ aprimorou a arquitetura original ao adicionar conexões densas entre camadas intermediárias, reduzindo a lacuna semântica entre as fases de codificação e decodificação. A Attention U-Net incorporou módulos de atenção espacial e de canal, ajustando dinamicamente a importância de regiões relevantes da imagem. Já a SegNet (Badrinarayanan

Figura 5 – Esquema de uma arquitetura *Encoder-Decoder*. O *Encoder* comprime os mapas de características, a *Ponte* processa a informação de mais alto nível, e o *Decoder* reconstrói a saída, recuperando a resolução espacial.



Fonte: Elaborado pelo autor.

et al., 2016) propôs a reutilização dos índices de *max-pooling* para preservar informações de posição durante a reconstrução.

A FCN (Long *et al.*, 2015) marcou um ponto de virada ao eliminar as camadas totalmente conectadas, substituindo-as por convoluções 1×1 , o que tornou possível gerar mapas de segmentação com resolução variável e adaptável. Posteriormente, a DeepLabv3+ (Chen *et al.*, 2018) combinou convoluções dilatadas e o módulo *Atrous Spatial Pyramid Pooling* (ASPP), capturando contextos multiescalares sem perda de resolução espacial e refinando as fronteiras segmentadas por meio de um decodificador leve.

Essas arquiteturas representam diferentes estratégias para equilibrar profundidade, contexto e resolução espacial, aspectos essenciais para o desempenho em segmentação densa. Entretanto, mesmo os modelos mais avançados ainda enfrentam desafios na preservação da continuidade geométrica das fronteiras e na coerência morfológica entre múltiplas regiões. Esse cenário motiva o desenvolvimento de abordagens híbridas que combinem a capacidade discriminativa do aprendizado profundo com a estabilidade geométrica de modelos baseados em contornos ativos, como o proposto neste trabalho.

3 ABORDAGEM SEMÂNTICO-GEOMÉTRICA PARA SEGMENTAÇÃO DE MULTIRREGIÕES

Neste capítulo, apresenta-se a metodologia adotada para a implementação do SEMAC. O método proposto consiste em um modelo de segmentação que combina a robustez dos ACM com uma análise semântico-geométrica incorporada por meio de um campo de evidência, de modo a preservar a consistência geométrica durante o processo de segmentação. A formulação opera em múltiplas escalas e realiza a segmentação multirregional a partir de um único contorno, com ramificação controlada, quando o campo indica separações naturais entre os componentes.

O capítulo está organizada em quatro partes principais. Na Seção 3.1, descreve-se a formulação geral do método, enfatizando o fluxo de processamento e a integração entre os componentes energéticos e geométricos. A Seção 3.1.1 detalha a construção do campo de evidência. Na Seção 3.1.2, apresenta-se a modelagem da evolução contrátil dos contornos ativos, bem como os mecanismos de estabilização e divisão automática de regiões. Por fim, as Seções 3.2, 3.3 e 3.4 descrevem, respectivamente, os conjuntos de dados utilizados, as métricas de avaliação e os procedimentos de treinamento.

3.1 *SEmantic Multi-Region Active Contour* (SEMAC)

O SEMAC caracteriza-se como um modelo de contornos ativos que integra uma análise semântico-geométrica, por meio de um campo de evidência, ao processo de evolução paramétrica. Essa integração visa preservar a consistência geométrica das bordas e viabilizar a segmentação de múltiplas regiões a partir de um único contorno, com ramificação controlada.

Em contraste com abordagens que dependem exclusivamente do gradiente de intensidade ou de funções heurísticas, o método considera um campo de evidência que consolida contrastes e transições em diferentes escalas, realçando as *Region of Interest* (ROI) a serem segmentadas e reduzindo ambiguidades em suas fronteiras.

Na prática, o campo de evidência atua como um mapa de compatibilidade espacial: realça regiões coerentes com os objetos de interesse, atenua o fundo e, quando analisado em múltiplas escalas, é incorporado à evolução do contorno ativo para priorizar fronteiras estáveis e detectar estreitamentos que justificam ramificações naturais em cenários com múltiplas regiões de interesse. Dessa forma, o modelo lida com imagens contendo uma ou várias regiões de interesse de forma unificada, superando limitações de abordagens tradicionais que requerem reinicializações sucessivas ou múltiplos contornos independentes para cada objeto.

O campo de evidência $E_\theta(x)$, obtido a partir de pares de entrada e referência, sintetiza contrastes, texturas e indícios estruturais em múltiplas escalas, resultando em um mapa contínuo que expressa o grau de compatibilidade semântica de cada ponto com as ROI. Após a suavização gaussiana, obtém-se $E_\sigma(x)$, utilizado como energia externa do modelo, cujo gradiente $\nabla E_\sigma(x)$ define a direção e a intensidade das forças que guiam o contorno ao longo da evolução dinâmica.

Essa formulação assegura coerência geométrica na preservação das fronteiras, consistência semântica ao alinhar a evolução a informações extraídas e estabilidade evolutiva mesmo em regiões complexas ou visualmente ambíguas. Em conjunto, esses fatores conferem ao SEMAC robustez frente a variações fotométricas e estruturais, além de favorecer a segmentação simultânea e morfologicamente consistente de múltiplos objetos.

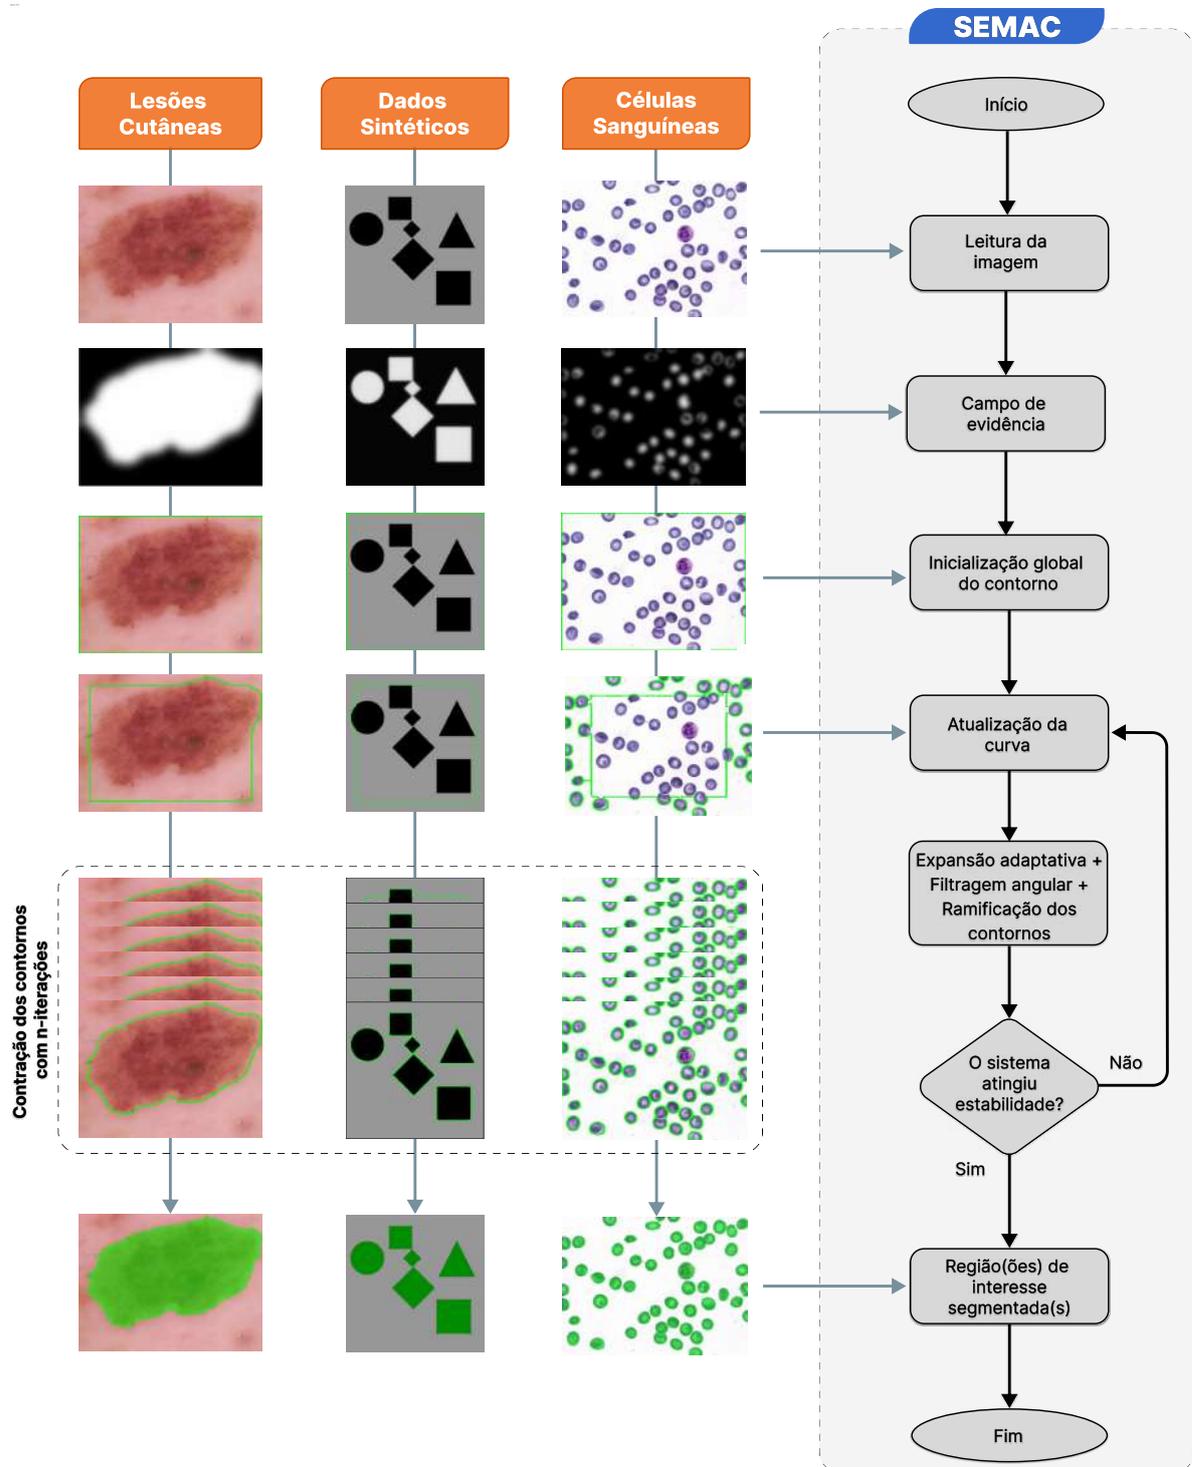
A Figura 6 apresenta uma visão geral do fluxo de processamento do SEMAC, desde a leitura da imagem até a segmentação final. À esquerda, exemplos intermediários ilustram sua adaptação a diferentes contextos; à direita, o fluxograma sintetiza as principais etapas do método, desde o campo de evidência até a estabilização geométrica dos contornos.

3.1.1 Energia Externa Baseada em Campo de Evidência Semântica

A energia externa desempenha o papel de conectar o domínio fotométrico das imagens à modelagem física dos contornos ativos. Ela define como as propriedades visuais da imagem (como cor, textura e intensidade) influenciam o movimento das curvas durante a segmentação. A ideia central é traduzir essas variações visuais em um mapa contínuo de evidência $E_\theta(x)$, que expressa, ponto a ponto, o grau de compatibilidade semântica de cada ponto com as regiões de interesse. Esse campo fornece à evolução dos contornos uma representação contextual aprendida, substituindo as respostas locais de gradiente por informações de maior nível extraídas diretamente da imagem.

Nos Modelos de Contornos Ativos clássicos, a energia externa ideal é aquela capaz de guiar o contorno de forma precisa e estável até as verdadeiras fronteiras do objeto, oferecendo gradientes suficientemente informativos para atraí-lo, mas suaves o bastante para evitar oscilações e capturas em regiões espúrias. Em outras palavras, busca-se um campo energético que combine seletividade e estabilidade, conduzindo a curva com fidelidade ao limite das regiões de interesse. Inspirado por essa concepção, o SEMAC propõe o campo de evidência como uma formulação alternativa para o potencial externo, no qual a informação fotométrica é reinterpretada como um mapa supervisionado de compatibilidade semântica. Essa representação contínua e aprendida

Figura 6 – Fluxo de processamento do método SEMAC. À esquerda, exemplos intermediários nos três conjuntos de dados (sintético, lesões cutâneas e células sanguíneas). À direita, o fluxograma com as etapas de construção do campo de evidência, evolução dos contornos, ramificação controlada e estabilização geométrica.



Fonte: Elaborado pelo autor.

aproxima o método das propriedades esperadas de uma energia externa ideal, ao mesmo tempo em que amplia sua robustez em cenários complexos e multi-região, possibilitando estabilidade e

precisão mesmo em contextos visuais desafiadores.

No SEMAC, a energia externa é representada por um mapa contínuo $E_\theta(x) \in [0, 1]$ definido sobre o domínio da imagem. Diferentemente das formulações clássicas, que dependem exclusivamente do gradiente de intensidade, E_θ é obtido por uma transformação paramétrica supervisionada f_θ , que projeta a imagem em um espaço de evidência semântica, conforme a Equação (3.1):

$$E_\theta : \mathbb{R}^{H \times W} \longrightarrow [0, 1]^{H \times W}, \quad E_\theta(x) = f_\theta(x), \quad (3.1)$$

em que H e W correspondem, respectivamente, à altura e à largura da imagem, e os valores em $[0, 1]$ indicam a intensidade de evidência associada a cada pixel: sendo 0 regiões de baixo interesse e 1 regiões de alta compatibilidade com o objeto.

O mapeamento f_θ é implementado por uma rede convolucional profunda que atua como codificador da imagem, extraindo hierarquicamente os atributos visuais mais relevantes. Essa etapa aplica sucessivas convoluções e operações de agregação para condensar as principais características estruturais (bordas, texturas e variações de intensidade) em um mapa de características latente que representa, de forma compacta, a distribuição espacial de padrões significativos. Em seguida, esse mapa é expandido por um decodificador, responsável por reconstruir uma máscara contínua de evidência, onde cada *pixel* indica sua correspondência com as regiões de interesse. Assim, a rede aprende a projetar diretamente o conteúdo visual da imagem em um campo de evidência semântica com propriedades adequadas para orientar a evolução dos contornos. Em alguns casos, o campo resultante apresenta transições suaves ou regiões parcialmente difusas, refletindo a natureza contínua da representação aprendida. Essas áreas de incerteza não representam falhas, mas indicam ambiguidades visuais que serão posteriormente refinadas pela etapa de contração paramétrica e pelo mecanismo multirregião do SEMAC, responsáveis por estabilizar e definir com maior precisão as fronteiras segmentadas.

Matematicamente, o processo é representado pela composição entre os operadores de contração \mathcal{C} e expansão \mathcal{E} , conforme a Equação (3.2):

$$E_\theta(x) = \mathcal{E}(\mathcal{C}(x)). \quad (3.2)$$

Durante a etapa de extração de características, descrita pela Equação (3.3),

$$\mathcal{C}_s(x) = \sigma(W_s * \delta(\mathcal{C}_{s-1}(x)) + b_s), \quad \mathcal{C}_0(x) = x, \quad (3.3)$$

em que W_s, b_s são os parâmetros da s -ésima convolução, $\sigma(\cdot)$ é a função de ativação LeakyReLU, e $\delta(\cdot)$ realiza subamostragem (*max-pooling* 2×2). A função LeakyReLU é empregada por manter gradientes não nulos para entradas negativas, evitando saturação em regiões de baixo contraste. O uso de *max-pooling* favorece a preservação de características estruturais dominantes, reduzindo o ruído e a redundância espacial. Essa operação reduz gradualmente a resolução espacial da imagem, mas amplia a profundidade informacional das representações, permitindo que a rede codifique tanto detalhes locais quanto padrões semânticos de maior escala.

A reconstrução do campo de evidência é obtida por meio do operador de expansão \mathcal{E} , definido na Equação (3.4):

$$\mathcal{E}_s(z) = \sigma(W'_s * \mathcal{U}(\mathcal{E}_{s-1}(z)) + b'_s), \quad \mathcal{E}_0(z) = z, \quad (3.4)$$

em que $\mathcal{U}(\cdot)$ representa o *upsampling* bilinear seguido de convolução 3×3 . As conexões entre níveis de mesma escala preservam detalhes estruturais e asseguram coerência geométrica na reconstrução, resultando em um mapa contínuo $E_\theta(x)$ que combina precisão de borda e consistência contextual.

Concluída a reconstrução do campo de evidência, o processo de aprendizado volta-se para ajustar os parâmetros θ e ϕ de modo que $E_\theta(x)$ reproduza, com fidelidade e coerência, as regiões de interesse presentes nas referências. Esse ajuste é formulado como um problema supervisionado que combina dois critérios complementares: fidelidade global e coerência local, conforme a Equação (3.5).

$$\mathcal{L}(\theta, \phi) = \mathbb{E}_{x,y}[\mathcal{L}_{\text{glob}}(E_\theta(x), y)] + \lambda \mathbb{E}_x[\mathcal{L}_{\text{loc}}(x, E_\theta(x); \phi)], \quad (3.5)$$

em que λ pondera os termos. A fidelidade global, expressa pela Equação (3.6), impõe proximidade estrutural à máscara de referência y :

$$\mathcal{L}_{\text{glob}}(E_\theta(x), y) = \frac{1}{|\Omega|} \sum_{(i,j) \in \Omega} |E_\theta(x_{ij}) - y_{ij}|. \quad (3.6)$$

A coerência local, definida na Equação (3.7), incentiva transições semanticamente plausíveis:

$$\mathcal{L}_{\text{loc}}(x, E_\theta(x); \phi) = -\log \phi(\mathcal{P}(x), \mathcal{P}(E_\theta(x))), \quad (3.7)$$

em que $\mathcal{P}(\cdot)$ extrai *patches* locais da imagem e do campo de evidência.

Neste ponto, a função ϕ desempenha um papel central e ainda não explicitado. Embora introduzida como parte do termo de coerência local, ϕ atua como um módulo discriminativo responsável por avaliar a plausibilidade semântica entre o conteúdo visual real da imagem e a representação contínua produzida pelo campo de evidência. Em termos conceituais, ela funciona como um avaliador treinável capaz de distinguir regiões coerentes daquelas estruturalmente incompatíveis.

Mais precisamente, ϕ recebe como entrada dois conjuntos de informação: os *patches* extraídos diretamente da imagem, $\mathcal{P}(x)$, que representam a estrutura fotométrica observada; e os *patches* correspondentes extraídos do campo de evidência, $\mathcal{P}(E_\theta(x))$, que representam a estrutura semântico-geométrica inferida pela rede. Ao comparar esses dois espaços locais, ϕ estima o grau de compatibilidade entre a evidência gerada e os padrões estruturais reais da imagem. Regiões em que o campo de evidência reflete adequadamente contrastes, texturas e transições presentes na imagem são avaliadas como consistentes; regiões incompatíveis são penalizadas.

Esse mecanismo confere à ϕ uma função discriminativa essencial dentro da formulação minimax da Equação (3.8). Enquanto os parâmetros θ buscam produzir um campo de evidência cada vez mais plausível em nível global e local, ϕ procura identificar falhas, inconsistências ou distorções presentes na representação gerada. A convergência ocorre quando θ produz campos $E_\theta(x)$ para os quais ϕ já não consegue distinguir regiões inconsistentes, indicando que a coerência local entre imagem e evidência foi alcançada.

Assim, ϕ atua como um mecanismo de fiscalização semântica local, garantindo que o campo de evidência preserve as relações estruturais relevantes e apresente transições suaves e coerentes. Esse comportamento impede o surgimento de artefatos, evita suavizações excessivas e assegura que a energia externa seja adequadamente informativa para orientar a evolução multirregião dos contornos ativos.

O termo \mathcal{L}_{loc} da Equação (3.5) tem papel essencial na regularização semântica do aprendizado. A função ϕ avalia a coerência entre o conteúdo visual original e o mapa de evidência gerado, identificando regiões onde as correspondências estruturais são mais consistentes. Dessa forma, o modelo é incentivado a produzir campos $E_\theta(x)$ que preservem a continuidade das texturas e a integridade das fronteiras, aproximando o comportamento do campo de evidência ao padrão esperado de evidência física no processo de segmentação. Esse equilíbrio entre fidelidade global e coerência local é o que permite à rede generalizar padrões complexos e gerar mapas de

evidência com significado morfológico, ainda que com transições suaves em áreas ambíguas.

A solução ótima resulta do equilíbrio entre fidelidade e coerência, conforme a Equação (3.8):

$$E_{\theta}^* \in \arg \min_{\theta} \max_{\phi} \mathcal{L}(\theta, \phi), \quad (3.8)$$

Após o treinamento, o campo $E_{\theta}(x)$ é suavizado por convolução gaussiana, obtendo-se $E_{\sigma}(x) = G_{\sigma} * E_{\theta}(x)$. Essa etapa atua como um processo de difusão espacial que reduz ruídos de alta frequência e assegura gradientes bem condicionados para a etapa posterior de evolução dos contornos. O vetor gradiente $\nabla E_{\sigma}(x)$, calculado numericamente por operadores diferenciais, define a direção e a intensidade das forças externas aplicadas às curvas paramétricas, estabelecendo o acoplamento físico entre a energia aprendida e a dinâmica geométrica.

Como a derivada espacial comuta com a convolução gaussiana para funções suaves, tem-se:

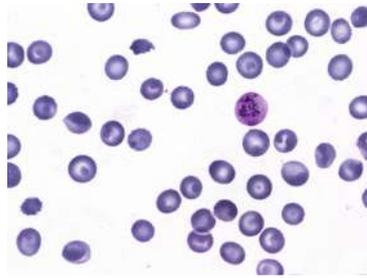
$$\nabla(G_{\sigma} * E_{\theta}) = G_{\sigma} * (\nabla E_{\theta}), \quad (3.9)$$

de modo que calcular ∇E_{σ} equivale a suavizar ∇E_{θ} . Na prática, o gradiente ∇E_{σ} é estimado diretamente a partir do campo suavizado E_{σ} , o que assegura maior estabilidade numérica e reduz a sensibilidade a ruídos de alta frequência nas forças externas.

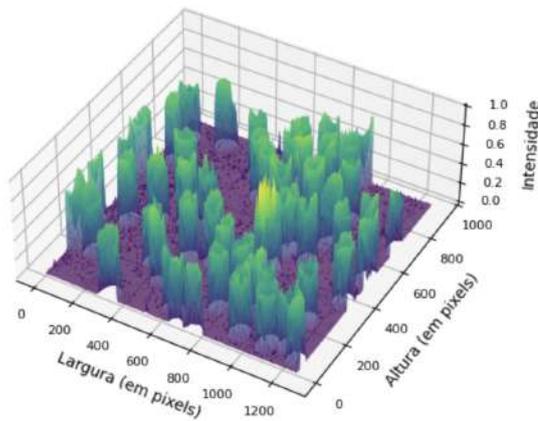
Em síntese, E_{σ} fornece a evidência semântica contínua, ainda que com transições graduais em regiões incertas, enquanto ∇E_{σ} traduz essa evidência em forças orientadoras para o processo de segmentação, sendo posteriormente refinada pelo MCA, que consolida essas fronteiras e elimina ambiguidades residuais. Além da informação fotométrica, o SEMAC atua no domínio de evidências por meio de um campo escalar contínuo $E_{\sigma}(x)$ que consolida indícios de contraste e transição em múltiplas escalas. Nesse domínio, regiões conectadas de alta evidência representam candidatos a regiões de interesse (ROI), enquanto faixas de baixa evidência indicam possíveis fronteiras entre objetos distintos.

Em ACM, a evolução das curvas é conduzida por um equilíbrio entre energias (interna e externa), o que torna o conceito de campo energético uma forma intuitiva de representar o comportamento dessas forças ao longo da imagem. Na Figura 7 é considerada essa analogia energética para ilustrar a distinção entre o domínio fotométrico e o domínio do campo de evidência, considerando uma amostra do conjunto de dados BBBC041Seg.

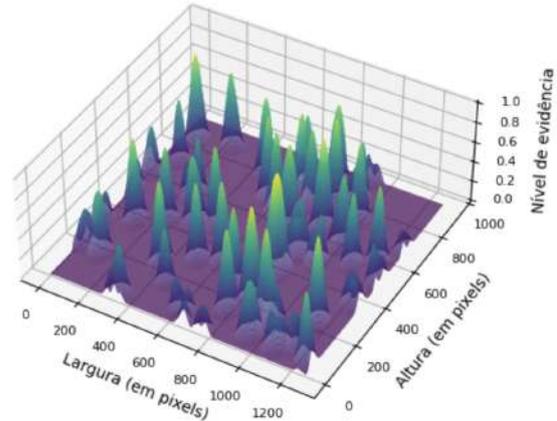
Figura 7 – Analogia visual entre o domínio fotométrico e o domínio do campo de evidência a partir de uma amostra do conjunto de dados BBBC041Seg. De forma conceitual, é ilustrada a transição do espaço de intensidades para um espaço contínuo de coerência semântico-geométrica, proposto pelo SEMAC.



(a) Imagem Original



(b) Domínio Fotométrico



(c) Domínio do Campo de Evidência

Fonte: Elaborado pelo autor.

Na Figura 7.b, observa-se a superfície do domínio fotométrico, construída a partir dos tons de cinza da imagem original. Nesse domínio, as variações de intensidade refletem diretamente as flutuações de iluminação e textura, tornando o campo energético sensível a ruídos fotométricos e inconsistências visuais.

Na Figura 7.c, é representado o domínio do campo de evidência, no qual as regiões de interesse emergem como áreas contínuas de alta evidência, delimitadas por transições bem definidas em torno dos objetos. Essa formulação substitui o gradiente fotométrico tradicional por uma representação semântico-geométrica mais consistente, estabelecendo uma base energética mais estável e informativa para a evolução dos contornos. Com isso, o processo torna-se mais controlado, permitindo ao SEMAC transcender as limitações do gradiente fotométrico e atuar de forma mais robusta na identificação simultânea de múltiplas regiões de interesse.

Do ponto de vista técnico, os termos estabilidade geométrica e coerência geométrica descrevem propriedades desejáveis na evolução dos contornos durante o processo de segmentação. A estabilidade geométrica refere-se à capacidade do contorno em manter sua forma e

continuidade mesmo diante de variações locais de intensidade ou ruído, assegurando que pequenas perturbações no campo de energia não resultem em deformações abruptas ou instabilidades. A coerência geométrica, por sua vez, refere-se à manutenção de uma relação espacial consistente entre as regiões segmentadas, assegurando que as fronteiras resultantes permaneçam compatíveis com a estrutura e a disposição dos objetos na imagem.

No contexto do SEMAC, essas propriedades emergem como consequência direta da introdução do campo de evidência, que proporciona um potencial energético contínuo e semanticamente estruturado, guiando o contorno de forma estável e consistente entre múltiplas regiões de interesse. Em outras palavras, o campo de evidência atua como uma representação refinada da imagem, na qual as regiões relevantes são destacadas enquanto variações irrelevantes são atenuadas. Enquanto o domínio fotométrico apresenta um relevo irregular, cheio de picos e vales induzidos por ruído, o campo de evidência suaviza esse cenário e enfatiza apenas as estruturas significativas. Assim, a estabilidade geométrica traduz a consistência do contorno ao longo do processo evolutivo, ao passo que a coerência geométrica reflete a harmonia entre as fronteiras segmentadas e a morfologia real dos objetos.

3.1.2 Contração Paramétrica e Ramificação Multirregião dos Contornos Ativos

O campo de evidência $E_\theta(x)$, descrito na Seção 3.1.1, é suavizado por meio de uma regularização gaussiana, originando $E_\sigma(x) = G_\sigma * E_\theta(x)$. Esse processo atua como uma difusão espacial que reduz variações de alta frequência, assegura gradientes bem condicionados e preserva a coerência geométrica das fronteiras, fornecendo uma superfície de energia estável para a evolução dos contornos.

A partir desse campo suavizado, define-se a evolução dinâmica dos contornos ativos, cuja forma é ajustada iterativamente pela minimização de um funcional de energia total que combina forças internas e externas. As forças internas impõem continuidade e suavidade à curva, enquanto as forças externas derivam do gradiente direcional da evidência $E_\sigma(x)$, orientando os vértices em direção às regiões de equilíbrio morfológico.

Seja $C : [0, 1) \rightarrow \mathbb{R}^2$ um contorno fechado parametrizado por s , cuja configuração minimiza o funcional de energia total definido na Equação (3.10):

$$\mathcal{E}[C] = \underbrace{\alpha \int_0^1 \|C'(s)\|^2 ds}_{\text{continuidade}} + \underbrace{\beta \int_0^1 \|C''(s)\|^2 ds}_{\text{suavidade}} + \underbrace{\gamma |\Omega_C|}_{\text{balão adaptativo}} + \underbrace{\lambda \int_0^1 E_\sigma(C(s)) ds}_{\text{energia externa semântica}}, \quad (3.10)$$

Os dois primeiros termos do funcional correspondem à energia interna clássica dos contornos ativos, definida na Seção 2.3. O parâmetro α controla a continuidade da curva, impondo tensão elástica entre pontos adjacentes, enquanto β regula sua suavidade, limitando variações abruptas de curvatura. Esses termos mantêm a regularidade geométrica durante a evolução e asseguram que o contorno preserve coesão estrutural mesmo sob a ação das forças externas.

O $E_\sigma(x)$ é o campo contínuo de evidência e $|\Omega_C|$ representa a área delimitada pelo contorno. O termo externo define a interação entre o contorno e a distribuição de afinidade semântica, fazendo com que a curva se desloque para regiões de maior compatibilidade contextual. O termo de balão ($\gamma|\Omega_C|$) atua como uma pressão interna que regula a contração ou expansão da curva, sendo aqui implementado segundo o modelo ABACM (FILHO *et al.*, 2014).

A partir do funcional em Equação 3.10, obtém-se a equação diferencial que rege a evolução do contorno por descida de gradiente, expressa na Equação (3.11):

$$\frac{\partial C}{\partial t} = \alpha C''(s) - \beta C^{(4)}(s) + \gamma \mathbf{N}(s) - \lambda \nabla E_\sigma(C(s)), \quad (3.11)$$

em que $\mathbf{N}(s)$ é o vetor normal unitário ao contorno. Os termos internos de continuidade e suavidade controlam a regularidade geométrica da curva, enquanto o termo externo $-\lambda \nabla E_\sigma$ atua como força de atração semântica.

A implementação discreta da Equação (3.11) utiliza uma representação circular de nós $\{x_k\}_{k=1}^N$, atualizados segundo uma busca local em uma vizinhança quadrada $\mathcal{N} = \{-z, \dots, z\}^2$. Cada nó avalia uma janela local de deslocamentos candidatos e seleciona aquele que minimiza o custo energético total. Essa busca adaptativa permite capturar variações espaciais finas sem comprometer a estabilidade global da curva. O deslocamento ótimo (i_k^*, j_k^*) é obtido conforme a Equação (3.12):

$$(i_k^*, j_k^*) \in \arg \min_{(i,j) \in \mathcal{N}} w_c \Phi_{\text{cont}}(k; i, j) + w_n \Phi_{\text{neigh}}(k; i, j) + w_e \Phi_{\text{ext}}(k; i, j), \quad (3.12)$$

em que os termos de custo são definidos pelas Equações (3.13)–(3.15):

$$\Phi_{\text{cont}}(k; i, j) = \|x_k + (i, j) - x_{k-1}\| + \|x_k + (i, j) - x_{k+1}\|, \quad (3.13)$$

$$\Phi_{\text{neigh}}(k; i, j) = \|x_k + (i, j) - t_k\|, \quad t_k = \text{projeção do bissetor entre } x_{k-1} \text{ e } x_{k+1}, \quad (3.14)$$

$$\Phi_{\text{ext}}(k; i, j) = E_\sigma(x_k + (i, j)). \quad (3.15)$$

Com isso, cada nó se desloca em direção ao ponto de maior evidência semântica dentro de sua vizinhança, garantindo que a evolução da curva siga o relevo de afinidade e se estabilize sobre as fronteiras estruturais das regiões de interesse.

A atualização iterativa dos nós é dada pela Equação (3.16):

$$x_k^{(t+1)} = x_k^{(t)} + (i_k^*, j_k^*), \quad (3.16)$$

seguida por etapas de expansão e filtragem responsáveis por manter a regularidade geométrica e a estabilidade numérica do contorno. Essas etapas implementam um mecanismo de autorregulação estrutural, no qual a discretização da curva se adapta dinamicamente às variações locais do campo de evidência.

Quando a distância entre dois nós consecutivos excede o limiar d_{\max} , é inserido um novo nó intermediário conforme a Equação (3.17):

$$\|x_{k+1} - x_k\| > d_{\max} \Rightarrow x_{k+\frac{1}{2}} = \frac{x_k + x_{k+1}}{2}, \quad (3.17)$$

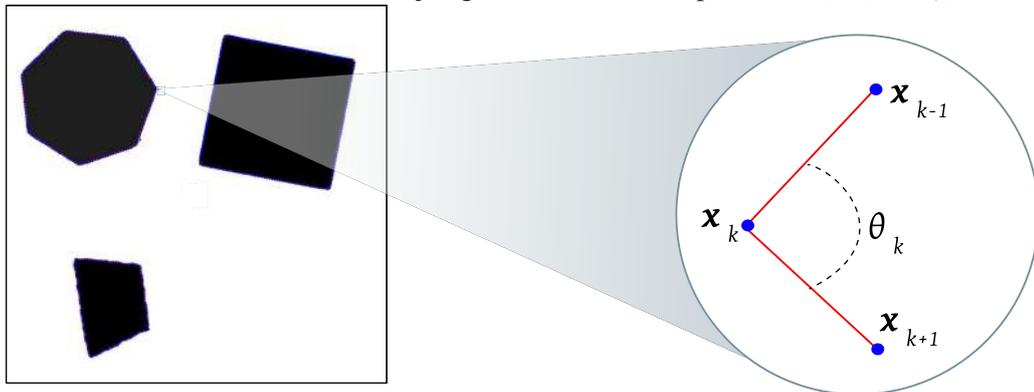
assegurando amostragem uniforme ao longo da curva e evitando descontinuidades topológicas. Esse processo de expansão adaptativa preserva a consistência da representação paramétrica mesmo em regiões de alta curvatura.

Além disso, aplica-se uma filtragem angular definida na Equação (3.18) para remover vértices redundantes:

$$\theta_k = \arccos\left(\frac{(x_{k-1} - x_k) \cdot (x_{k+1} - x_k)}{\|x_{k-1} - x_k\| \|x_{k+1} - x_k\|}\right), \quad (3.18)$$

eliminando nós com $\theta_k < \theta_{\min}$ e preservando a continuidade direcional do contorno. Esse mecanismo atua como um filtro morfológico dinâmico, responsável por suavizar irregularidades locais e prevenir colapsos topológicos durante a evolução.

Figura 8 – Representação do cálculo do ângulo local θ_k entre nós consecutivos de um contorno ativo paramétrico. O detalhamento ilustra a relação geométrica entre os pontos \mathbf{x}_{k-1} , \mathbf{x}_k e \mathbf{x}_{k+1} .



As operações de expansão e filtragem compõem a etapa de regularização local do SEMAC, garantindo que a discretização da curva permaneça compatível com a escala geométrica e energética do campo E_σ .

A evolução de cada contorno é controlada por critérios complementares de convergência e estabilidade local. A condição composta de parada é definida na Equação (3.19):

$$\left(|P^{(t)} - P^{(t-1)}| < \varepsilon\right) \wedge \left(N^{(t)} > N_{\min}\right) \wedge \left(t < T_{\max}\right), \quad (3.19)$$

em que $P^{(t)}$ é o perímetro atual, $N^{(t)}$ o número de nós e T_{\max} o limite máximo de iterações. Durante a evolução, $P^{(t)}$ e a variação média das forças são recalculados a cada iteração, e o processo somente é interrompido quando essa regra de parada é satisfeita, garantindo equilíbrio entre forças internas e externas.

As Figuras 9 e 10 ilustram o processo de evolução multi-região guiado pelo campo de forças adaptativo. Na Figura 9, observam-se os vetores de força (em verde) orientando-se para as regiões de menor potencial, conduzindo a contração e a estabilização dos contornos. Esse mecanismo garante a aderência das fronteiras aos objetos de interesse, mantendo a coerência geométrica ao longo das iterações.

Já a Figura 10 evidencia a fase topológica do processo, em que dois segmentos do contorno aproximam-se e entram em interseção. Nesse instante, o modelo detecta automaticamente o cruzamento entre regiões adjacentes e aciona o mecanismo de divisão (*split*), originando dois contornos independentes, cada um delimitando uma região coerente. Durante a evolução, o SEMAC monitora continuamente a geometria e o campo de forças locais. A divisão é acionada quando ocorre uma interseção entre segmentos não adjacentes do contorno ou quando o gradiente do campo de evidência apresenta direções opostas em nós consecutivos, indicando a presença de duas bacias de energia distintas. Nessas condições, o contorno é automaticamente decomposto em dois subconjuntos de nós conectados, os quais passam a evoluir de forma independente, mantendo a coerência geométrica e semântica de cada região. Esse comportamento demonstra a capacidade do modelo em ajustar-se a variações estruturais sem necessidade de reinicialização manual.

O equilíbrio global é alcançado quando o conjunto de contornos $\{\Gamma_i\}$ torna-se invariante ao longo das iterações, conforme a Equação (3.20):

$$|P^{(t)} - P^{(t-1)}| < \varepsilon \wedge |\Gamma^{(t)}| = |\Gamma^{(t-1)}|. \quad (3.20)$$

Figura 9 – Evolução multi-região orientada pelo campo de forças. Os vetores em verde indicam a direção de movimento dos nós, guiando o contorno para regiões de menor potencial e assegurando a estabilização das fronteiras. À direita de cada linha temporal é exibido o detalhamento de uma região específica, onde se observa a atuação local das forças e a suavização progressiva das arestas.

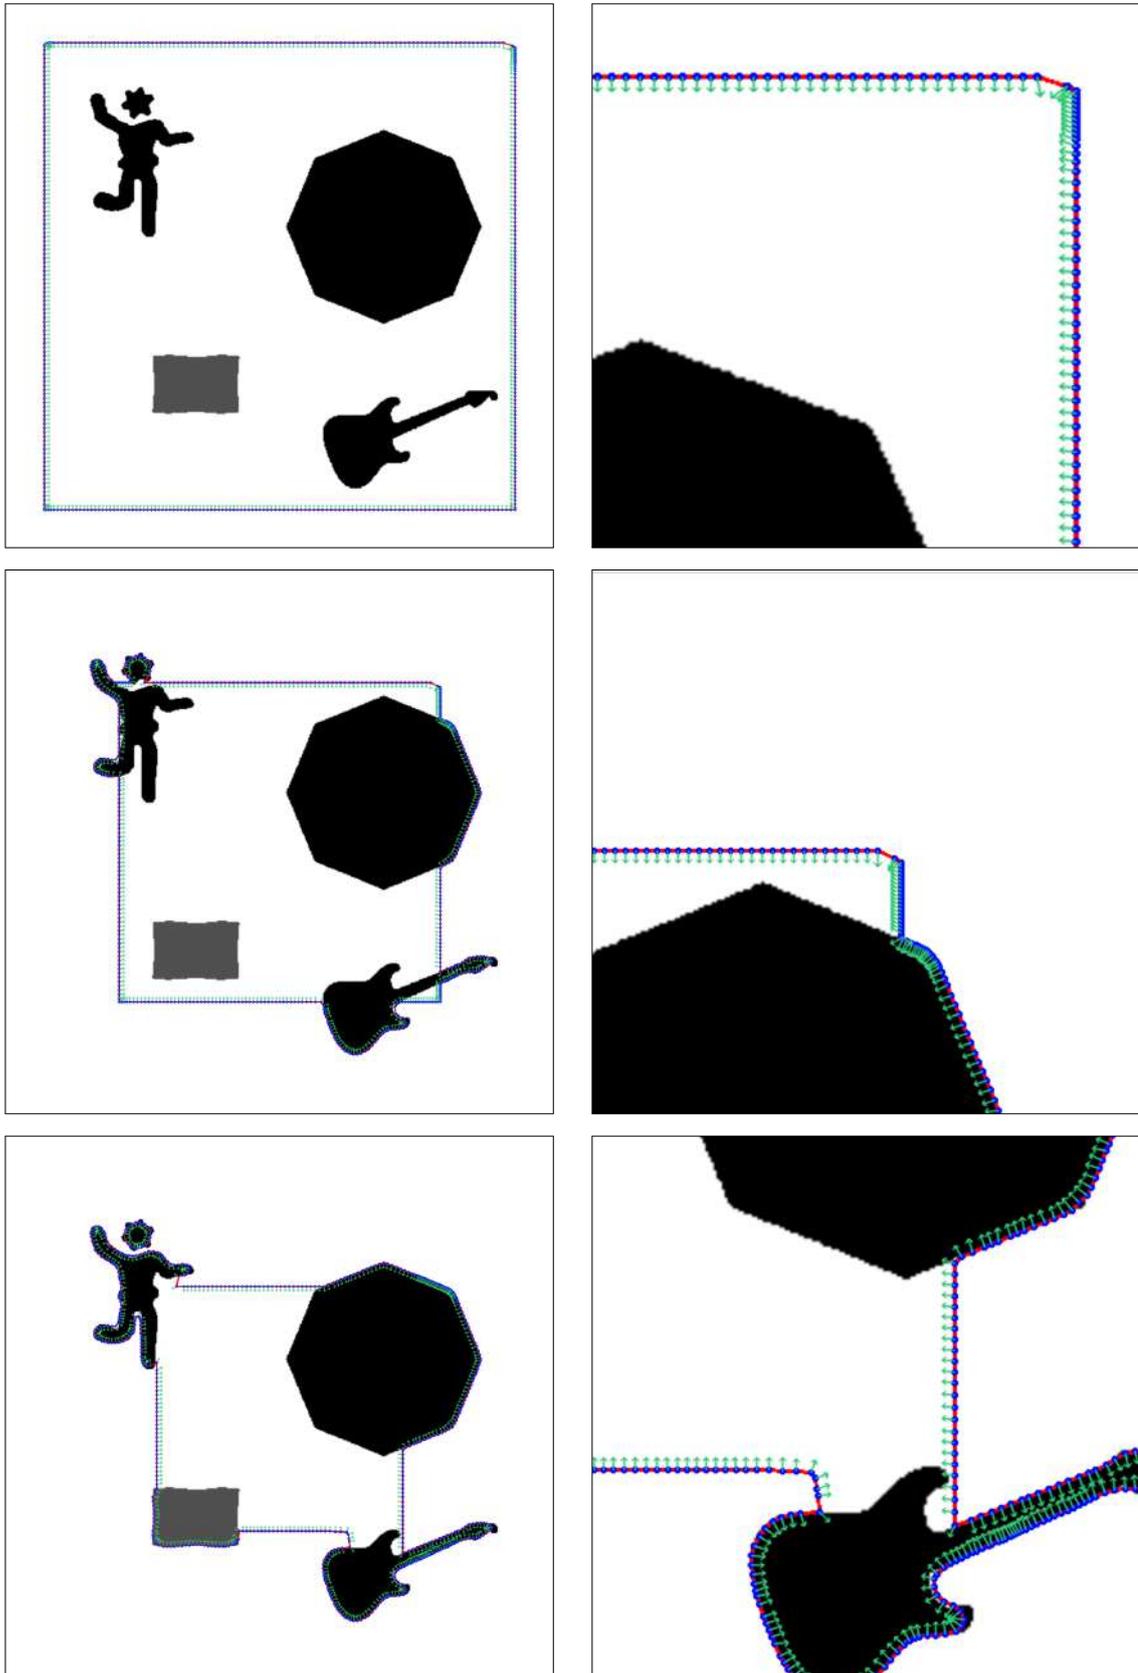
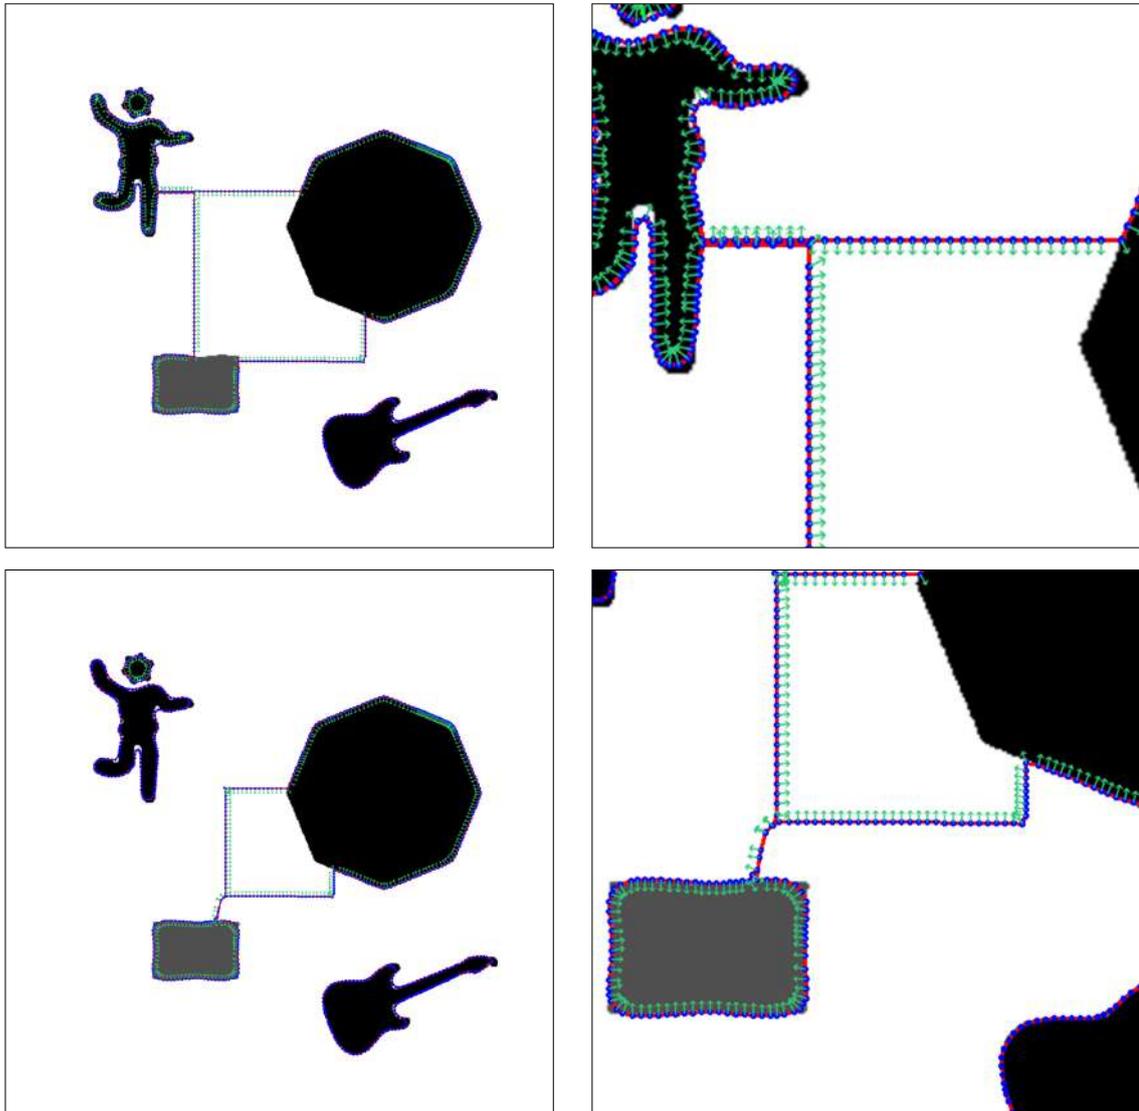


Figura 10 – Sequência de evolução e divisão topológica do contorno. A primeira coluna mostra a detecção de interseção entre segmentos do contorno; na segunda, exibe-se uma ampliação da região. Por fim, formam-se dois contornos independentes, cada um delimitando uma região distinta, evidenciando a capacidade do SEMAC em lidar com múltiplas regiões de forma autônoma.



Fonte: Elaborado pelo autor.

O primeiro termo assegura estabilização geométrica (perímetro), enquanto o segundo confirma estabilização topológica, indicando ausência de novas divisões. Fisicamente, o campo E_σ funciona como uma superfície de potencial sobre a qual o contorno se comporta como uma membrana elástica tensionada, movendo-se sob a ação das forças $-\nabla E_\sigma$ até atingir equilíbrio sobre as fronteiras naturais das estruturas de interesse.

3.2 Conjuntos de Dados

Foram utilizados três conjuntos de dados distintos: um conjunto sintético, construído para representar cenários controlados, e dois conjuntos compostos por dados heterogêneos. Essa diversidade permitiu avaliar o método proposto tanto em condições experimentais, nas quais todos os parâmetros são conhecidos e controlados, quanto em contextos mais complexos, caracterizados por elevada variabilidade visual e estrutural.

3.2.1 Cenário Especialista: Conjunto de Dados Sintéticos

Com o objetivo de avaliar a robustez do método em ambiente controlado e reproduzível, foi construído um conjunto de dados sintético composto por imagens bidimensionais de 512×512 *pixels*, codificadas em 8 *bits*. O conjunto totaliza 1.200 amostras, distribuídas em três categorias principais: bordas ideais, bordas irregulares e alta densidade de objetos, cada uma contendo 400 imagens, sendo 200 de referência e 200 modificadas geradas sobre a mesma geometria. Essa estrutura permite examinar, de forma isolada e comparável, a Sensibilidade do método a variações morfológicas e fotométricas que se aproximam de condições observadas em aplicações reais.

A geração das imagens baseia-se na composição de K objetos geométricos $\{S_i\}_{i=1}^K$ sobre fundo uniforme $B = 255$. As imagens de referência são definidas pela Equação (3.21):

$$I_{\text{ref}}(x, y) = \min \left\{ B, \min_{i=1..K} \left[\mathbb{1}_{S_i}(x, y) v_i + (1 - \mathbb{1}_{S_i}(x, y)) B \right] \right\}, \quad (3.21)$$

em que $\mathbb{1}_{S_i}$ denota a função indicadora do objeto S_i e $v_i \in \{0, 30, 60, 80\}$ representa o tom de cinza do objeto.

As imagens modificadas introduzem variações fotométricas e estocásticas sobre a mesma composição geométrica, conforme a Equação (3.22):

$$I_{\text{mod}}(x, y) = \text{clip} \left(\alpha(x, y) I_{\text{ref}}(x, y) + \eta_{\text{sp}}(x, y) \right), \quad (3.22)$$

onde $\alpha(x, y)$ modela gradientes de iluminação lineares horizontal, vertical ou radiais em torno de um centro deslocado, com variação suave típica no intervalo $0,55 \leq \alpha \leq 1,15$, e $\eta_{\text{sp}}(x, y)$ corresponde a ruído impulsivo sal-e-pimenta de baixa densidade, com probabilidade

por *pixel* entre 0,5% e 2%. O operador $\text{clip}(\cdot)$ limita o resultado ao intervalo $[0, 255]$, truncando valores fora da faixa válida de 8 *bits* e evitando saturações após as transformações.

A Tabela 1 apresenta um resumo das seis categorias do cenário sintético definidos para a etapa de avaliação, organizados conforme o tipo de estrutura e a presença de modificações fotométricas e geométricas.

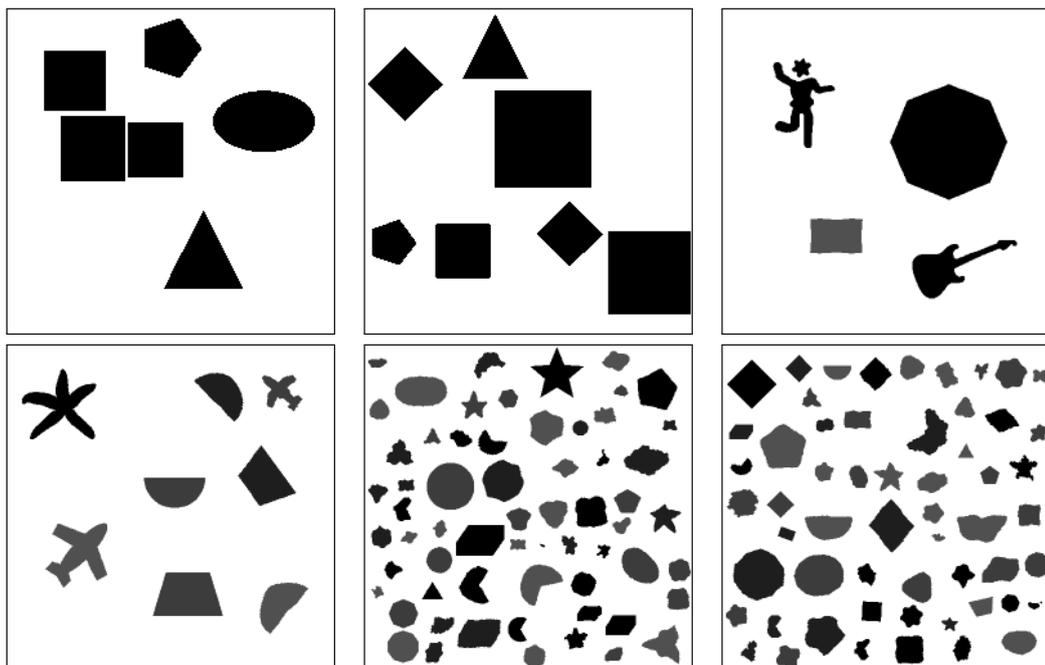
Tabela 1 – Resumo das seis condições sintéticas utilizadas para avaliação do método.

Denominação	Descrição resumida
Bordas ideais	Formas geométricas regulares e bem definidas, sem modificações.
Bordas ideais com modificações	Mesmas formas geométricas, porém com variações fotométricas e ruído leve simulando perturbações de iluminação.
Bordas irregulares	Bordas levemente irregulares e deformadas, mantendo condição limpa.
Bordas irregulares com modificações	Bordas irregulares com inclusão de artefatos e ruído local, representando deformações complexas.
Alta densidade de objetos	Múltiplos objetos próximos ou sobrepostos, sem ruído.
Alta densidade de objetos com modificações	Mesmo padrão denso, acrescido de ruído e variações de intensidade, simulando desafios de separação de fronteiras.

Fonte: Elaborado pelo autor.

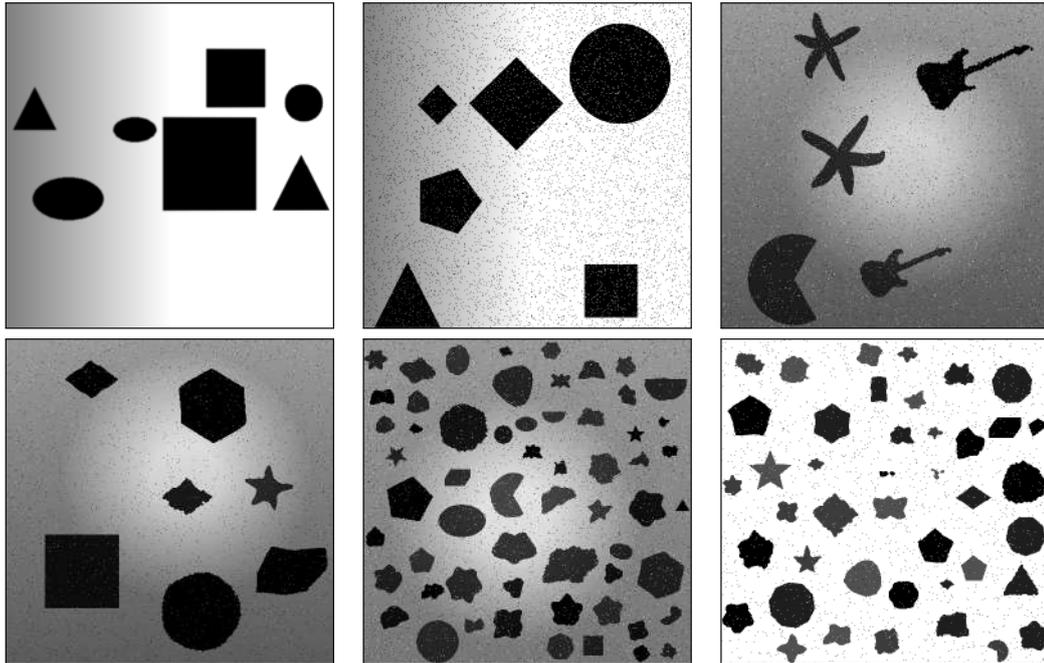
As Figuras 11 e 12 apresentam exemplos representativos do conjunto sintético, contemplando amostras com bordas lineares, bordas irregulares e alta densidade de objetos, tanto em condições ideais quanto com a presença de ruídos ou modificações na imagem, utilizadas para avaliar o desempenho do SEMAC em diferentes contextos geométricos e fotométricos.

Figura 11 – Amostras sintéticas com bordas lineares, bordas irregulares e alta densidade.



Fonte: Elaborado pelo autor.

Figura 12 – Amostras sintéticas com bordas ideais, bordas irregulares e alta densidade.

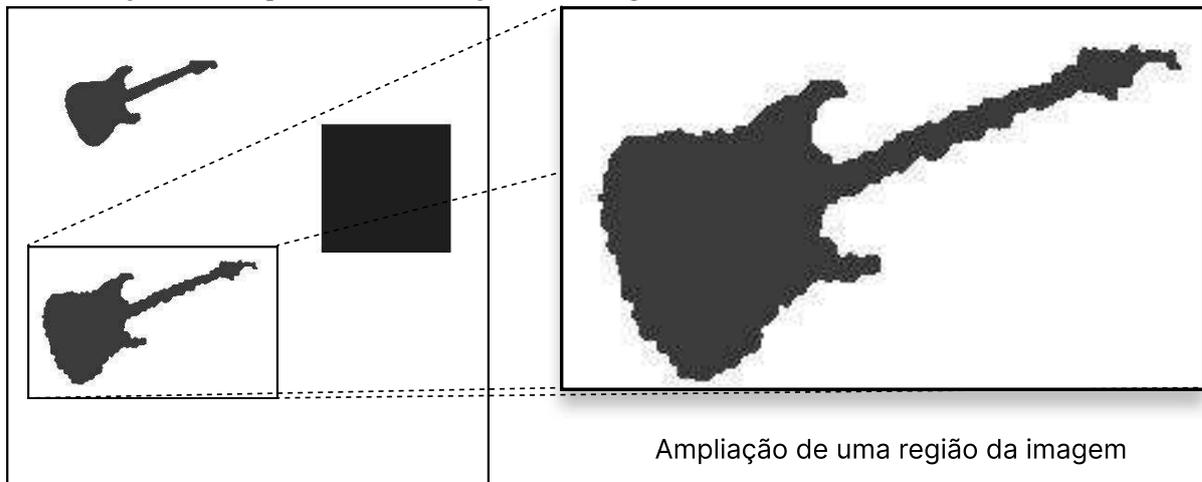


Fonte: Elaborado pelo autor.

Na categoria de bordas ideais, as imagens são compostas por figuras geométricas regulares, incluindo círculos, elipses, retângulos, quadrados, paralelogramos, trapézios, losangos, polígonos regulares de três a dez lados, setores circulares e estrelas de cinco pontas. Os contornos são exatos, sem deformações locais, e os objetos são posicionados de modo a evitar sobreposição entre retângulos delimitadores. O número de objetos por cena varia entre 3 e 40, com rotações e escalas aleatórias que ampliam a diversidade estrutural. As versões com modificações aplicam os gradientes de iluminação e o ruído impulsivo descritos anteriormente, degradando parcialmente o contraste e a uniformidade luminosa.

Na categoria de bordas modificadas, empregam-se as mesmas formas básicas, porém submetidas a irregularização de contorno de baixa frequência e pequena amplitude, com ondulações suaves e microerosões rasas. As deformações preservam conectividade e topologia, produzindo fronteiras lobuladas que se aproximam de estruturas de origem biológica, como lesões cutâneas ou colônias celulares. As versões com modificações adicionam artefatos locais e perda de nitidez, combinando irregularidade de borda com variações fotométricas. A Figura 13 ilustra um exemplo ampliado de um objeto com borda modificada, evidenciando as ondulações e microerosões que caracterizam essa categoria.

Figura 13 – Detalhe ampliado de um objeto sintético com bordas modificadas, evidenciando microerosões e deformações locais que simulam variações morfológicas naturais.



Fonte: Elaborado pelo autor.

Na categoria de alta densidade de objetos, busca-se reproduzir situações em que múltiplas instâncias disputam o espaço da imagem. Cada cena contém entre 80 e 180 objetos de pequeno porte, distribuídos com margens globais de 0 a 1 *pixel* e mecanismo de posicionamento que favorece vizinhanças quase contíguas sem sobreposição, com folgas típicas menores ou iguais a 2 *pixels*. As formas podem apresentar contornos lineares ou levemente irregulares, mantendo variabilidade morfológica interna à categoria. As versões com modificações aplicam os mesmos gradientes de iluminação e ruído impulsivo, intensificando o desafio de separação entre fronteiras adjacentes.

As imagens de referência e modificadas são geradas de forma pareada dentro de cada categoria, isto é, compartilham a mesma composição geométrica e diferem apenas pelas transformações fotométricas e estocásticas.

Essa construção em três eixos de complexidade, aliada ao pareamento entre imagens de referência e modificadas, fornece uma base sólida para a análise do método proposto. O conjunto permite mensurar, de forma sistemática, a influência da geometria dos objetos, da morfologia das bordas e da densidade espacial, bem como a resiliência do processo de segmentação diante de variações fotométricas e de iluminação não uniforme, antes da aplicação em bases reais heterogêneas.

3.2.2 *Cenário Generalista: Conjunto de Dados Heterogêneo*

Na segunda etapa, o método foi avaliado em um contexto mais desafiador e diversificado, abrangendo diferentes tipos de dados com variações de textura, contraste, iluminação, resolução e complexidade estrutural. A utilização de múltiplas bases possibilita uma análise mais ampla, permitindo verificar a capacidade de generalização do método diante de condições heterogêneas.

3.2.2.1 *Imagens Dermatoscópicas*

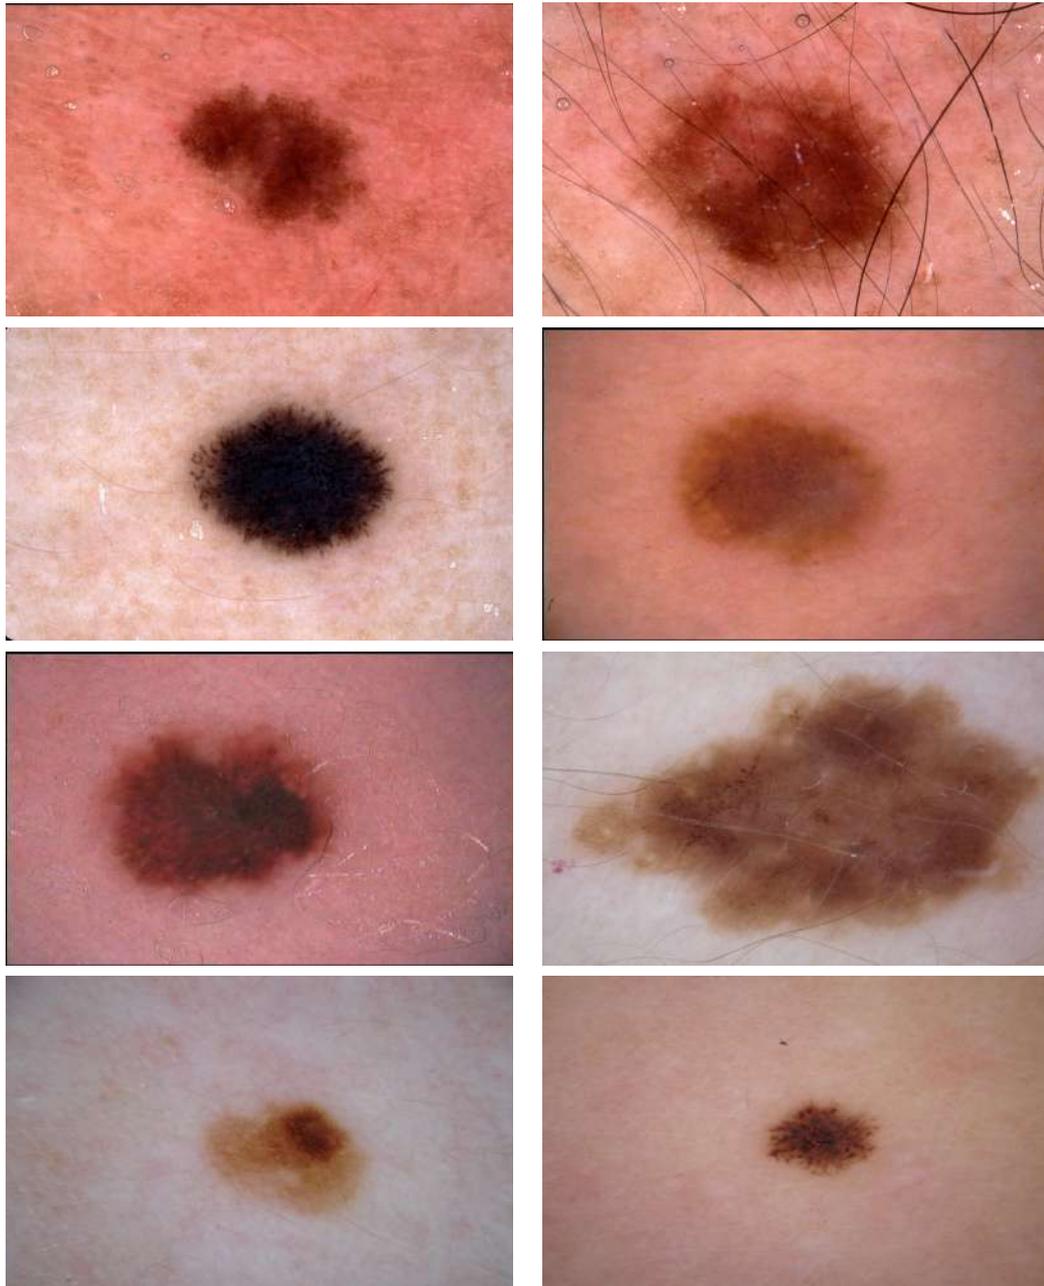
O segundo conjunto de imagens utilizado neste trabalho corresponde ao ISIC 2018: *Skin Lesion Analysis Towards Melanoma Detection Challenge*, promovido pelo ISIC (Tschandl *et al.*, 2018). Esse repositório reúne um conjunto extenso e diversificado de imagens dermatoscópicas voltadas para o estudo e desenvolvimento de métodos automáticos de segmentação e diagnóstico de lesões cutâneas.

O ISIC 2018 contém 3.694 imagens obtidas em condições clínicas reais, apresentando ampla variabilidade de textura, coloração, iluminação e ruído. Cada imagem possui uma máscara binária de referência que delimita manualmente a área da lesão, fornecendo a base para a avaliação quantitativa da segmentação automática. As amostras foram coletadas em diferentes instituições médicas e com distintos equipamentos de captura, o que confere ao conjunto um caráter heterogêneo e desafiador, especialmente para algoritmos sensíveis a variações de domínio. A Figura 14 apresenta alguns exemplos do conjunto de imagens do ISIC.

As imagens incluem diferentes tipos de lesões pigmentadas, como melanomas, nevos e queratoses, cada uma com padrões morfológicos particulares que dificultam a detecção de fronteiras precisas. A presença de sombras, pelos e variações de contraste representa outro fator de complexidade, pois interfere diretamente na definição dos contornos e na distinção entre regiões de pele saudável e áreas lesionadas.

Nesse contexto, o ISIC 2018 foi empregado para avaliar a robustez e a capacidade de generalização do método proposto frente a situações clínicas mais complexas. A diversidade do conjunto permite testar o comportamento do modelo diante de situações em que a coerência geométrica e a estabilidade topológica são essenciais para evitar sobresegmentações e falsos positivos. Essa base de dados constitui, portanto, um importante parâmetro de comparação com abordagens consolidadas da literatura, possibilitando validar o desempenho do modelo em um

Figura 14 – Exemplos de imagens do conjunto ISIC 2018.



Fonte: Elaborado pelo autor.

ambiente realista e desafiador.

3.2.2.2 *Imagens Microscópicas de Células Sanguíneas*

O terceiro conjunto de dados utilizado foi o *BBBC041Seg: Segmentação Automática de Células Sanguíneas em Lâminas Microscópicas* (Depto *et al.*, 2021), um conjunto público desenvolvido especificamente para a tarefa de segmentação de células sanguíneas. Ele é composto por 1.328 imagens no formato PNG, cada uma acompanhada de sua respectiva máscara binária

de referência. As imagens possuem dimensões de 520×696 *pixels* e profundidade de 8 *bits*. As anotações foram realizadas manualmente por especialistas, assegurando a Precisão na delimitação dos contornos celulares.

Esse conjunto é particularmente relevante para a avaliação de métodos de segmentação, pois reproduz condições reais de microscopia e impõe múltiplos desafios: alta densidade de células em campo reduzido, presença de sobreposição e contato entre objetos, variações sutis de forma e intensidade decorrentes tanto da diversidade biológica quanto do processo de coloração, além de artefatos de fundo inerentes à preparação das lâminas. Esses fatores tornam o BBBC041Seg um cenário adequado para verificar a capacidade do método em lidar com limites pouco contrastados e com elevada variabilidade visual.

A diversidade de amostras pode ser observada na Figura 15, que apresenta diferentes condições de microscopia contempladas pelo conjunto BBBC041Seg. Nota-se a presença de campos com baixa e alta densidade celular, variações morfológicas expressivas, diferenças de coloração e intensidade, além de situações em que células aparecem isoladas ou em agrupamentos sobrepostos. Essa heterogeneidade torna o conjunto um recurso valioso para avaliar a capacidade do método em lidar com limites pouco contrastados, bordas difusas e elevada variabilidade estrutural.

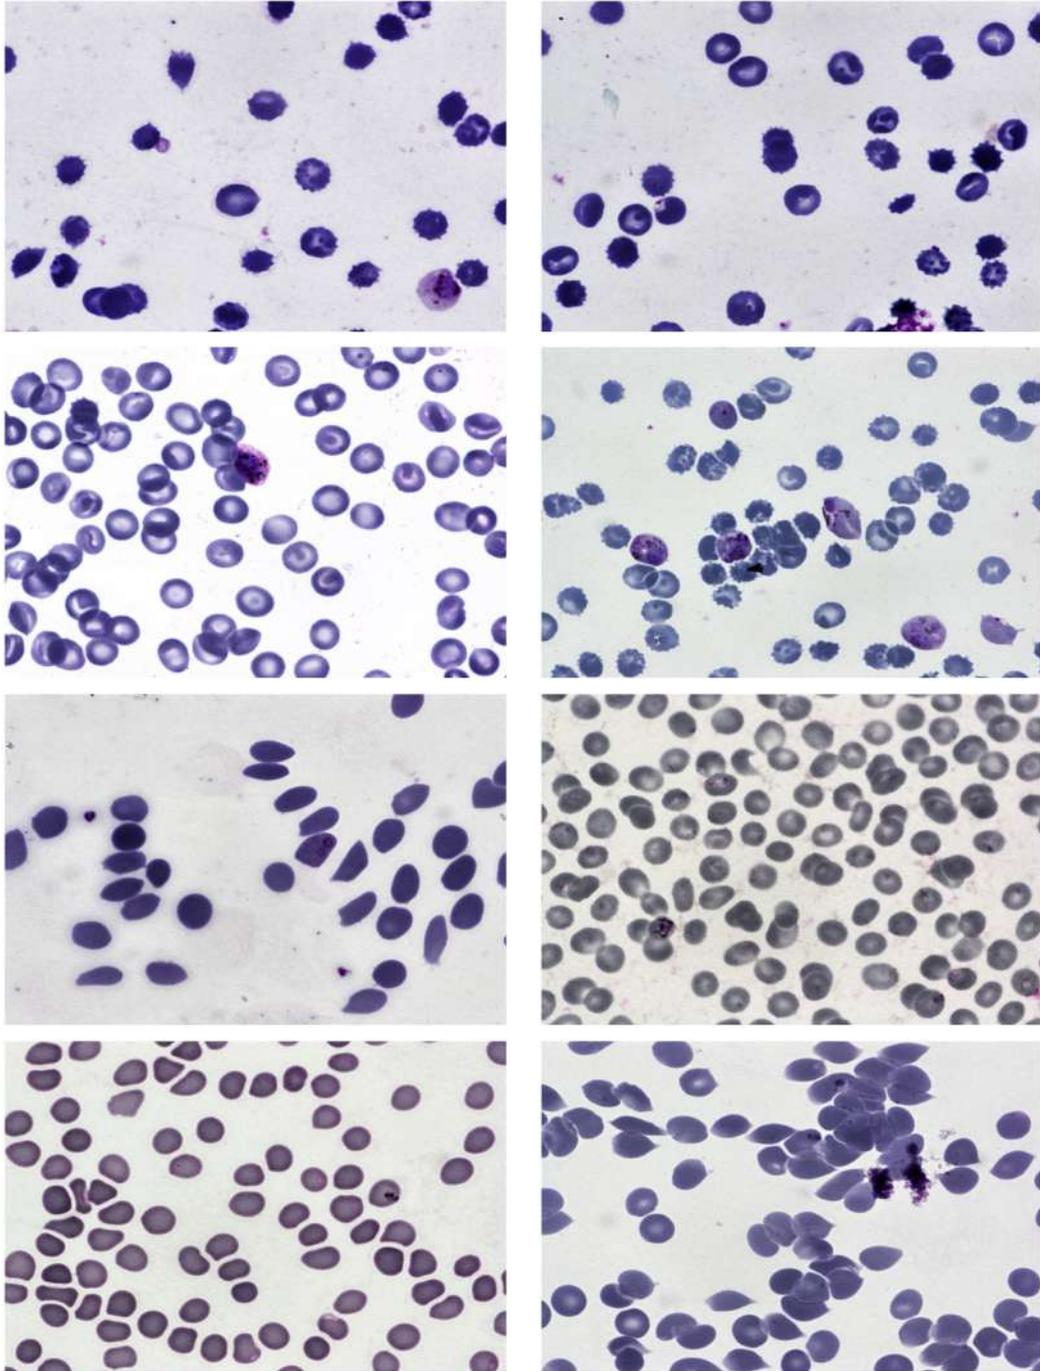
3.3 Métricas de Avaliação para Segmentação

Esta seção descreve as métricas utilizadas para avaliar o desempenho do SEMAC nos diferentes conjuntos de dados empregados: o conjunto sintético controlado, as imagens dermatoscópicas de lesões cutâneas e as amostras microscópicas de células sanguíneas. A escolha dos indicadores seguiu critérios amplamente reconhecidos na literatura (Metz, 1978), assegurando comparabilidade com estudos anteriores e consistência na interpretação dos resultados.

Essas métricas quantificam o grau de concordância entre a região segmentada pelo método (*Segmented Region (SR)*) e a máscara de referência (GT). No conjunto sintético, as máscaras foram geradas automaticamente durante a criação dos dados, garantindo correspondência exata entre imagem e referência. Nos demais conjuntos, a GT foi obtida manualmente ou semiautomaticamente, conforme o tipo de dado e o protocolo de anotação adotado.

Em um cenário de segmentação binária, no qual a imagem é composta apenas por duas regiões, o problema pode ser interpretado como uma tarefa de classificação de dois rótulos. Nessa configuração, cada *pixel* é classificado como pertencente à ROI ou ao fundo (*Background*

Figura 15 – Exemplos do conjunto de dados BBBC041Seg, composto por imagens microscópicas de células sanguíneas.



Fonte: Elaborado pelo autor.

Region (BR)), representados respectivamente pelos valores 1 e 0 (Yu *et al.*, 2023). Assim, a ROI é tratada como classe positiva e o BR como classe negativa, permitindo que a avaliação se baseie na contagem de *pixels* corretamente e incorretamente classificados.

O objetivo central é que a SR, também chamada de máscara predita, reproduza com a maior fidelidade possível a ROI definida no padrão-ouro. Essa correspondência é representada

por uma matriz de confusão 2x2, ilustrada na Figura 16, que organiza os *pixels* de referência e predição em quatro categorias fundamentais: o Verdadeiro Positivo (VP), que corresponde às regiões de concordância entre o método e a referência; o Falso Positivo (FP), que indica áreas detectadas indevidamente; o Falso Negativo (FN), que representa regiões reais não identificadas pelo modelo; e o Verdadeiro Negativo (VN), que abrange os *pixels* corretamente reconhecidos como fundo.

Figura 16 – Matriz de confusão para segmentação binária, destacando os casos de acerto (verde) e erro (vermelho). A região de interesse e a região de fundo são comparadas entre a máscara de referência e a segmentação predita, originando os quatro elementos fundamentais: VP, VN, FP e FN.

	Predito para a região de interesse	Predito para a região de fundo	
Referência para a região de interesse	Verdadeiros Positivos (VP)	Falsos Negativos (FN)	<div style="display: flex; flex-direction: column; align-items: center;"> <div style="display: flex; align-items: center; margin-bottom: 5px;"> <div style="width: 15px; height: 15px; background-color: #ffcdd2; margin-right: 5px;"></div> Erros </div> <div style="display: flex; align-items: center;"> <div style="width: 15px; height: 15px; background-color: #c8e6c9; margin-right: 5px;"></div> Acertos </div> </div>
Referência para a região de fundo	Falsos Positivos (FP)	Verdadeiros Negativos (VN)	

Fonte: Elaborado pelo autor.

A interpretação dessas categorias é essencial para compreender o impacto dos erros de segmentação em diferentes contextos. Em imagens médicas, por exemplo, falsos negativos podem indicar regiões de contorno não reconhecidas, enquanto em aplicações industriais podem corresponder a falhas não detectadas em superfícies. Já os falsos positivos podem surgir de ruídos, sombras ou variações de textura interpretadas incorretamente como regiões de interesse. Em qualquer cenário, esses erros afetam diretamente a confiabilidade das máscaras preditas e, conseqüentemente, das métricas derivadas da matriz de confusão, que expressam o equilíbrio entre detecção precisa e controle de classificações indevidas.

Para mensurar objetivamente esse comportamento e avaliar a qualidade das segmentações produzidas pelo modelo, são utilizadas métricas consolidadas que traduzem numericamente o desempenho obtido. Com base nessa formulação, as métricas foram agrupadas em duas cate-

gorias complementares: as métricas baseadas em classificação, apresentadas na Subseção 3.3.1, voltadas à mensuração global de acertos e erros; e as métricas de similaridade, descritas na Subseção 3.3.2, que analisam a sobreposição geométrica e a fidelidade espacial entre a região predita e o padrão-ouro.

Essa organização favorece uma análise abrangente, capaz de capturar tanto a eficiência estatística do algoritmo quanto sua capacidade de preservar a morfologia das estruturas segmentadas, o que se mostra especialmente relevante nos experimentos realizados, em que o SEMAC combina inferência semântica e refinamento geométrico orientado por campo de evidência.

3.3.1 Métricas Baseadas em Classificação

As métricas baseadas em classificação avaliam a capacidade do algoritmo em distinguir corretamente as classes envolvidas na segmentação, classificando cada *pixel* como pertencente à ROI ou ao fundo (BR). Nesse contexto, cada imagem segmentada pode ser interpretada como um conjunto de decisões binárias, em que o modelo atribui a cada *pixel* um rótulo positivo (região de interesse) ou negativo (fundo). Essa formulação permite derivar os VP, FP, VN e FN que compõem a matriz de confusão e servem como base para o cálculo das principais métricas de desempenho: Acurácia, Precisão, Sensibilidade e Especificidade.

A Figura 17 apresenta uma representação visual dessa relação, exemplificando como o processo de segmentação é traduzido em elementos da matriz de confusão e destacando a associação direta entre esses componentes e as fórmulas das métricas correspondentes.

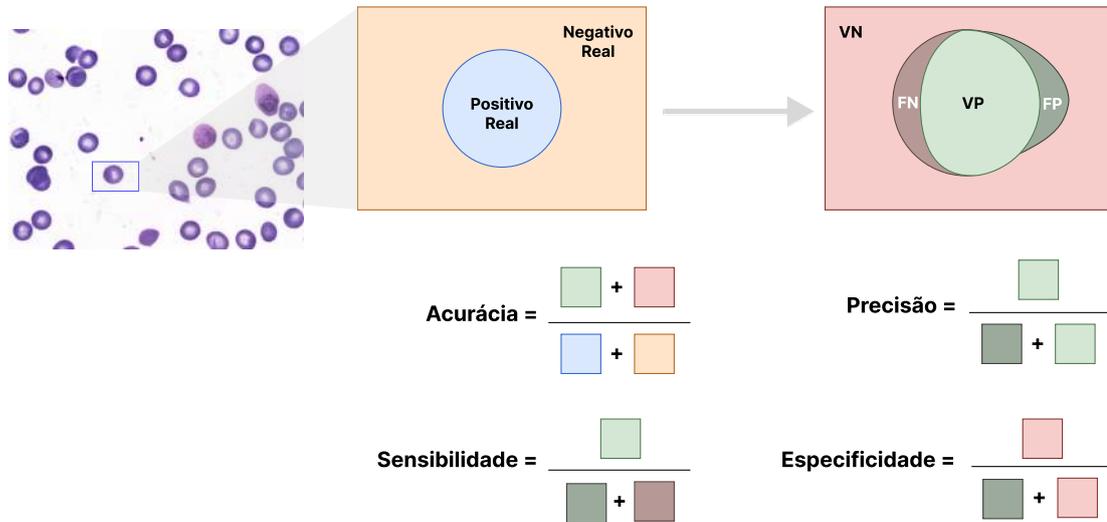
3.3.1.1 Acurácia

A Acurácia (*Acc*) expressa a proporção global de *pixels* corretamente classificados em relação ao total avaliado, englobando tanto as ROI quanto o BR. Em segmentação binária, cada *pixel* é tratado como uma instância independente, podendo pertencer ou não à estrutura-alvo. Assim, a Acurácia representa o grau geral de concordância entre a máscara predita (SR) e o padrão-ouro (GT), conforme definido na Equação 3.23.

$$\text{Acc} = \frac{VP + VN}{VP + VN + FP + FN} \quad (3.23)$$

Valores elevados de Acurácia indicam boa correspondência global entre a segmen-

Figura 17 – Relação entre o processo de segmentação e a matriz de confusão, destacando os quatro desfechos possíveis (VP, FP, VN e FN) e as métricas derivadas.



Fonte: Elaborado pelo autor.

tação gerada e a referência, o que pode refletir, por exemplo, a detecção correta de uma área defeituosa em uma superfície industrial, o delineamento preciso de uma estrutura biológica ou o isolamento coerente de objetos em um cenário sintético. Em situações clínicas, como na análise de lesões cutâneas, a Acurácia pode representar o alinhamento entre a área delimitada pelo modelo e a região afetada na pele, enquanto em amostras de sangue reflete a identificação correta das células sem a inclusão de regiões do fundo microscópico. Apesar de seu caráter intuitivo, a Acurácia tende a ser limitada em contextos de forte desbalanceamento entre classes, que podem favorecer artificialmente os acertos no fundo. Por esse motivo, deve ser analisada em conjunto com outras métricas mais sensíveis à classe positiva, como Sensibilidade, Precisão e os índices de sobreposição (Dice e IoU) (Zou *et al.*, 2004).

3.3.1.2 Especificidade

A Especificidade (Spec) quantifica a capacidade do modelo em reconhecer corretamente os *pixels* pertencentes à classe negativa, isto é, ao fundo (BR). Essa métrica indica o quanto o modelo evita classificar regiões neutras ou irrelevantes como pertencentes à ROI, conforme descrito na Equação (3.24).

$$\text{Spe} = \frac{VN}{VN + FP} \quad (3.24)$$

Altos valores de Especificidade demonstram que o algoritmo minimiza a ocorrência de falsos positivos, preservando o fundo original sem incorporar ruídos ou artefatos. Em contextos clínicos, isso equivale a evitar a marcação indevida de áreas saudáveis como lesão ou estrutura anatômica; em cenários industriais, significa não identificar incorretamente uma região íntegra como defeituosa. A Especificidade isoladamente, contudo, não garante boa segmentação, pois um modelo muito conservador pode evitar falsos positivos às custas de ignorar regiões de interesse. Por isso, deve ser avaliada em conjunto com a Sensibilidade e outras métricas de equilíbrio, assegurando o controle simultâneo entre rejeição do fundo e detecção eficaz das estruturas relevantes (Zou *et al.*, 2004).

3.3.1.3 Sensibilidade

A Sensibilidade (Sens) mede a proporção de *pixels* positivos corretamente identificados pelo modelo, refletindo sua capacidade de recuperar integralmente a região de interesse. Sua definição é apresentada na Equação (3.25).

$$\text{Sens} = \frac{VP}{VP + FN} \quad (3.25)$$

Alta Sensibilidade indica que o método cobre adequadamente a região-alvo, evitando a omissão de áreas relevantes. Essa característica é essencial em aplicações que exigem detecção completa de estruturas, como identificação de falhas, análise de componentes visuais ou reconhecimento de padrões em imagens biológicas. Em um exemplo clínico, alta Sensibilidade pode indicar que o modelo segmenta toda a área de uma lesão, sem deixar regiões patológicas de fora, ou que detecta integralmente células sobrepostas em uma amostra sanguínea. Entretanto, priorizar apenas a Sensibilidade pode aumentar o número de falsos positivos, reduzindo a Precisão e a Especificidade. Dessa forma, a análise integrada dessas métricas é fundamental para verificar se o modelo mantém equilíbrio entre abrangência na detecção e fidelidade morfológica (Zou *et al.*, 2004).

3.3.1.4 Precisão

A Precisão (Prec) avalia a confiabilidade das predições positivas, indicando a proporção de *pixels* rotulados como pertencentes à ROI que realmente correspondem à estrutura de referência. Sua formulação é dada pela Equação (3.26).

$$\text{Pre} = \frac{VP}{VP + FP} \quad (3.26)$$

Altos valores de Precisão indicam que o modelo identifica corretamente as regiões de interesse, reduzindo a ocorrência de falsos positivos sobre áreas neutras. Essa métrica é relevante em aplicações que exigem alta confiabilidade na detecção, como inspeção de qualidade em imagens industriais, mapeamento de áreas biológicas ou análise de padrões geométricos em dados sintéticos. Em uma situação clínica, por exemplo, alta Precisão indica que as regiões marcadas como lesão correspondem de fato à área patológica, minimizando a inclusão de áreas de pele saudável. A Precisão, no entanto, deve ser interpretada juntamente com a Sensibilidade, já que um modelo pode apresentar alta Precisão ao segmentar apenas as regiões mais evidentes, ignorando partes menos contrastantes. A combinação dessas duas métricas revela o equilíbrio entre seletividade e abrangência da segmentação, fatores essenciais para avaliar o desempenho global do método (Litjens *et al.*, 2017).

3.3.1.5 Coeficiente de Correlação de Matthews (MCC)

O MCC é uma métrica abrangente que combina os quatro elementos da matriz de confusão em um único indicador equilibrado. Sua formulação é apresentada na Equação (3.27).

$$\text{MCC} = \frac{(VP \cdot VN) - (FP \cdot FN)}{\sqrt{(VP + FP)(VP + FN)(VN + FP)(VN + FN)}} \quad (3.27)$$

O MCC varia no intervalo $[-1, 1]$, em que valores próximos de 1 indicam concordância perfeita entre predição e referência, valores próximos de 0 representam desempenho aleatório e valores negativos apontam correlação inversa. Diferentemente da Acurácia, o MCC leva em consideração o impacto de todas as categorias, sendo menos sensível ao desbalanceamento entre classes. Essa propriedade o torna especialmente adequado para avaliar o desempenho do SEMAC, que combina inferência semântica e refinamento geométrico em diferentes condições visuais e estruturais.

Altos valores de MCC indicam que o modelo mantém equilíbrio entre detecção, rejeição e consistência morfológica, refletindo de forma compacta o desempenho global do sistema em contextos variados. Isso inclui, por exemplo, a identificação de anomalias em tecidos, o reconhecimento de falhas em materiais ou a segmentação de padrões sintéticos com topologia

complexa (Chicco; Jurman, 2020). Para fins de apresentação dos resultados, todos os valores de MCC foram convertidos para a escala percentual ($100 \times \text{MCC}$), de modo que os resultados são expressos em %. Assim, valores próximos de 100% correspondem a desempenho excelente.

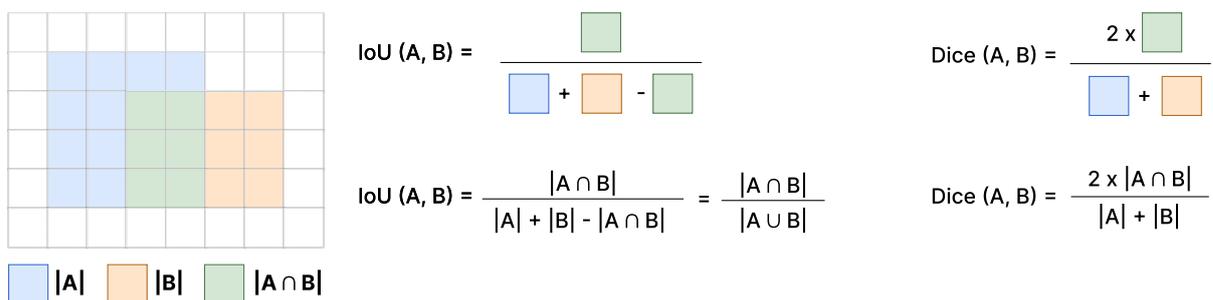
3.3.2 Métricas Baseadas em Similaridade

As métricas baseadas em similaridade quantificam o grau de correspondência espacial entre a segmentação predita e a de referência, avaliando tanto a proporção de acertos quanto a fidelidade geométrica das fronteiras. Tais medidas são particularmente adequadas ao SEMAC, cuja formulação combina inferência semântica e refinamento geométrico por contornos ativos. Ambas as etapas dependem diretamente da Precisão posicional e da coerência morfológica das regiões segmentadas.

Entre as principais métricas empregadas destacam-se o Índice de Jaccard (IoU) e o Coeficiente de Similaridade de Dice (Dice), amplamente utilizados em segmentação por mensurarem o grau de sobreposição entre as regiões de interesse. Valores elevados desses indicadores refletem alta concordância entre predição e referência, demonstrando a capacidade do modelo em preservar a forma e a coerência estrutural das regiões segmentadas.

A Figura 18 apresenta uma representação conceitual dessas métricas, em que a interseção entre as regiões A (padrão-ouro) e B (predição) define o grau de similaridade obtido.

Figura 18 – Representação esquemática das métricas de similaridade Dice e IoU, que avaliam a sobreposição entre as regiões A (padrão-ouro) e B (predição).



Fonte: Elaborado pelo autor.

3.3.2.1 Índice de Jaccard

O Índice de Jaccard, também conhecido como *Intersection over Union* (IoU), é amplamente empregado para quantificar a similaridade entre a segmentação predita e a máscara

de referência (GT). Essa métrica mede a razão entre a interseção e a união das duas regiões, conforme mostrado na Equação (3.28).

$$J(A,B) = \frac{|A \cap B|}{|A \cup B|} \quad (3.28)$$

No contexto da matriz de confusão binária, o cálculo pode ser expresso conforme a Equação (3.29).

$$\text{IoU} = \frac{VP}{VP + FP + FN} \quad (3.29)$$

O IoU assume valores entre 0 e 1, sendo que valores próximos de 1 indicam elevada sobreposição entre a predição e o padrão-ouro, enquanto valores baixos refletem discrepâncias espaciais significativas. Essa métrica penaliza igualmente falsos positivos e falsos negativos, fornecendo uma avaliação equilibrada da qualidade da segmentação (Rahman; Wang, 2016).

Nos experimentos com lesões cutâneas, o IoU mede a capacidade do SEMAC em delinear com Precisão os contornos irregulares das lesões, reproduzindo suas bordas reais sem invadir áreas saudáveis. Nas amostras de células sanguíneas, essa métrica quantifica o grau de concordância entre os limites previstos e os traçados manuais, sendo especialmente útil para verificar a separação adequada entre células em regiões de contato. Assim, o IoU fornece uma medida robusta da fidelidade geométrica e da consistência espacial do método proposto em diferentes condições visuais e morfológicas.

3.3.2.2 Coeficiente de Similaridade de Dice

O Coeficiente de Sørensen–Dice (Dice) é uma métrica amplamente utilizada para quantificar a correspondência espacial entre duas regiões segmentadas. Diferentemente de medidas baseadas apenas em acerto percentual, o Dice enfatiza a área de sobreposição entre predição e referência, atribuindo peso duplo à interseção das regiões. Sua formulação geral é apresentada na Equação (3.30).

$$\text{Dice} = \frac{2|A \cap B|}{|A| + |B|} \quad (3.30)$$

Nessa expressão, A representa a região de referência (ou padrão-ouro) e B corresponde à predição. O termo $|A \cap B|$ indica a quantidade de *pixels* corretamente sobrepostos entre

as duas máscaras, enquanto $|A|$ e $|B|$ representam suas áreas totais. O fator 2 no numerador garante que a interseção tenha peso proporcional à soma das áreas, tornando a métrica mais sensível a pequenas discrepâncias de contorno.

A Equação (3.30) pode ser reescrita em termos da matriz de confusão binária, considerando Verdadeiros Positivos (VP), Falsos Positivos (FP) e Falsos Negativos (FN), conforme a Equação (3.31).

$$\text{Dice} = \frac{2 \cdot VP}{2 \cdot VP + FP + FN} \quad (3.31)$$

Os valores do Dice variam entre 0 e 1, onde 0 indica ausência total de sobreposição e 1 representa correspondência perfeita entre predição e referência. Por atribuir maior peso à interseção, tende a gerar valores ligeiramente superiores aos do IoU, embora ambas as métricas apresentem comportamentos semelhantes (Dice, 1945; Zou *et al.*, 2004). Essa característica o torna especialmente útil em aplicações nas quais pequenas variações de fronteira influenciam significativamente a qualidade da segmentação.

Na prática, o Dice avalia a capacidade do SEMAC de preservar a forma e o tamanho das regiões de interesse, mantendo a coerência morfológica e o alinhamento geométrico das fronteiras. É eficaz em cenários com contornos irregulares, alta densidade de objetos ou oclusões parciais — por exemplo, na análise de lesões cutâneas, na segmentação de células sanguíneas ou em tarefas industriais de detecção de falhas em superfícies complexas.

Por equilibrar de maneira eficiente os efeitos de falsos positivos e falsos negativos, o Dice permanece como uma das métricas mais relevantes para avaliação de segmentação em diferentes domínios, sendo amplamente adotado como referência para comparação entre métodos.

3.4 Procedimentos de Treinamento

O processo de treinamento do SEMAC foi conduzido de forma supervisionada, visando o aprendizado do campo de evidência semântico $E_{\theta}(x)$ conforme o funcional definido na Equação (3.5). O objetivo foi ajustar os parâmetros θ e ϕ de modo a equilibrar fidelidade global e coerência local, assegurando que o campo de evidência represente adequadamente as estruturas morfológicas das regiões de interesse e forneça gradientes contextuais consistentes para a evolução dos contornos ativos.

As imagens foram normalizadas para o intervalo $[-1, 1]$ e redimensionadas para 512×512 *pixels*. As máscaras binárias foram redimensionadas com interpolação *nearest* e normalizadas em $[0, 1]$. Aplicaram-se rotações aleatórias de até $\pm 10^\circ$, espelhamentos horizontais e variações sutis de brilho e contraste, assegurando robustez a perturbações fotométricas e geométricas.

A minimização do funcional $\mathcal{L}(\theta, \phi)$ foi realizada por descida de gradiente estocástica com otimizador adaptativo e taxa de aprendizado inicial de 10^{-3} , decaimento exponencial de 5×10^{-4} e tamanho de lote $B = 8$. O processo foi executado por até 200 épocas, com parada antecipada baseada na métrica Dice do conjunto de validação, interrompendo o treinamento quando a variação média foi inferior a 10^{-4} durante 40 épocas consecutivas. Durante o treinamento, foram monitoradas as métricas Acurácia, Precisão, Sensibilidade, Especificidade, IoU, Dice e MCC. O modelo final adotado foi aquele que apresentou o maior valor médio de Dice na validação. Após a convergência, o campo $E_\theta(x)$ foi suavizado por convolução gaussiana para obtenção de $E_\sigma(x)$, utilizado como energia externa na evolução dos contornos descrita na Seção 3.1.2.

A Tabela 2 apresenta a distribuição média das amostras obtida após o particionamento estratificado, considerando os três conjuntos avaliados: (i) o conjunto sintético, construído em ambiente controlado; (ii) o conjunto dermatoscópico, referente ao ISIC 2018; e (iii) o conjunto microscópico de células sanguíneas (BBBC041Seg).

Tabela 2 – Distribuição das imagens entre treino, validação e teste para cada conjunto de dados.

Conjunto de Dados	Total	Treino	Validação	Teste
Sintético	1 200	840	120	240
Lesões cutâneas	3 694	2 594	100	1 000
Células Sanguíneas	1 328	930	132	266

Fonte: Elaborado pelo autor.

Os experimentos foram executados em ambiente de nuvem Google Colab, utilizando GPU NVIDIA A100 com 40 GB de memória dedicada, 83 GB de RAM e suporte CUDA/cuDNN integrado ao TensorFlow 2.x. A escolha dessa configuração ocorreu por conveniência de execução, não sendo requisito específico para o funcionamento ou reprodutibilidade do SEMAC.

4 RESULTADOS E DISCUSSÕES

Este capítulo apresenta e discute os resultados obtidos com a aplicação do SEMAC em dois contextos experimentais complementares: o cenário especialista, baseado em um conjunto sintético desenvolvido para avaliar o comportamento do modelo sob condições controladas, e o cenário generalista, composto por imagens clínicas dermatológicas e citológicas utilizadas para testar sua capacidade de generalização em contextos reais e heterogêneos.

Em ambos os cenários foram realizadas análises quantitativas e qualitativas. As métricas empregadas, como Acurácia, Sensibilidade, Precisão, Especificidade, MCC, IoU e Dice, mensuraram o desempenho do SEMAC quanto à fidelidade das fronteiras e à consistência das regiões segmentadas. As análises qualitativas complementaram essa avaliação ao evidenciar o comportamento evolutivo, a coerência morfológica e a estabilidade da segmentação diante de variações estruturais e fotométricas.

As próximas seções apresentam os resultados obtidos em cada cenário: a Seção 4.1 descreve os experimentos conduzidos em condições controladas com imagens sintéticas, enquanto a Seção 4.2 aborda os resultados sobre imagens clínicas reais. Por fim, a Seção 4.3 discute de forma integrada como a formulação energética, o campo de evidência semântica e a dinâmica multicontorno influenciam o desempenho global e a estabilidade evolutiva do SEMAC.

4.1 Cenário Especialista

O cenário especialista foi empregado para examinar o comportamento do SEMAC em condições controladas, permitindo observar seu desempenho diante de variações progressivas de complexidade geométrica e fotométrica. As imagens sintéticas utilizadas abrangem diferentes configurações de bordas lineares, irregulares e de alta densidade, avaliadas tanto em condições ideais quanto com a presença de ruído e modificações na imagem.

Essa etapa experimental permitiu verificar a estabilidade numérica, a precisão geométrica e a coerência topológica do método frente a perturbações artificiais. As variações planejadas no conjunto de teste favoreceram a análise da interação entre as forças internas de suavização e as forças externas guiadas pelo campo de evidência semântica, destacando a capacidade do método em ajustar-se a diferentes relevos energéticos sem perda de continuidade morfológica.

As subseções a seguir apresentam os resultados quantitativos e qualitativos obtidos nesse cenário, evidenciando o comportamento progressivo do modelo à medida que as condições

sintéticas se tornam mais complexas e desafiadoras.

4.1.1 Resultados Quantitativos

As avaliações quantitativas do SEMAC sobre o conjunto sintético foram conduzidas em seis condições experimentais que combinam variações geométricas e fotométricas. Essas condições, descritas na Tabela 1, abrangem diferentes arranjos de formas, graus de irregularidade de bordas, densidade de objetos e presença de modificações fotométricas na imagem.

Os resultados correspondentes estão apresentados nas Tabelas 3 e 4, que reúnem as médias e os desvios padrão das métricas de segmentação Acurácia, Sensibilidade, Precisão, Especificidade, MCC, IoU e Dice. Em conjunto, essas análises permitem avaliar a estabilidade geométrica, a fidelidade de fronteira e a resposta do método frente a perturbações controladas de forma, densidade e contraste.

Tabela 3 – Resultados médios e desvios padrão das métricas gerais e de correlação em dados sintéticos sob diferentes condições geométricas e fotométricas.

Condição	Acc (%)	Prec (%)	Sens (%)	Espec (%)	MCC (%)
Bordas ideais	99,95±0,03	99,85±0,03	99,80±0,04	99,97±0,02	99,82±0,03
Bordas ideais + Modificações na imagem	99,88±0,04	99,60±0,05	99,55±0,05	99,93±0,03	99,52±0,04
Bordas irregulares	99,55±0,05	99,10±0,06	99,20±0,06	99,70±0,05	99,05±0,06
Bordas irregulares + Modificações na imagem	99,10±0,06	98,70±0,07	98,85±0,07	99,30±0,06	98,65±0,07
Alta densidade de objetos	98,70±0,07	98,40±0,07	98,50±0,07	99,00±0,06	98,35±0,07
Alta densidade de objetos + Modificações na imagem	98,35±0,07	98,10±0,08	98,20±0,08	98,80±0,07	98,05±0,08

Fonte: Elaborado pelo autor.

Tabela 4 – Resultados médios e desvios padrão das métricas de similaridade em dados sintéticos sob diferentes condições geométricas e fotométricas.

Condição	Dice (%)	IoU (%)
Bordas ideais	99,80±0,03	99,45±0,04
Bordas ideais + Modificações na imagem	99,55±0,04	99,10±0,05
Bordas irregulares	99,10±0,05	98,70±0,06
Bordas irregulares + Modificações na imagem	98,75±0,06	98,30±0,06
Alta densidade de objetos	98,45±0,07	98,10±0,07
Alta densidade de objetos + Modificações na imagem	98,10±0,08	98,00±0,08

Fonte: Elaborado pelo autor.

Nas condições com bordas ideais, o método apresentou desempenho de altíssima precisão em todas as métricas, com desvios padrão inferiores a 0,05%. A Acurácia atingiu 99,95% e a Especificidade, 99,97%, evidenciando a elevada capacidade do método em distinguir

corretamente as regiões de interesse do fundo da imagem. Esses valores indicam que praticamente todos os *pixels* de fundo foram classificados corretamente como negativos, resultando em rejeição precisa do fundo e ocorrência mínima de falsos positivos. Tal comportamento confirma a eficácia das forças internas de suavização e do mecanismo de regularização geométrica do SEMAC, que impedem expansões indevidas dos contornos em áreas homogêneas, garantindo estabilidade mesmo sob discretizações finas.

Com a introdução de modificações fotométricas e ruído leve nas imagens ideais, o desempenho permaneceu acima de 99% em todas as métricas, com reduções médias inferiores a 0,5% em relação à condição anterior. Essa estabilidade evidencia a robustez da dinâmica dos contornos, na qual a regularização interna preserva a coerência estrutural mesmo sob pequenas perturbações externas.

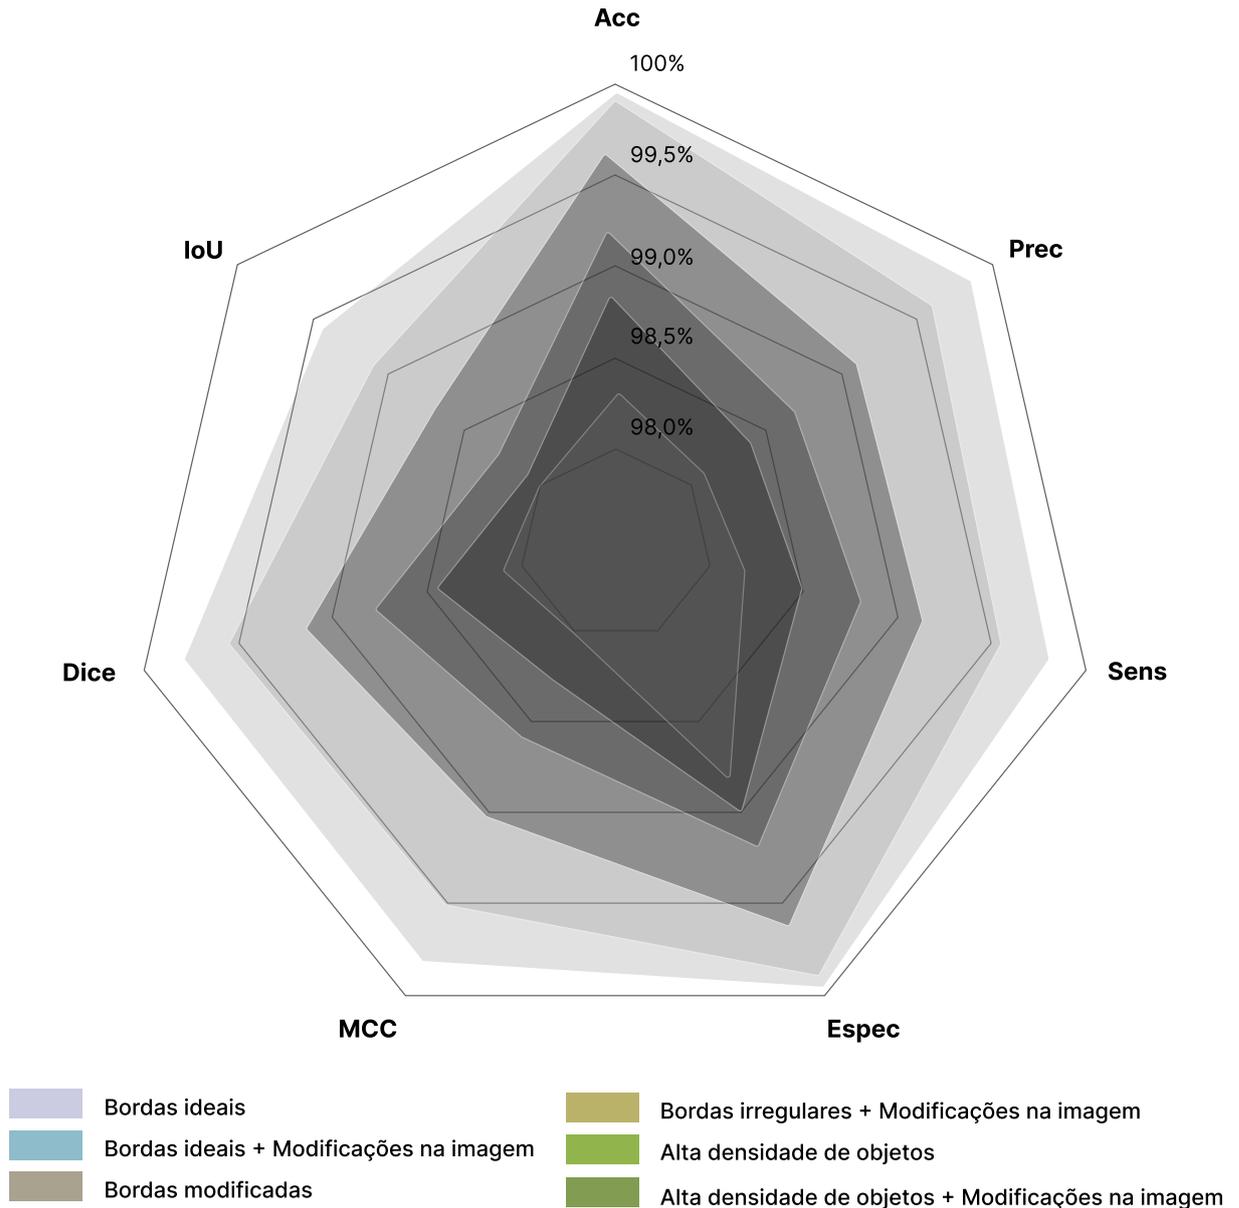
Nos cenários com bordas irregulares, que introduzem deformações locais e irregularidades geométricas, o SEMAC manteve desempenho elevado, com Dice de 99,0% e IoU de 98,7%. A discreta redução em relação ao caso ideal é compatível com o aumento da complexidade morfológica e reflete o comportamento esperado de um ACM estável, em que as forças internas amortecem as oscilações provocadas por gradientes externos irregulares. Mesmo sob perturbações fotométricas, o contorno ajusta sua trajetória de forma adaptativa, aderindo às bordas dominantes e descartando detalhes espúrios, o que explica a pequena variação (<1%) nas métricas de similaridade. Esses resultados indicam que o método proposto mantém o equilíbrio energético entre regiões vizinhas, assegurando coerência geométrica e estabilidade multirregional mesmo sob ruído local ou descontinuidades.

Nas condições de alta densidade de objetos, o SEMAC demonstrou capacidade discriminativa consistente, mesmo quando as instâncias estavam separadas por margens estreitas ou apresentavam sobreposições parciais. Essa performance decorre da formulação multirregional do método, na qual múltiplos contornos evoluem simultaneamente sobre um campo energético compartilhado. Essa estrutura promove interação indireta entre fronteiras, de modo que a aproximação de uma curva influencia o gradiente local percebido pelas demais, evitando fusões indevidas e preservando a integridade topológica das regiões. A ação combinada das forças internas e da energia externa aprendida garante separabilidade morfológica e continuidade espacial, mantendo Dice e IoU próximos de 98% mesmo sob sobreposição parcial ou interferência de gradientes.

A Figura 19 apresenta a distribuição conjunta das métricas de segmentação nos

seis cenários sintéticos avaliados. O gráfico radar permite observar, de forma integrada, o equilíbrio entre as diferentes métricas de desempenho, sendo que cada eixo representa uma métrica normalizada em relação ao valor máximo obtido. Assim, quanto mais regular e expandido for o polígono formado, maior é a uniformidade e a robustez do método nos distintos aspectos de avaliação.

Figura 19 – Distribuição conjunta das métricas de segmentação nos seis cenários sintéticos avaliados.



Fonte: Elaborado pelo autor.

Observa-se que o SEMAC mantém desempenho consistente e equilibrado em todos os eixos, com valores superiores a 98% em todas as métricas. Nos cenários com bordas ideais e irregulares, o radar exibe uma forma hexagonal quase regular e próxima ao limite

máximo, evidenciando uniformidade de desempenho e estabilidade numérica durante a evolução dos contornos. Esse comportamento confirma que o SEMAC preserva coerência estrutural e fidelidade de fronteira mesmo em condições regulares ou levemente irregulares, mantendo variações inferiores a 1% entre os eixos avaliados.

Com o aumento da complexidade geométrica e fotométrica, especialmente nos cenários de alta densidade de objetos e presença de ruído, observa-se uma leve contração do polígono, concentrada na métricas IoU. Essa tendência é comum em tarefas de segmentação com múltiplas instâncias adjacentes, nas quais pequenas imprecisões de fronteira reduzem o valor dessas métricas. Ainda assim, o SEMAC atenua esse efeito graças à sua formulação multirregional, que preserva a separabilidade entre curvas e evita fusões indevidas mesmo sob alta densidade ou interferência local. Como resultado, as reduções permanecem inferiores a 2%, demonstrando consistência geométrica e estabilidade energética mesmo sob sobreposição parcial e ruído.

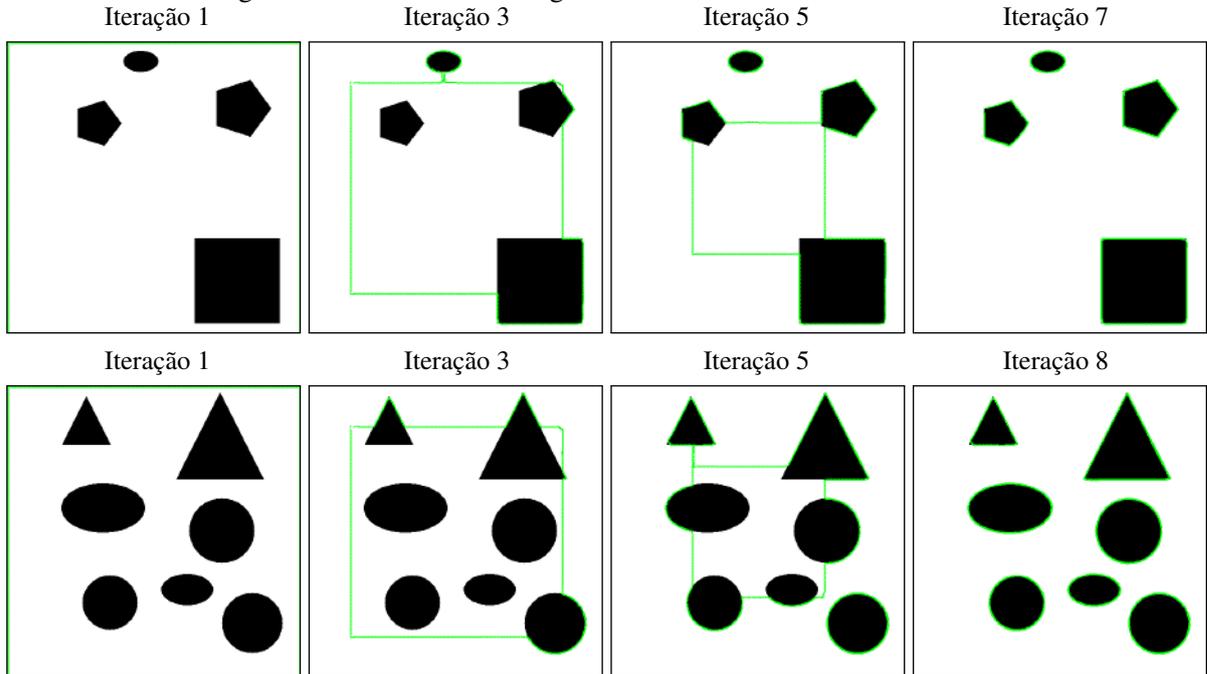
De modo geral, a análise dos seis conjuntos sintéticos demonstra que o SEMAC mantém alta precisão e coerência morfológica em diferentes condições geométricas e fotométricas. As forças internas garantem suavidade e continuidade dos contornos, enquanto a energia externa derivada do campo de evidência fornece orientação contextual que guia a curva para as fronteiras estruturalmente mais relevantes. Essa integração entre a formulação clássica e a informação semântica resulta em segmentações robustas, estáveis e morfológicamente consistentes, com variação global inferior a 2,0% entre o cenário ideal e o mais complexo.

4.1.2 Resultados Qualitativos

A análise qualitativa das segmentações em dados sintéticos tem como objetivo complementar as avaliações quantitativas apresentadas na Subseção 4.1.1, oferecendo uma visão mais detalhada e visual sobre o comportamento evolutivo dos contornos e a dinâmica de equilíbrio das forças internas e externas. Por meio das ilustrações a seguir, é possível observar a forma como o SEMAC responde a diferentes condições geométricas e fotométricas, permitindo interpretar visualmente os efeitos de regularização, estabilização e adaptação morfológica ao longo do processo de evolução.

A Figura 20 ilustra a evolução do processo de segmentação em amostras com bordas regulares e fundo uniforme, enquanto a Figura 21 apresenta resultados em amostras irregulares artificialmente, simulando variações estruturais e ruídos locais. Nas duas situações, observa-

Figura 20 – Evolução dos contornos ativos em dados sintéticos com bordas regulares, mostrando amostras sem modificações artificiais. As curvas verdes indicam o contorno evolutivo em diferentes iterações, evidenciando convergência estável e coerência geométrica.



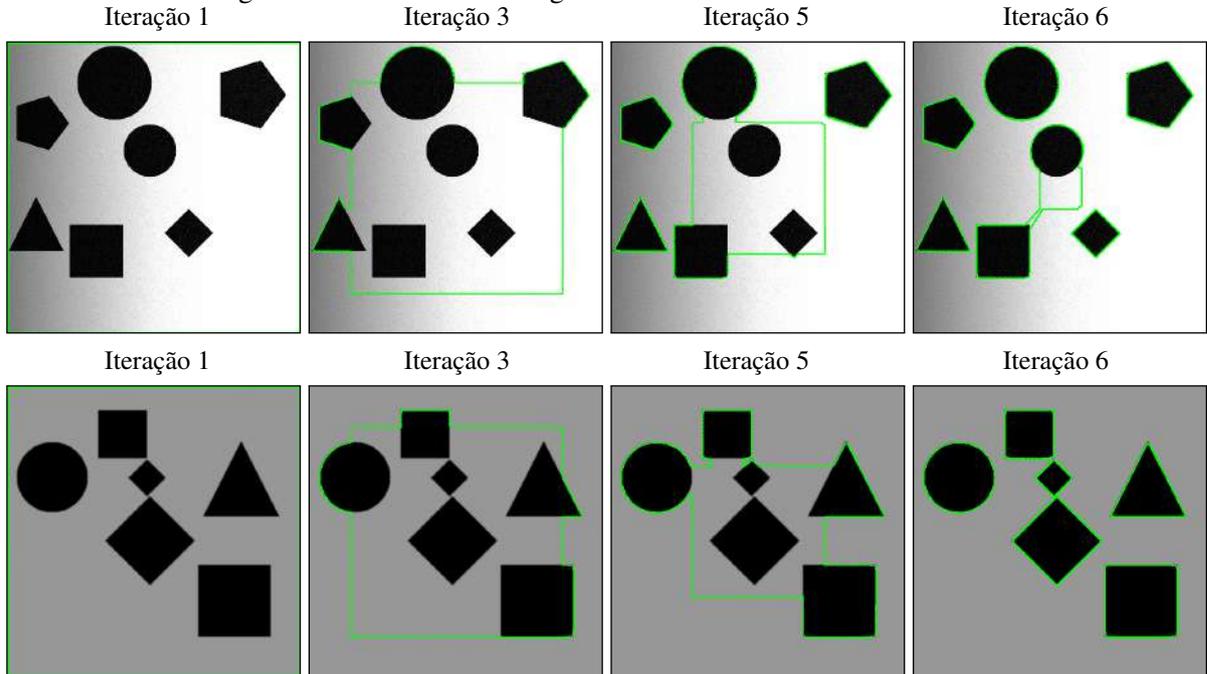
Fonte: Elaborado pelo autor.

se que as curvas verdes representam as posições sucessivas do contorno ativo ao longo das iterações, evidenciando o processo de contração progressiva até o equilíbrio energético. A convergência ocorre rapidamente nas primeiras etapas, com retração suave das curvas em direção às fronteiras dos objetos, demonstrando estabilidade e coerência geométrica mesmo sob pequenas perturbações. Os resultados visuais estão em conformidade com as métricas quantitativas, nas quais o desempenho manteve-se alto, confirmando a consistência da energia formulada sob diferentes condições sintéticas.

As Figuras 22 e 23 apresentam exemplos com bordas degradadas e perturbações fotométricas. Mesmo diante dessas irregularidades, o contorno mantém a direção dominante do gradiente e converge para mínimos locais compatíveis com as bordas reais, evitando vazamentos ou desvios para áreas externas, mesmo quando o brilho do fundo se aproxima do interior do objeto. Em regiões com concavidades mais acentuadas, observa-se um ajuste gradual da curva por etapas sucessivas, até o fechamento completo das reentrâncias, sem perda de continuidade ou coerência geométrica.

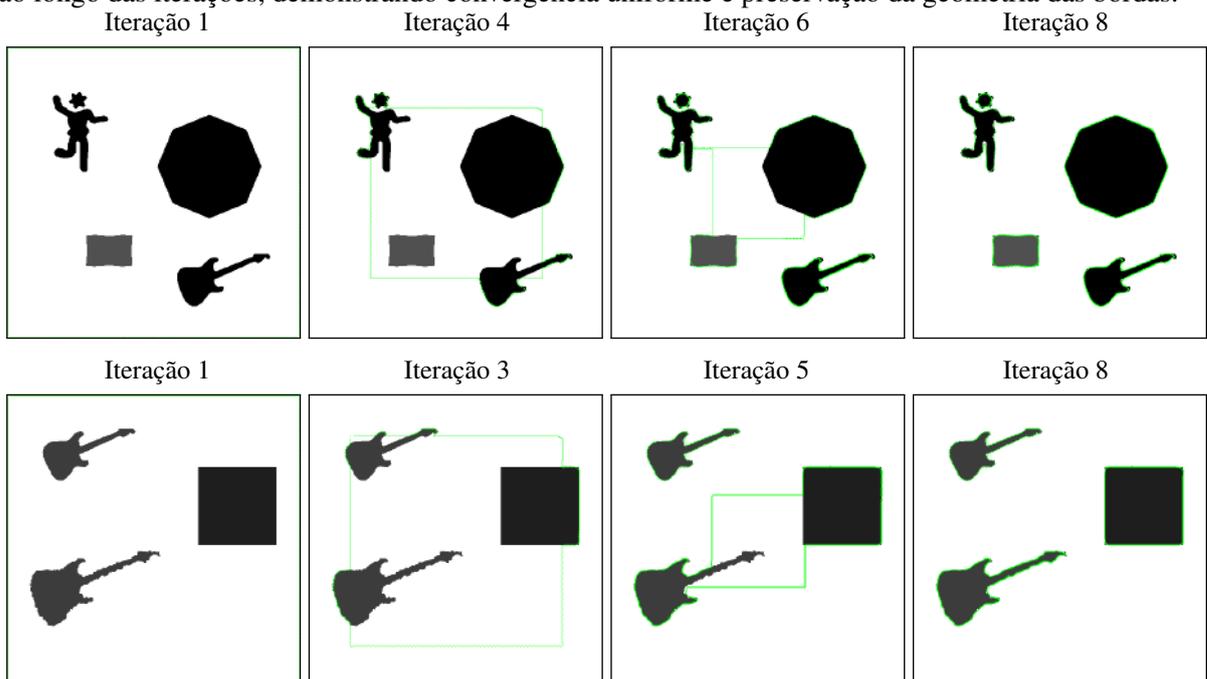
Essa dinâmica explica o discreto aumento de variabilidade nas métricas de Sensibilidade e IoU, enquanto a Acurácia e o MCC permanecem elevadas, refletindo a baixa incidência de falsos positivos e a estabilidade geral da segmentação.

Figura 21 – Evolução dos contornos ativos em dados sintéticos com bordas regulares, mostrando amostras com modificações artificiais. As curvas verdes indicam o contorno evolutivo em diferentes iterações, evidenciando convergência estável e coerência geométrica.



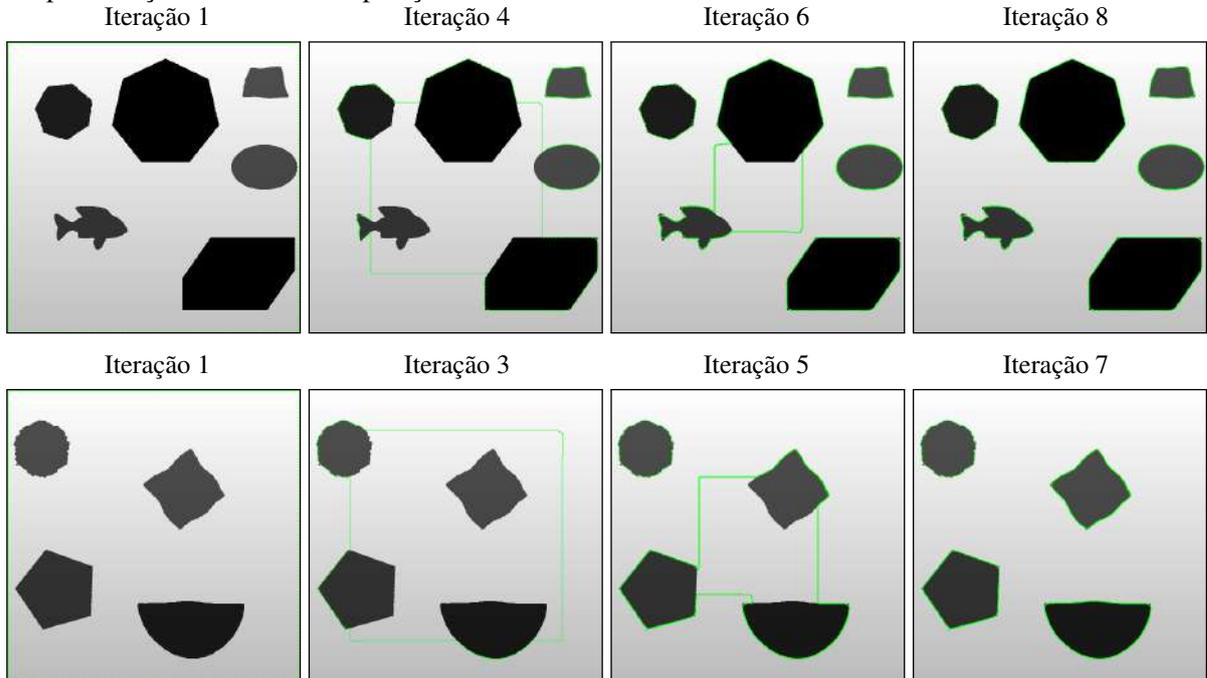
Fonte: Elaborado pelo autor.

Figura 22 – Evolução do processo de segmentação em dados sintéticos com bordas irregulares. As amostras exibem condições sem modificações artificiais. As curvas verdes representam o contorno ativo ao longo das iterações, demonstrando convergência uniforme e preservação da geometria das bordas.



Fonte: Elaborado pelo autor.

Figura 23 – Evolução do processo de segmentação em dados sintéticos com bordas irregulares e modificações artificiais. Observa-se a capacidade do método em manter estabilidade e coerência mesmo sob perturbações locais e sobreposição de fronteiras.



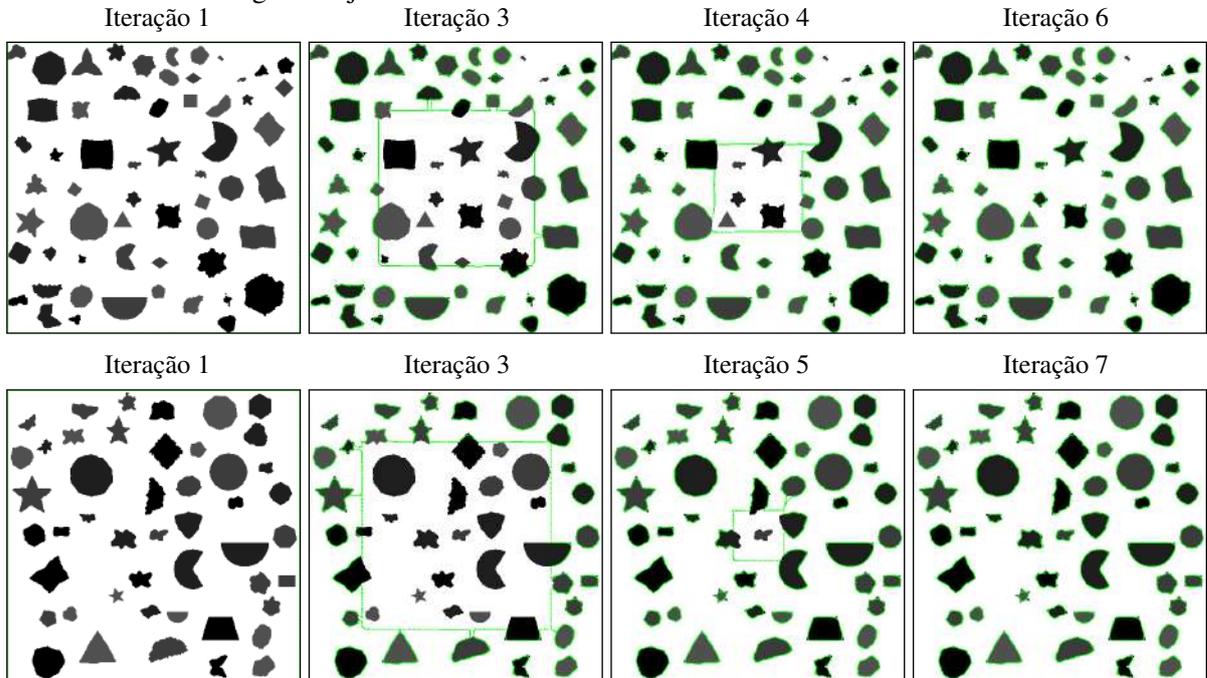
Fonte: Elaborado pelo autor.

A Figura 24 demonstra o comportamento do SEMAC em condições de alta densidade de objetos, compostas por múltiplas instâncias próximas. O contorno evolutivo preserva as fronteiras de separação mesmo quando a distância entre objetos é reduzida e os gradientes se interferem mutuamente. Em regiões de aglomeração com gargalos estreitos, observa-se que a curva aproxima-se simultaneamente de duas bordas e realiza o descolamento apenas após o aumento local do contraste, evitando fusões indesejadas. Nas áreas em que a textura de fundo introduz ruído pontual, o contorno mantém trajetória estável e suprime variações isoladas, indicando que a energia externa penaliza deslocamentos sem suporte espacial consistente.

As Figuras 26, 27 e 28 apresentam amostras representativas do conjunto sintético, ilustrando a correspondência entre as segmentações obtidas pelo SEMAC e o respectivo padrão-ouro. Para cada caso, são exibidas: (i) a imagem original, (ii) o GT, (iii) a segmentação predita e (iv) a sobreposição entre GT e predição, evidenciando o grau de coincidência entre as regiões segmentadas.

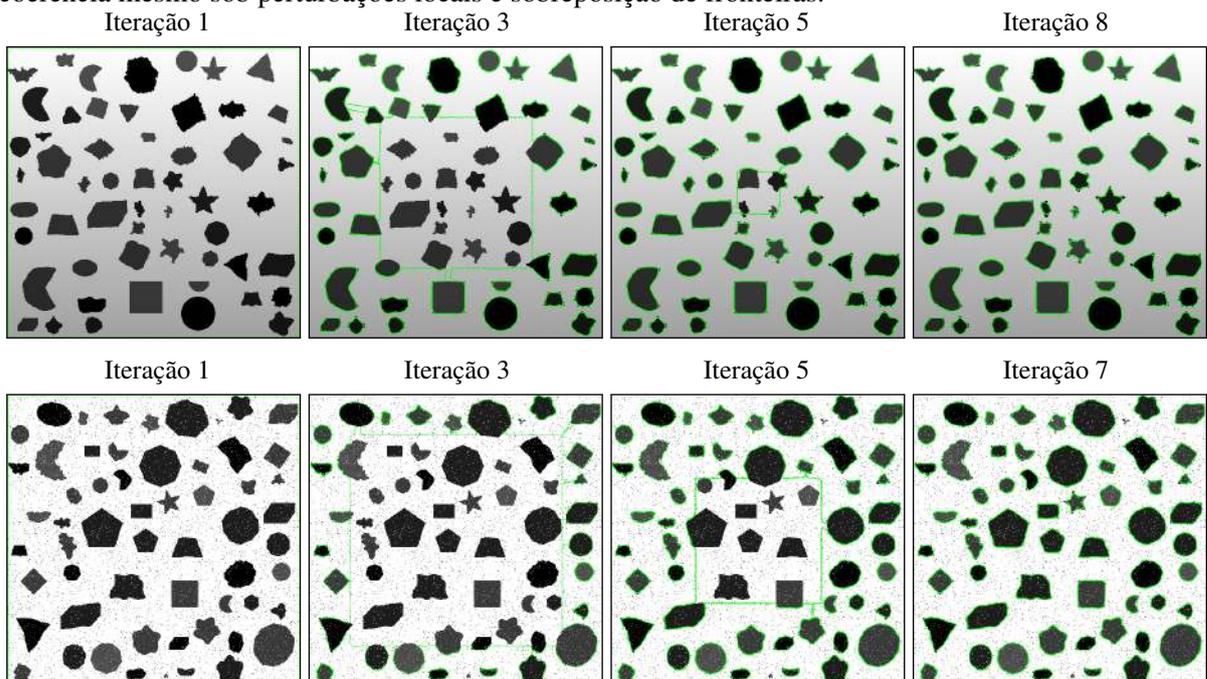
Na Figura 26, referente ao cenário de bordas regulares, observa-se uma sobreposição praticamente completa entre as regiões de GT e as predições. As formas geométricas são reproduzidas com alta fidelidade, sem ocorrência de falsos positivos ou vazamentos nas fronteiras. O resultado reforça a estabilidade do SEMAC em condições ideais, nas quais as transições de

Figura 24 – Evolução dos contornos ativos em dados sintéticos com alta densidade de objetos. As curvas verdes representam o contorno evolutivo ao longo das iterações, evidenciando estabilidade e preservação das fronteiras entre regiões adjacentes.



Fonte: Elaborado pelo autor.

Figura 25 – Evolução dos contornos ativos em dados sintéticos com alta densidade de objetos e modificações artificiais na imagem. Observa-se a capacidade do método em manter estabilidade e coerência mesmo sob perturbações locais e sobreposição de fronteiras.



Fonte: Elaborado pelo autor.

intensidade são abruptas e bem definidas. Essa precisão visual está em plena concordância com as métricas quantitativas superiores a 99% apresentadas na Subseção 4.1.1.

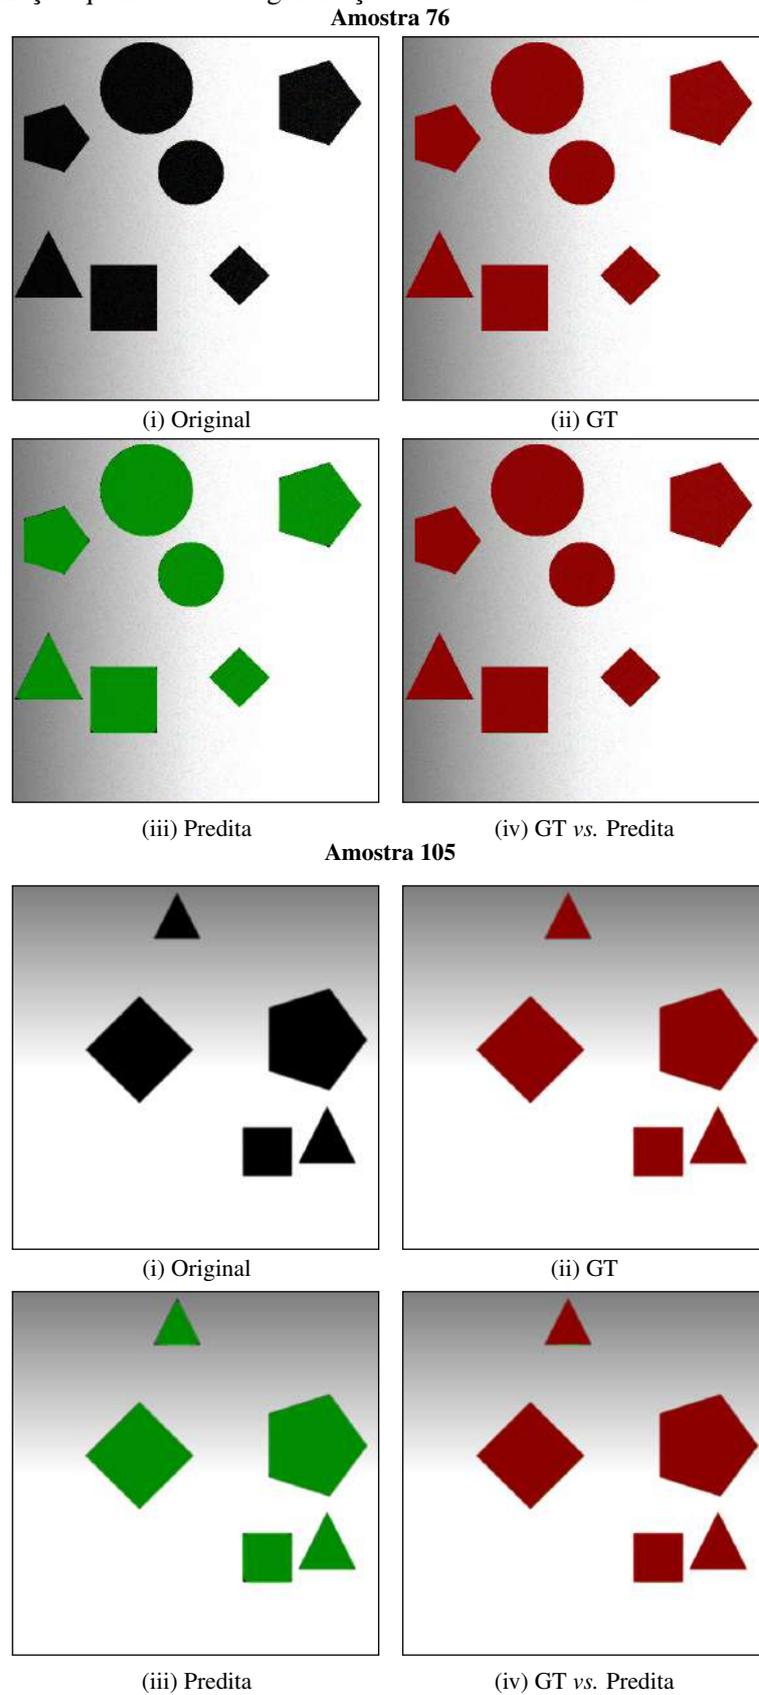
A Figura 27 apresenta amostras com bordas deterioradas e ruído fotométrico. Mesmo diante de variações de contraste e gradientes de iluminação, o método preserva a coerência morfológica e a correspondência espacial entre as regiões segmentadas e o padrão-ouro. Observa-se, em particular, que na primeira amostra da Figura 27 o corpo e a cabeça do boneco, posicionados em proximidade extrema, são corretamente identificados como objetos distintos, em conformidade com a referência. Esse comportamento confirma a capacidade do SEMAC em lidar com situações de contato entre estruturas, aspecto essencial em contextos biomédicos com células. Além disso, nas demais formas, as bordas exibem leve suavização sem perda geométrica, demonstrando que o campo energético se adapta às variações locais de intensidade sem comprometer a integridade das regiões segmentadas.

Na Figura 28, correspondente ao cenário de alta densidade de objetos, o SEMAC mantém desempenho consistente mesmo sob sobreposição parcial e interferência mútua entre gradientes. A sobreposição entre GT e predição evidencia coincidência quase integral nas regiões internas, com pequenas divergências apenas em zonas de contato muito estreito, onde ocorre subsegmentação discreta. Ainda assim, as fronteiras permanecem bem definidas, e o método preserva a separação entre instâncias adjacentes, aspecto particularmente notável diante do elevado número de objetos e do ruído visual adicionado. Visualmente, observa-se que o SEMAC reproduz adequadamente tanto as formas regulares quanto as irregulares, mantendo proporção, área e continuidade geométrica compatíveis com o padrão-ouro.

O SEMAC demonstrou quatro propriedades qualitativas essenciais sob condições regulares e perturbadas: (i) estabilidade inicial com rápida aderência às bordas em cenários regulares, alcançando convergência em poucas iterações; (ii) robustez frente a gradientes fotométricos suaves, com correção progressiva de oscilações intermediárias até atingir mínimos locais coerentes com as bordas reais; (iii) resistência a vazamentos em regiões de baixo contraste e ruído pontual, refletida na manutenção de alta precisão e especificidade; e (iv) preservação da separação entre objetos adjacentes em contextos de alta densidade, realizando ajustes finos que evitam fusões indevidas e asseguram coerência morfológica. Essas propriedades explicam as pequenas reduções observadas nas métricas de sobreposição sob perturbações moderadas.

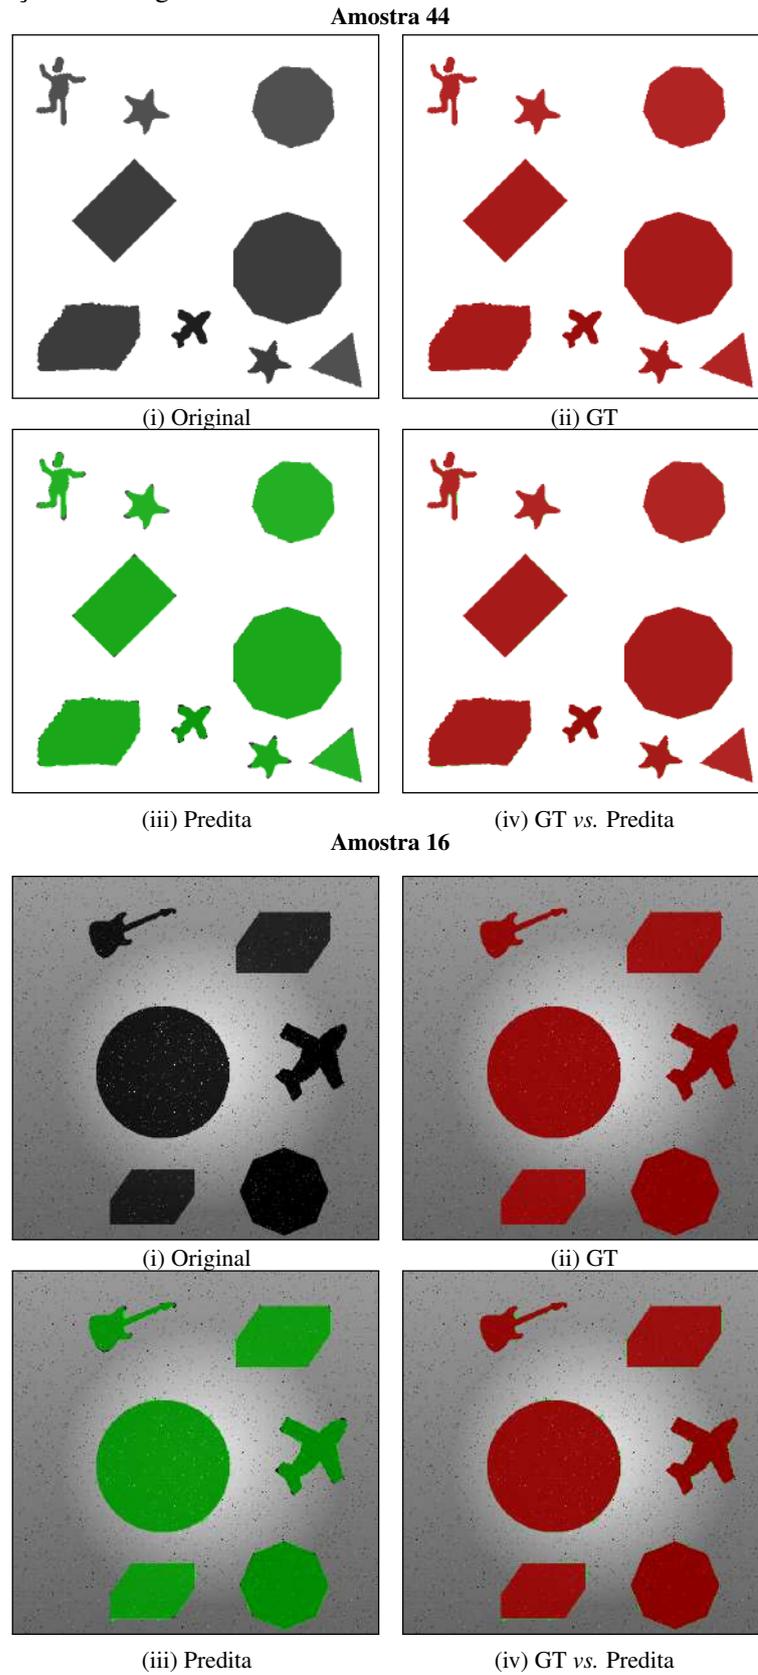
As evidências visuais complementam as análises quantitativas e confirmam que o processo de minimização de energia permanece estável e eficaz diante de variações controladas

Figura 26 – Visualização qualitativa da segmentação em duas amostras sintéticas.



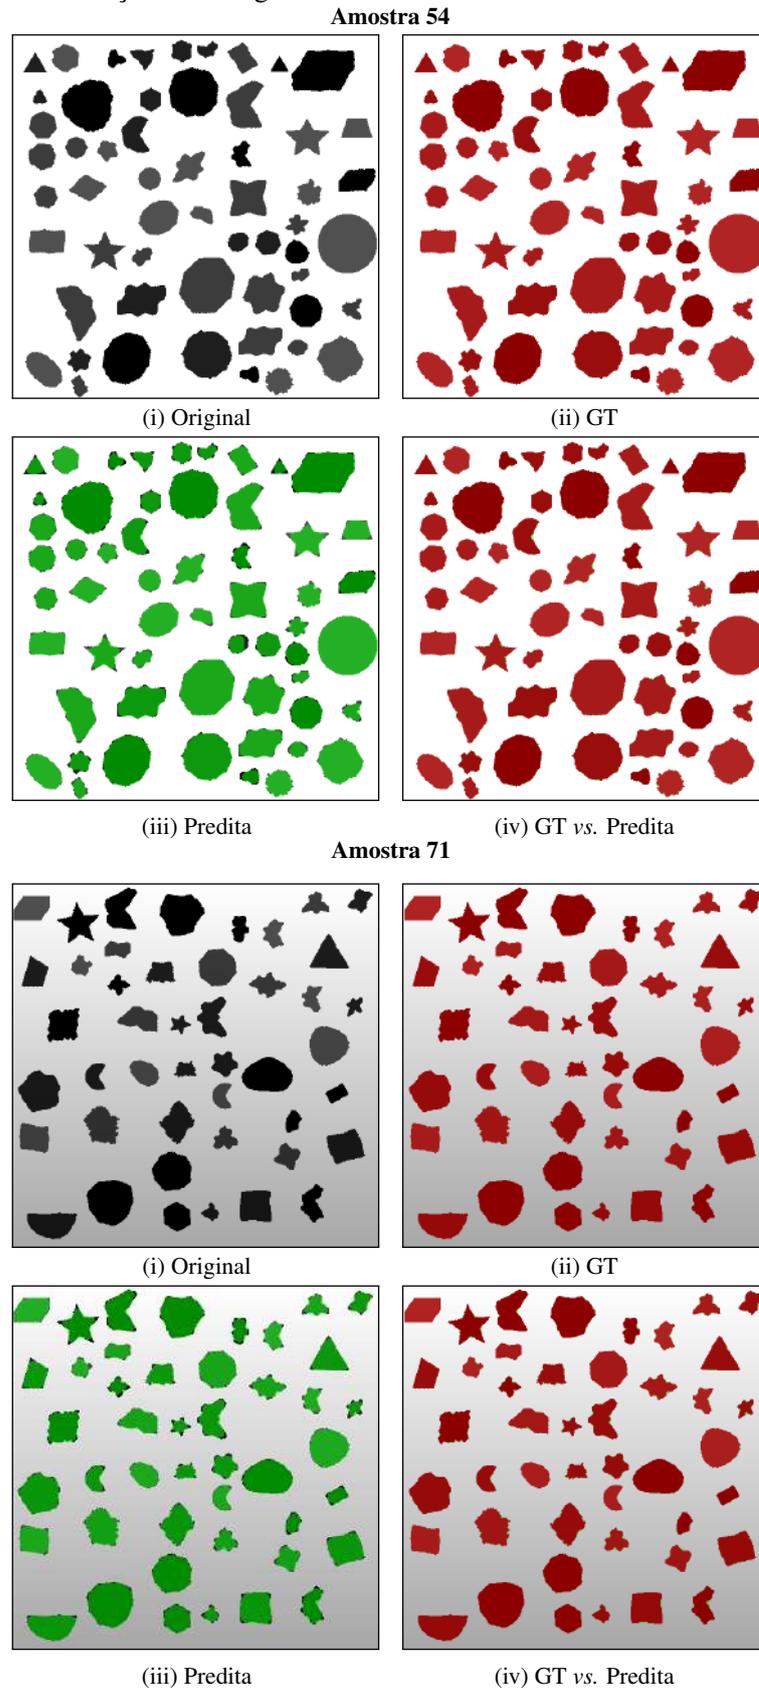
Fonte: Elaborado pelo autor.

Figura 27 – Visualização qualitativa da segmentação em duas amostras sintéticas com bordas irregulares, com e sem modificações na imagem.



Fonte: Elaborado pelo autor.

Figura 28 – Visualização qualitativa da segmentação em duas amostras sintéticas com alta densidade de objetos, com e sem modificações na imagem.



Fonte: Elaborado pelo autor.

de geometria, textura e iluminação. O método mantém a coerência estrutural das segmentações e apresenta correspondência espacial consistente com o padrão-ouro, indicando bom potencial de generalização para imagens biomédicas reais, mesmo na presença de formas irregulares, gradientes de iluminação ou ruído de aquisição.

De forma integrada, os resultados do conjunto sintético demonstram que o SEMAC apresenta comportamento estável e coerente do ponto de vista energético em ambientes controlados. A análise conjunta das Figuras 20 a 28, aliada às métricas quantitativas, evidencia a capacidade do método de preservar a integridade geométrica e topológica das regiões de interesse mesmo sob perturbações moderadas.

Esses achados consolidam a etapa de validação inicial do método, estabelecendo um referencial de desempenho sob condições ideais e semi-perturbadas. Essa base experimental confirma a eficiência do mecanismo de minimização de energia e fornece sustentação teórica e empírica para sua aplicação em imagens biomédicas reais, nas quais as variações de textura, contraste e artefatos de aquisição impõem desafios substancialmente maiores à convergência e à estabilidade do processo de segmentação.

4.2 Cenário Generalista

Concluída a etapa de validação em condições controladas, esta seção apresenta a aplicação do SEMAC em imagens reais, provenientes de diferentes domínios biomédicos. O objetivo é avaliar sua capacidade de generalização diante de variações naturais de textura, contraste e presença de artefatos, aspectos que tornam a segmentação mais desafiadora em contextos experimentais e clínicos.

As subseções seguintes abordam separadamente dois conjuntos representativos: lesões cutâneas (Seção 4.2.1) e células sanguíneas (Seção 4.2.2). Em ambos os casos, são apresentadas análises quantitativas e qualitativas, com comparações frente a métodos de referência da literatura, a fim de verificar o desempenho e a adaptabilidade do SEMAC em domínios visualmente distintos.

4.2.1 Segmentação de lesões cutâneas

As lesões cutâneas constituem um dos desafios mais complexos da VC aplicada à área da saúde, em razão da ampla diversidade de formas, texturas e contrastes, além da presença

de artefatos de aquisição como pelos, reflexos e variações de iluminação. Essas características produzem bordas irregulares e transições sutis entre pele saudável e lesão, tornando a segmentação uma tarefa sensível a pequenas variações fotométricas e estruturais. O SEMAC, por sua formulação multirregião, permite delinear simultaneamente N regiões de interesse, incluindo o caso particular de uma única lesão ($N=1$), mantendo coerência geométrica e estabilidade durante o processo evolutivo.

4.2.1.1 Resultados Quantitativos

Sob essas condições adversas, o SEMAC preservou estabilidade evolutiva e boa aderência às fronteiras das lesões, evitando desvios em regiões de baixo gradiente ou bordas difusas, situações em que abordagens puramente clássicas ou redes neurais supervisionadas tendem a perder definição ou gerar sobresegmentações.

A Tabela 5 apresenta as métricas obtidas no conjunto ISIC 2018, comparadas a abordagens recentes da literatura. O SEMAC atingiu Acurácia de 95,90%, Sensibilidade de 94,20% e Especificidade de 96,40%, refletindo uma segmentação equilibrada, capaz de detectar adequadamente as regiões patológicas sem comprometer a preservação do fundo. A Precisão de 90,80% indica que a maioria dos pixels classificados como lesão corresponde efetivamente à área de interesse, enquanto o $MCC = 90,87\%$ confirma a correlação positiva entre predição e referência, mesmo sob variações de forma e textura. O SEMAC apresentou desempenho equilibrado, sem sacrificar sensibilidade em prol de especificidade ou vice-versa.

Tabela 5 – Resultados comparativos em métricas quantitativas para segmentação em imagens de pele.

Método	Referência	ACC (%)	Prec (%)	Sens (%)	Espec (%)	MCC (%)
SEMAC	Método proposto	95,90	90,80	94,20	96,40	90,87
GFANet	Qiu <i>et al.</i> (2023)	96,29	–	90,75	97,79	–
FAT-Net	Wu <i>et al.</i> (2022)	95,78	–	91,00	96,99	–
ADF-Net	Huang <i>et al.</i> (2024)	96,70	–	92,34	97,41	–
ASP-VMUNet	Bao <i>et al.</i> (2025)	93,83	–	89,97	95,33	–

Fonte: Elaborado pelo Autor.

Em termos quantitativos, o SEMAC apresenta desempenho competitivo em relação às arquiteturas baseadas em convoluções profundas e aos modelos híbridos com mecanismos de atenção. Embora apresente uma Acurácia ligeiramente inferior à ADF-Net (diferença de apenas 0,8%), o método proposto demonstra maior consistência global ($MCC = 90,87\%$), o que indica melhor equilíbrio entre verdadeiros positivos e negativos e menor propensão à sobresegmentação. Esse comportamento decorre da natureza controlada da evolução dos contornos, em que as

forças internas atuam como um mecanismo de regularização geométrica, impedindo a expansão indevida sobre regiões de fundo com gradiente ambíguo. Com isso, o SEMAC tende a formar fronteiras mais compactas e semanticamente coerentes, limitando o avanço dos contornos a áreas efetivamente suportadas pela evidência fotométrica e mantendo estabilidade mesmo em imagens com contraste difuso.

Entre os métodos comparativos, o GFANet (Qiu *et al.*, 2023) integra múltiplos níveis de atenção reversa para realçar bordas e suprimir ruído de fundo. Essa abordagem obtém elevada Especificidade (97,79%), indicando forte capacidade de rejeitar regiões não lesionadas, mas tende à subsegmentação em áreas de textura irregular. Isso ocorre porque o refinamento progressivo das bordas, embora eficaz em contornos nítidos, reduz a resposta em gradientes sutis, levando à omissão parcial de regiões com baixo contraste.

O FAT-Net (Wu *et al.*, 2022), por sua vez, combina convoluções e transformadores para capturar dependências de longo alcance, o que resulta em maior Sensibilidade (91,00%) e melhor cobertura da área lesionada. No entanto, esse ganho vem acompanhado de leve queda na Especificidade e aumento expressivo no custo computacional, devido à sobreposição de múltiplos módulos de atenção global.

A ADF-Net (Huang *et al.*, 2024) constitui uma evolução direta dessa linha de pesquisa, ao introduzir mecanismos de atenção focal adaptativa e fusão dual de características. Essa arquitetura alcança um equilíbrio consistente entre contexto local e global, aprimorando a distinção entre bordas e fundo. No entanto, sua eficiência depende fortemente do ajuste de hiperparâmetros e da disponibilidade de grandes conjuntos de dados rotulados, o que limita sua capacidade de generalização para domínios distintos.

Por fim, o ASP-VMUNet (Bao *et al.*, 2025) utiliza convoluções atours e o módulo Mamba para ampliar o campo receptivo sem perda de resolução espacial. Apesar disso, o SEMAC não reproduz o mesmo nível de desempenho global, sugerindo que a simples expansão da área de contexto não é suficiente para resolver ambiguidades topológicas ou inconsistências fotométricas nas bordas das lesões.

Em contraste com as abordagens anteriores aplicadas a esse mesmo conjunto de dados, o SEMAC adota uma formulação energética explícita, na qual a evolução dos contornos é guiada por um campo de evidência a partir dos dados. Essa estrutura combina aprendizado supervisionado profundo com princípios físicos de otimização, conferindo ao SEMAC maior interpretabilidade e estabilidade numérica, ao mesmo tempo em que reduz a dependência de

ajustes empíricos e mecanismos de atenção complexos. Enquanto as redes puramente neurais ajustam suas fronteiras com base em correlações estatísticas locais, o SEMAC realiza uma otimização física sobre o campo de evidência, modulando dinamicamente as forças de contração e expansão conforme a coerência morfológica das regiões. O resultado é uma segmentação mais regularizada e semanticamente consistente, capaz de preservar detalhes anatômicos relevantes sem comprometer o equilíbrio entre fidelidade geométrica e robustez numérica. Essas propriedades tornam o método particularmente adequado para aplicações biomédicas, nas quais a precisão de fronteira e a interpretabilidade do processo são tão importantes quanto o desempenho quantitativo.

A Tabela 6 apresenta as métricas de similaridade, que quantificam o grau de sobreposição entre as máscaras preditas e as de referência. O SEMAC alcançou IoU de 85,90% e Dice de 92,30%, com ganhos de 3,9% e 3,3% em relação ao FAT-Net, e de 2,2% e 2,1% sobre o GFANet, respectivamente. Esses valores indicam que o campo de evidência conduz a evolução dos contornos de forma estável e contínua, favorecendo segmentações coesas e menos sensíveis a variações de textura, contraste e iluminação.

Tabela 6 – Resultados comparativos em métricas de similaridade para segmentação em imagens de pele.

Método	Referência	IoU (%)	Dice (%)
SEMAC	Método proposto	85,90	92,30
GFANet	Qiu <i>et al.</i> (2023)	83,66	90,13
FAT-Net	Wu <i>et al.</i> (2022)	82,02	89,03
ADF-Net	Huang <i>et al.</i> (2024)	84,52	90,82
ASP-VMUNet	Bao <i>et al.</i> (2025)	80,32	89,09

Fonte: Elaborado pelo Autor.

A diferença entre o desempenho do SEMAC e o das principais arquiteturas do estado da arte é inferior a 1,5% em IoU, situando-se dentro da variabilidade experimental esperada. Essa proximidade demonstra que a integração entre aprendizado supervisionado e formulação energética é capaz de sustentar altos níveis de similaridade sem recorrer a mecanismos explícitos de atenção ou regularizações complexas. A estrutura híbrida do SEMAC, ao combinar princípios físicos de contorno com aprendizado profundo, equilibra generalização e controle morfológico, assegurando estabilidade e reprodutibilidade das segmentações.

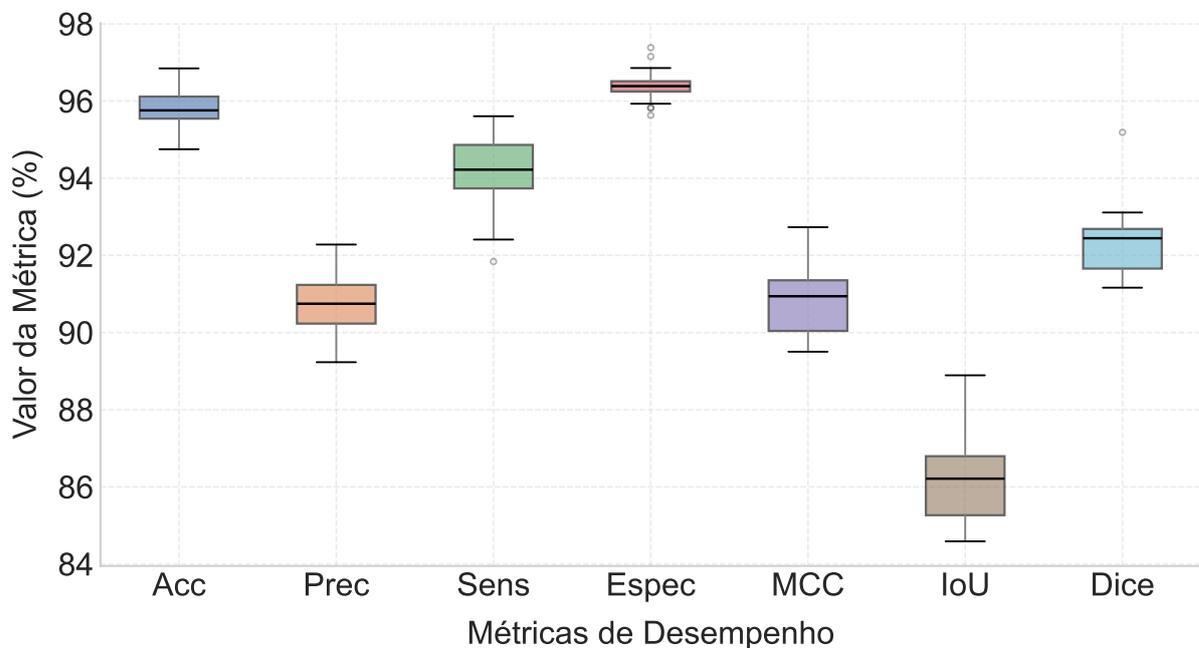
As arquiteturas puramente neurais, como FAT-Net e ADF-Net, tendem a sobreajustar em regiões de baixo contraste devido à natureza local de seus mapas de atenção. No SEMAC, a ação conjunta das forças internas e externas suaviza essas oscilações e estabiliza a fronteira em

áreas ambíguas. Esse equilíbrio entre coerência geométrica e orientação contextual resulta em segmentações mais homogêneas e previsíveis, reduzindo a variabilidade estatística e preservando a integridade das bordas.

Do ponto de vista conceitual, o SEMAC integra a formulação clássica dos contornos ativos ao aprendizado profundo supervisionado, realizando uma otimização física sobre o campo de evidência. Seu comportamento estável decorre do ajuste dinâmico entre as forças internas, que impõem continuidade e suavidade, e a energia externa, que conduz a curva em direção às bordas semanticamente consistentes. Essa formulação preserva a interpretabilidade geométrica e assegura robustez diante de ruídos e variações estruturais, evidenciando potencial para aplicações clínicas que exigem precisão morfológica e reprodutibilidade.

A Figura 29 apresenta a distribuição das métricas de desempenho obtidas pelo método proposto na segmentação de lesões cutâneas. Observa-se baixa variabilidade e elevada consistência entre execuções, com desvios padrão inferiores a 1,1% nas principais métricas. Esse comportamento demonstra que o SEMAC mantém estabilidade sob diferentes configurações de inicialização e ajustes de hiperparâmetros, preservando a robustez dos resultados obtidos.

Figura 29 – Distribuição das métricas de desempenho na segmentação de lesões cutâneas por meio de *boxplots*. Cada *boxplot* representa a dispersão dos valores obtidos nas imagens do conjunto de teste.



Fonte: Elaborado pelo autor.

As métricas de Acurácia (95,90%) e Precisão (90,80%) apresentam caixas compactas e *whiskers* curtos, evidenciando uma distribuição concentrada e alto grau de reprodutibilidade.

Esse comportamento confirma a capacidade do SEMAC em identificar corretamente as regiões lesionadas, minimizando erros de classificação e assegurando resultados consistentes. A Especificidade, com média de 96,40% e desvio padrão de apenas 0,4%, destaca-se como a métrica mais estável, indicando que o método controla de forma eficiente a expansão dos contornos e evita a inclusão de áreas de fundo. Já a Sensibilidade, embora apresente leve dispersão ($\sigma = 0,9\%$), mantém valores médios acima de 94%, reforçando a habilidade do SEMAC em capturar fronteiras difusas sem comprometer a integridade geométrica da segmentação.

As métricas de similaridade IoU (85,90%) e Dice (92,30%) evidenciam a fidelidade geométrica das segmentações, com sobreposição elevada entre previsões e anotações de referência. A amplitude interquartil moderada indica que o SEMAC mantém coerência estrutural mesmo em cenários visuais adversos. Por fim, o valor de MCC igual a 90,87%, com desvio padrão σ de 0,85, demonstra o equilíbrio entre falsos positivos e falsos negativos, validando a estabilidade global do método proposto.

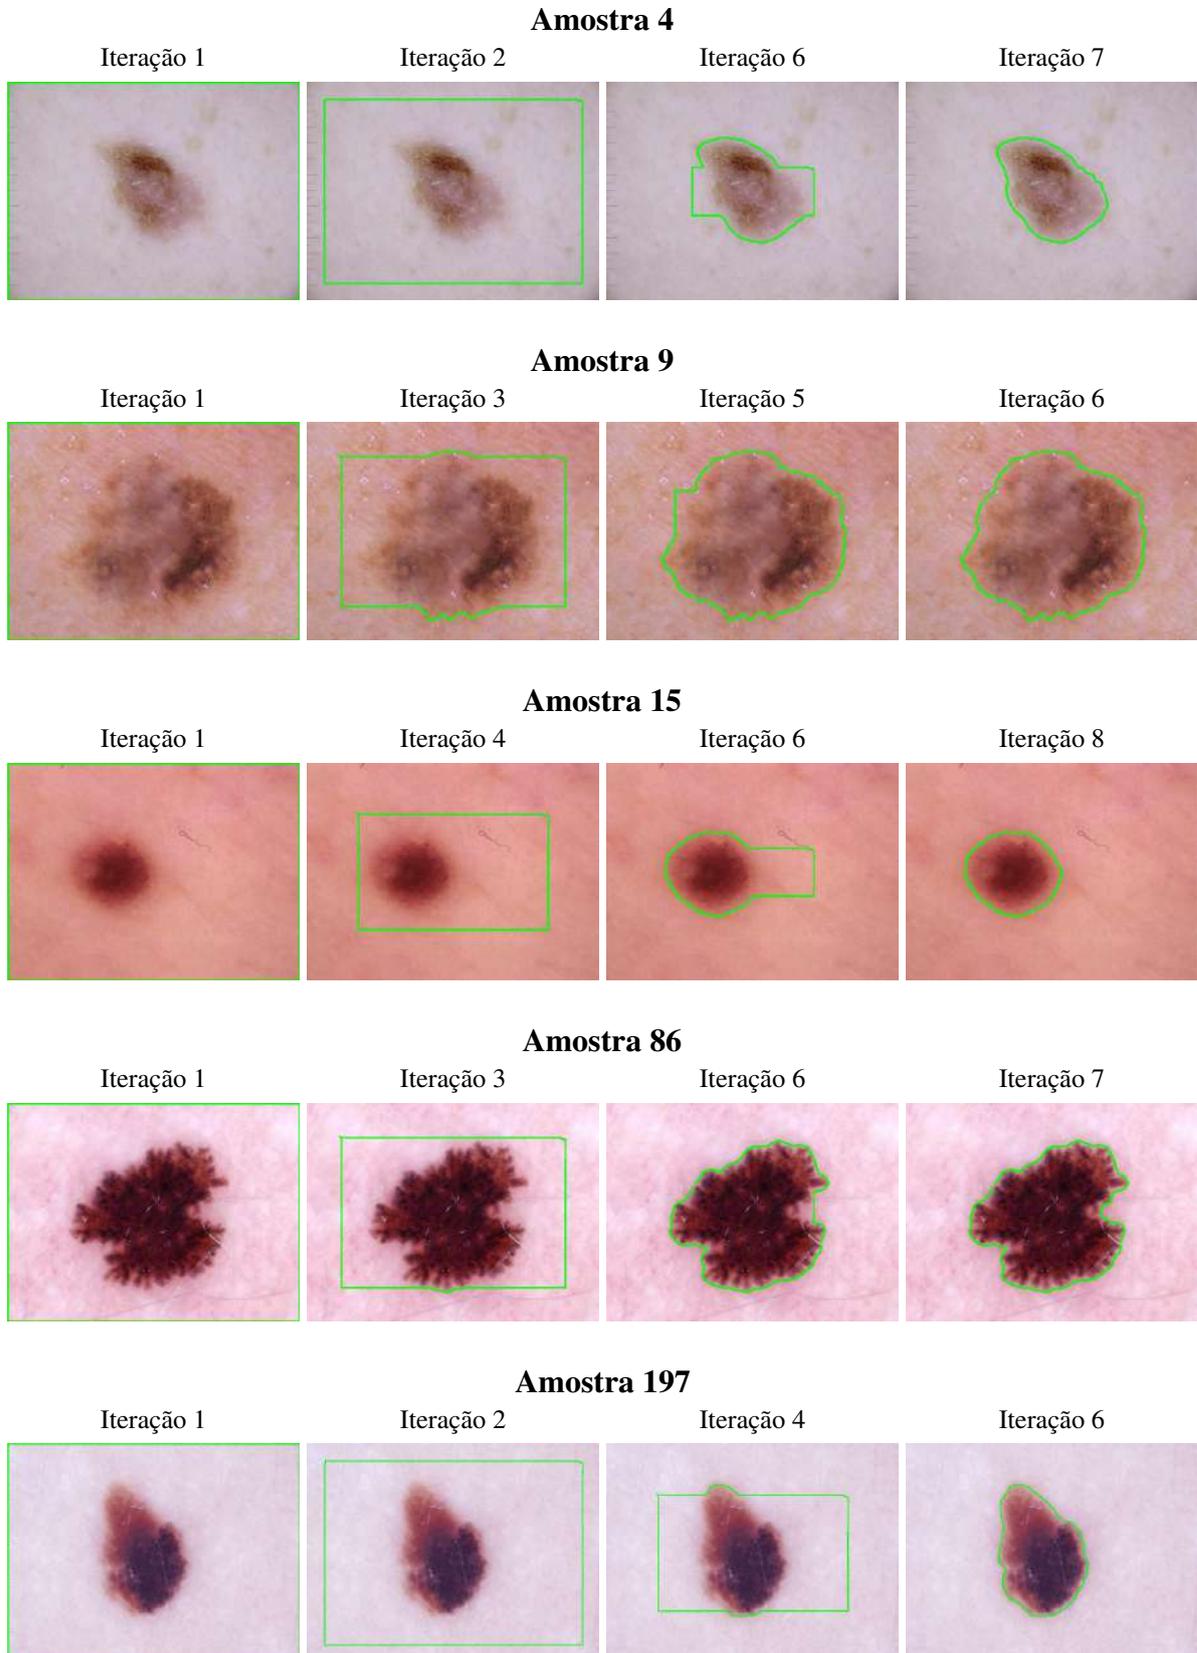
De modo geral, o SEMAC combina a estrutura geométrica dos contornos ativos com a expressividade estatística do campo de evidência, alcançando desempenho comparável ao de arquiteturas profundas recentes, mas com menor sensibilidade à quantidade de dados e maior estabilidade interpretável. Em vez de depender exclusivamente da generalização de redes, o SEMAC fundamenta sua evolução em princípios energéticos explícitos, nos quais o campo de evidência atua como modulador contextual das forças internas e externas.

4.2.1.2 *Resultados Qualitativos*

A Figura 30 ilustra a evolução do processo de segmentação em imagens de pele ao longo das iterações do SEMAC. São apresentadas cinco amostras representativas que abrangem diferentes condições visuais, permitindo observar como o SEMAC se adapta a distintos graus de complexidade. As amostras 4 e 9 exemplificam casos de baixo contraste entre a lesão e o tecido saudável, nas quais o contorno evolui de forma progressiva até estabilizar nas fronteiras reais. A amostra 15 corresponde a uma borda nítida e bem delimitada, evidenciando convergência rápida e regularidade geométrica. Já as amostras 86 e 197 ilustram situações de maior irregularidade morfológica, com bordas descontínuas e texturas heterogêneas, nas quais o método ajusta o contorno de modo incremental, mantendo continuidade e coerência estrutural ao longo da evolução.

Nas iterações iniciais, o contorno parte de uma configuração retangular que delimita

Figura 30 – Evolução do processo de segmentação em imagens de pele pelo SEMAC. Cada linha corresponde a uma amostra distinta, enquanto as colunas representam diferentes estágios iterativos. Observa-se a progressiva adaptação das curvas de contorno (em verde) desde a inicialização retangular até a convergência final às bordas reais da lesão.



Fonte: Elaborado pelo autor.

de forma ampla a região suspeita. À medida que o processo evolui, essa forma inicial se deforma gradualmente, adaptando-se às variações fotométricas e morfológicas até aderir com precisão às bordas reais da lesão. O ritmo de convergência varia conforme o tamanho e a complexidade das estruturas segmentadas. Lesões extensas, como a Amostra 4, alcançam estabilização rapidamente, pois o contorno inicial já cobre boa parte da área de interesse, exigindo apenas correções marginais nas fronteiras.

Em contrapartida, em lesões menores (como nas Amostras 4 e 15), observa-se um processo mais gradual e refinado. Nessas situações, o contorno precisa contrair-se de forma controlada ao longo das iterações para capturar as nuances da região patológica, ajustando a curvatura local até que a segmentação se estabilize de maneira coerente e morfolologicamente fiel.

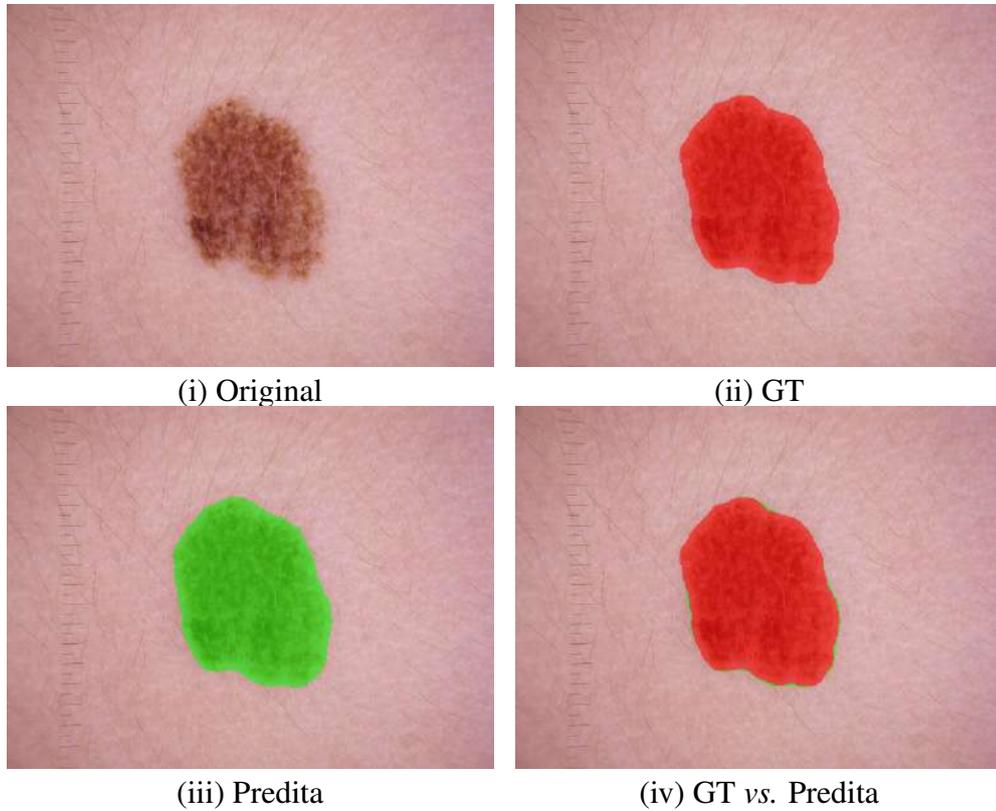
A Figura 31 apresenta uma análise qualitativa dos resultados obtidos pelo SEMAC na segmentação de lesões cutâneas. Para cada amostra, são exibidas: (i) a imagem original; (ii) a máscara de referência anotada manualmente (GT); (iii) a segmentação predita; e (iv) a sobreposição entre GT e predição, evidenciando o grau de coincidência entre as regiões segmentadas. Observa-se que, nas três amostras, o SEMAC delinea com precisão as regiões de interesse, mantendo boa aderência às bordas reais. As diferenças entre GT e predição concentram-se nas extremidades das lesões, associadas a pequenas irregularidades geométricas ou a variações sutis de tonalidade, típicas de imagens dermatoscópicas. Esses resultados demonstram que o método mantém a integridade morfológica das lesões e reduz significativamente erros de subsegmentação e supersegmentação.

Esse comportamento reforça que a formulação multicontorno lida de forma eficaz com heterogeneidade de textura, variações de contraste e interferências externas, ajustando-se dinamicamente à complexidade e ao tamanho da lesão. O número distinto de iterações até a convergência entre amostras reflete essa adaptabilidade, indicando que o processo evolutivo é guiado por critérios energéticos locais em vez de depender de um número fixo de passos.

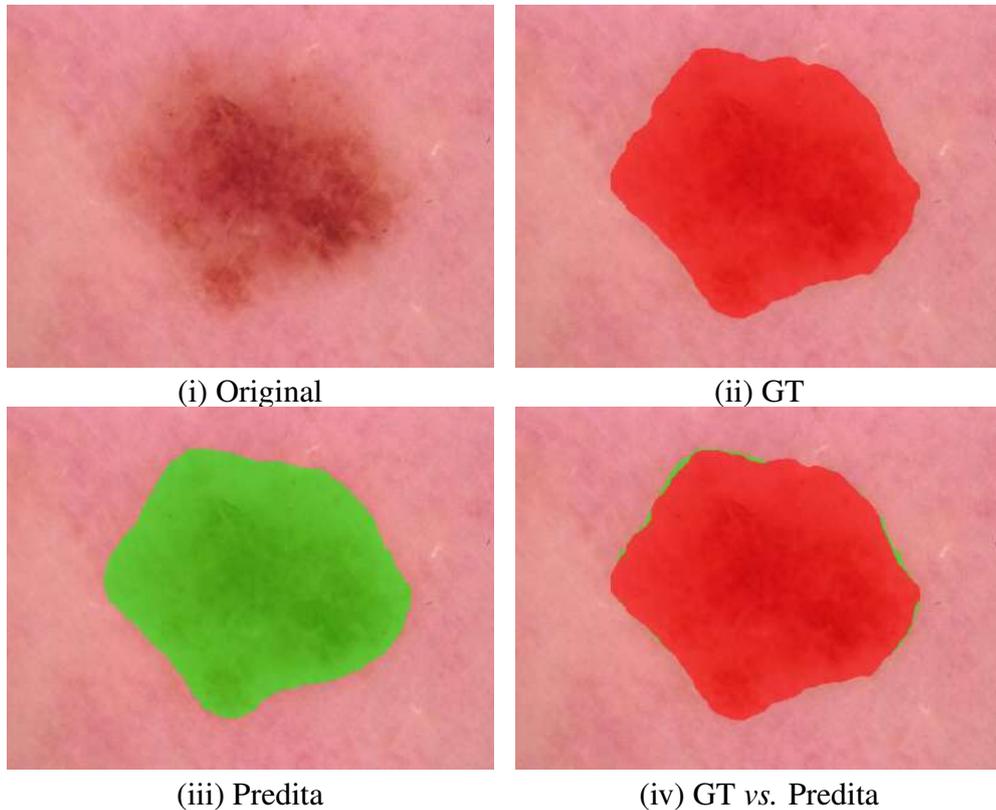
A análise qualitativa complementa as evidências quantitativas, mostrando que o SEMAC é capaz de evoluir de aproximações iniciais amplas até contornos precisos e estáveis, mesmo sob condições desafiadoras. Essa consistência visual, aliada ao desempenho numérico elevado, consolida o método como uma alternativa eficaz e confiável para a segmentação automática de lesões de pele.

Figura 31 – Visualização qualitativa de duas amostras de lesões cutâneas. Para cada caso, são apresentadas: (i) a imagem original; (ii) a sobreposição do GT; (iii) a segmentação predita pelo SEMAC; e (iv) a sobreposição entre a GT e a predição.

Amostra 49



Amostra 101



4.2.2 Segmentação de Células Sanguíneas

Após a etapa de avaliação em imagens de pele, o SEMAC foi aplicado ao domínio de células sanguíneas, com o objetivo de analisar seu desempenho em estruturas de menor escala e alta densidade espacial em casos reais. Diferentemente das lesões cutâneas, que geralmente apresentam uma única região de interesse bem delimitada, as imagens microscópicas de sangue contêm múltiplos objetos próximos e com fronteiras pouco contrastantes. Essas características impõem desafios adicionais ao processo de segmentação, exigindo que o SEMAC preserve a individualidade das instâncias, mantenha a separação entre células adjacentes e lide adequadamente com interferências provocadas por ruído e sobreposição óptica.

4.2.2.1 Resultados Quantitativos

A avaliação quantitativa no domínio das células sanguíneas, apresentada na Tabela 7, evidencia que o SEMAC mantém desempenho elevado mesmo em um cenário caracterizado por alta densidade estrutural, sobreposição de instâncias e contraste variável entre fundo e objeto. O SEMAC obteve Acurácia de 96,24%, Precisão de 95,60%, Sensibilidade de 93,10%, Especificidade de 97,90% e MCC de 91,40%, indicando equilíbrio consistente entre detecção e rejeição de regiões, com controle efetivo de falsos positivos e negativos.

Tabela 7 – Resultados comparativos em métricas quantitativas para segmentação em imagens de células sanguíneas.

Método	Referência	ACC (%)	Prec (%)	Sens (%)	Espec (%)	MCC (%)
SEMAC	Método proposto	96,24	95,60	93,10	97,90	91,40
CellSegUNet	Depto <i>et al.</i> (2021)	97,60	–	–	–	–

Fonte: Elaborado pelo autor.

A formulação do SEMAC evita tanto a fusão indevida de células adjacentes quanto a fragmentação excessiva de estruturas contínuas, problemas recorrentes em métodos puramente convolucionais aplicados a imagens microscópicas. A elevada Especificidade (97,90%) evidencia que o SEMAC controla de forma eficaz a expansão dos contornos, impedindo a incorporação de áreas de fundo, enquanto a Sensibilidade (93,10%) confirma sua capacidade de detectar fronteiras sutis mesmo sob ruído e baixa definição óptica. O valor de MCC superior a 90% reforça a estabilidade global do equilíbrio entre verdadeiros e falsos classificadores, demonstrando a robustez do processo evolutivo diante de variações topológicas e heterogeneidade intra-amostra.

Em comparação ao CellSegUNet (Metlek, 2024), o SEMAC apresenta desempenho

Tabela 8 – Resultados comparativos em métricas de similaridade para segmentação em imagens de células sanguíneas. O estudo de Depto *et al.* (2021) avaliou diversos métodos de segmentação aplicados ao mesmo conjunto de dados de células sanguíneas, possibilitando uma comparação direta de desempenho entre as abordagens.

Método	Referência	Dice (%)	IoU (%)
SEMAC	Método proposto	94,80	90,10
Otsu's Method	Depto <i>et al.</i> (2021)	92,60	86,50
BHT	Depto <i>et al.</i> (2021)	52,50	49,48
Watershed	Depto <i>et al.</i> (2021)	78,21	68,21
U-Net	Depto <i>et al.</i> (2021)	93,09	87,16
U-Net++	Depto <i>et al.</i> (2021)	88,80	81,44
TernausNet	Depto <i>et al.</i> (2021)	93,38	87,65
R2U-Net	Depto <i>et al.</i> (2021)	86,70	77,70
Attention U-Net	Depto <i>et al.</i> (2021)	91,00	83,70
Attention R2U-Net	Depto <i>et al.</i> (2021)	78,50	65,20
FCN	Depto <i>et al.</i> (2021)	85,40	75,20
DeepLabv3+	Toptaş e Hanbay (2023)	96,00	91,00
CellSegUNet	Metlek (2024)	97,10	92,70

Fonte: Elaborado pelo autor.

competitivo, alcançando 94,80% de Dice e 90,10% de IoU, valores apenas 2,30 p.p. e 2,60 p.p. inferiores, respectivamente, aos do modelo supervisionado especializado. Essa proximidade de resultados é relevante considerando que o SEMAC adota uma formulação que engloba aprendizado profundo e dinâmica geométrica, mantendo estrutura explicável e estabilidade física mesmo sem ajustes específicos para o domínio hematológico. Enquanto o CellSegUNet foi projetado exclusivamente para a segmentação de células sanguíneas, o SEMAC conserva desempenho semelhante com uma arquitetura mais genérica e interpretável.

Como mostrado na Tabela 8, o SEMAC supera métodos clássicos como Watershed e BHT, com ganhos expressivos tanto em Dice e em IoU, além de apresentar resultados superiores a arquiteturas intermediárias como U-Net (+1,71% em Dice e +2,94% em IoU) e TernausNet (+1,42% e +2,45%, respectivamente). Em relação ao DeepLabv3+ (Toptaş; Hanbay, 2023), modelo de segmentação genérica amplamente utilizado, o desempenho do SEMAC difere em apenas 1,2% em IoU e 1,2% em Dice, mantendo, contudo, maior regularidade e estabilidade morfológica nas fronteiras segmentadas.

A diferença observada em relação aos modelos de referência reflete a natureza integrada do SEMAC, no qual o campo de evidência atua como componente ativo do processo de evolução geométrica. Em vez de operar de forma puramente paramétrica, o SEMAC traduz as informações aprendidas pela rede em forças energéticas contínuas, que orientam a contração e a

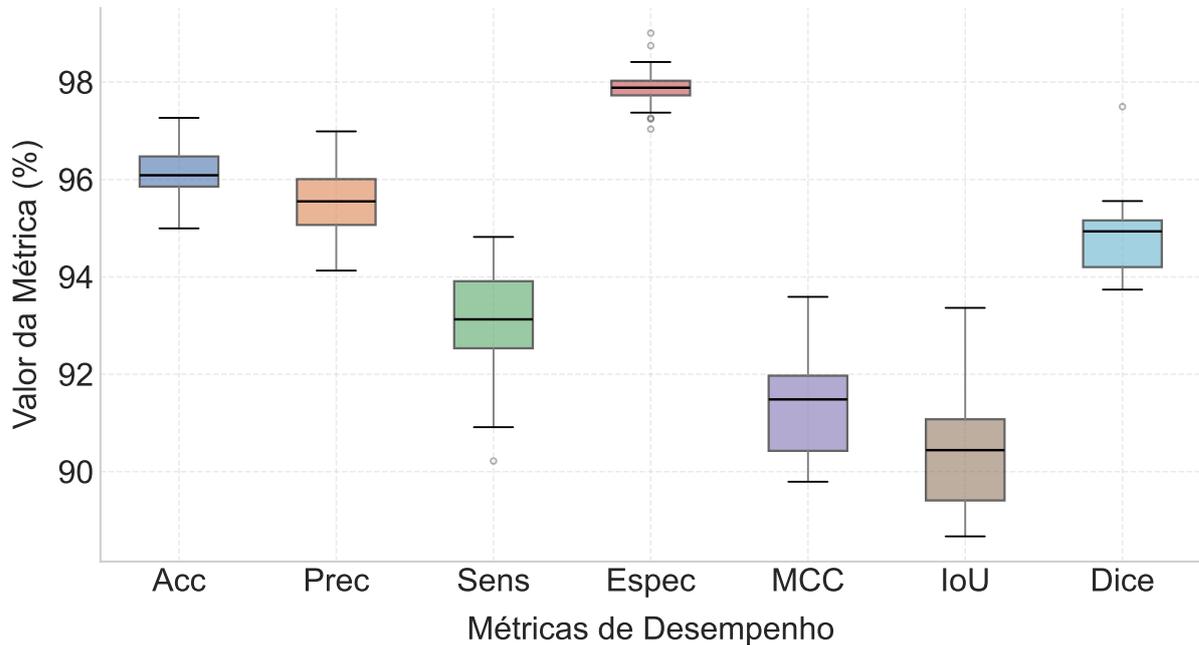
expansão dos contornos de acordo com a coerência morfológica da imagem. Essa formulação confere ao método maior estabilidade e regularidade na convergência, permitindo que as fronteiras evoluam de maneira controlada mesmo em regiões de baixo contraste ou com sobreposição de estruturas. Assim, o desempenho alcançado não decorre apenas da capacidade de aprendizado, mas da forma como esse aprendizado é incorporado à dinâmica física da segmentação, resultando em previsibilidade, robustez e aderência geométrica superiores em contextos biomédicos complexos.

A comparação com modelos puramente neurais evidencia diferenças conceituais relevantes. Enquanto arquiteturas como U-Net, DeepLabv3+ e CellSegUNet dependem de mecanismos de atenção e convoluções dilatadas para reconstruir o contexto global, o SEMAC preserva a formulação clássica dos contornos ativos, incorporando o campo de evidência como componente contínuo da energia externa. Esse campo orienta as forças de fronteira com base em relações probabilísticas locais e regionais, reforçando gradientes em áreas ambíguas e conduzindo a uma convergência mais suave e estável. Como consequência, o SEMAC reduz a ocorrência de sobresegmentação em regiões densas, mantém coerência espacial entre múltiplos objetos e assegura contornos mais regulares mesmo sob ruído fotométrico ou variação topológica.

A Figura 32 apresenta a distribuição das métricas de desempenho obtidas na segmentação de células sanguíneas. Observa-se alta consistência entre execuções, com desvios padrão inferiores a 1,2% em todas as métricas, o que evidencia a estabilidade do método diante da variabilidade morfológica das amostras. A Acurácia (96,24%) e a Precisão (95,60%) concentram-se em valores elevados, com dispersões reduzidas ($\sigma = 0,65$ e $\sigma = 0,75$, respectivamente), indicando excelente capacidade do SEMAC em identificar corretamente as regiões celulares. A Especificidade, com média de 97,90% e desvio de apenas 0,45%, destaca-se como a métrica mais estável, refletindo o controle eficaz sobre a delimitação das fronteiras e a exclusão de regiões de fundo. A Sensibilidade (93,10%), embora apresente variação ligeiramente superior ($\sigma = 1,10$), mantém desempenho consistente mesmo em áreas de sobreposição celular.

O coeficiente de Matthews (MCC = 91,40%, $\sigma = 1,00$) confirma o equilíbrio entre verdadeiros e falsos resultados, reforçando a confiabilidade do processo de segmentação. As métricas de similaridade, IoU (90,10%) e Dice (94,80%), evidenciam elevada sobreposição entre as predições e as anotações de referência, com baixa variabilidade interamostral. Essa estabilidade confirma a robustez da integração entre o campo de evidência e a evolução geométrica dos contornos, favorecendo a obtenção de fronteiras contínuas, coerentes e morfológicamente

Figura 32 – Distribuição das métricas de desempenho na segmentação de células sanguíneas por meio de *boxplots*. Cada *boxplot* representa a variação dos valores obtidos nas imagens do conjunto de teste.



Fonte: Elaborado pelo autor.

consistentes. Esses resultados consolidam o SEMAC como uma abordagem interpretável e generalizável para a segmentação automática de células sanguíneas em contextos clínicos e laboratoriais.

Os resultados quantitativos indicam que o SEMAC alcança um ponto de equilíbrio entre desempenho e interpretabilidade, preservando a robustez geométrica observada nas imagens de pele e estendendo sua aplicabilidade a domínios microscópicos mais complexos. O SEMAC demonstra capacidade de generalização comparável à de arquiteturas supervisionadas de última geração, mas com menor dependência de dados anotados e maior explicabilidade estrutural, aspectos desejáveis em contextos biomédicos que demandam transparência e confiabilidade nos processos de segmentação automática.

4.2.2.2 Resultados Qualitativos

As Figuras 33 e 34 ilustram a evolução do processo de segmentação em imagens de células sanguíneas, evidenciando a progressiva adaptação dos contornos ativos (em verde) às bordas reais das células ao longo das iterações. O comportamento observado demonstra a capacidade do SEMAC multirregião de evoluir simultaneamente múltiplos contornos ($N > 1$), ajustando-os de forma coordenada às diferentes regiões de interesse. Em amostras com células

isoladas ou levemente agrupadas (Figura 33), a convergência ocorre rapidamente, uma vez que os contornos interagem minimamente entre si e aderem às fronteiras verdadeiras em poucas iterações. Por outro lado, em configurações mais densas, como nas amostras que estão na Figura 34, o processo se torna mais gradual: as curvas competem por regiões adjacentes e precisam de iterações adicionais até que as fronteiras sejam devidamente separadas e estabilizadas. Esse comportamento evidencia o caráter adaptativo do SEMAC, cuja evolução iterativa corrige progressivamente sobreposições e ambiguidades locais, preservando a coerência morfológica e a independência entre as regiões segmentadas.

A Figura 35 complementa a análise ao comparar os resultados finais do SEMAC com as máscaras de referência. Nota-se predominância de acertos e baixa incidência de erros localizados, concentrados principalmente em regiões de sobreposição celular ou de baixo contraste fotométrico. Os falsos-negativos ocorrem, em geral, nas bordas parcialmente ocultas por contato entre células, enquanto pequenos falsos-positivos aparecem em fragmentos residuais ou em zonas com reflexos ópticos. Ainda assim, a correspondência entre predição e referência demonstra preservação precisa da morfologia celular, com contornos suaves e aderentes às fronteiras verdadeiras, evidenciando a eficiência da regulação energética em separar regiões adjacentes sem distorcer sua geometria.

A análise visual também revela que o processo de evolução multirregião ($N > 1$) preserva a independência entre os contornos, evitando tanto fusões indevidas quanto fragmentações artificiais. Em áreas de alta densidade celular, os contornos se estabilizam de forma cooperativa, ajustando suas fronteiras em resposta às forças de repulsão mútua e à influência do campo de evidência local. Essa dinâmica garante a delimitação individual das células mesmo em regiões de contato intenso, onde a distinção morfológica é fundamental para análise quantitativa posterior. A capacidade do método de manter topologia estável e coerência geométrica ao longo da evolução reforça sua aplicabilidade em cenários laboratoriais, nos quais pequenas distorções de fronteira podem comprometer medidas de área ou forma.

A análise qualitativa confirma que o SEMAC preserva com precisão a morfologia circular ou elíptica típica das células, mantendo estabilidade mesmo sob ruído, variações de contraste e agrupamentos densos. A interação entre o processo iterativo de evolução e o controle geométrico das fronteiras assegura segmentações coerentes e contínuas, com contornos regulares e ausência de distorções estruturais, mesmo em regiões de contato ou sobreposição parcial. Esse comportamento indica que o SEMAC regula de forma eficaz a competição entre contornos

Figura 33 – Evolução do processo de segmentação em imagens de células sanguíneas bem espaçadas, utilizando o SEMAC. Observa-se a adaptação suave das curvas de contorno (em verde) desde a inicialização retangular até a convergência final sobre as fronteiras reais, evidenciando a precisão na delimitação individual das células.

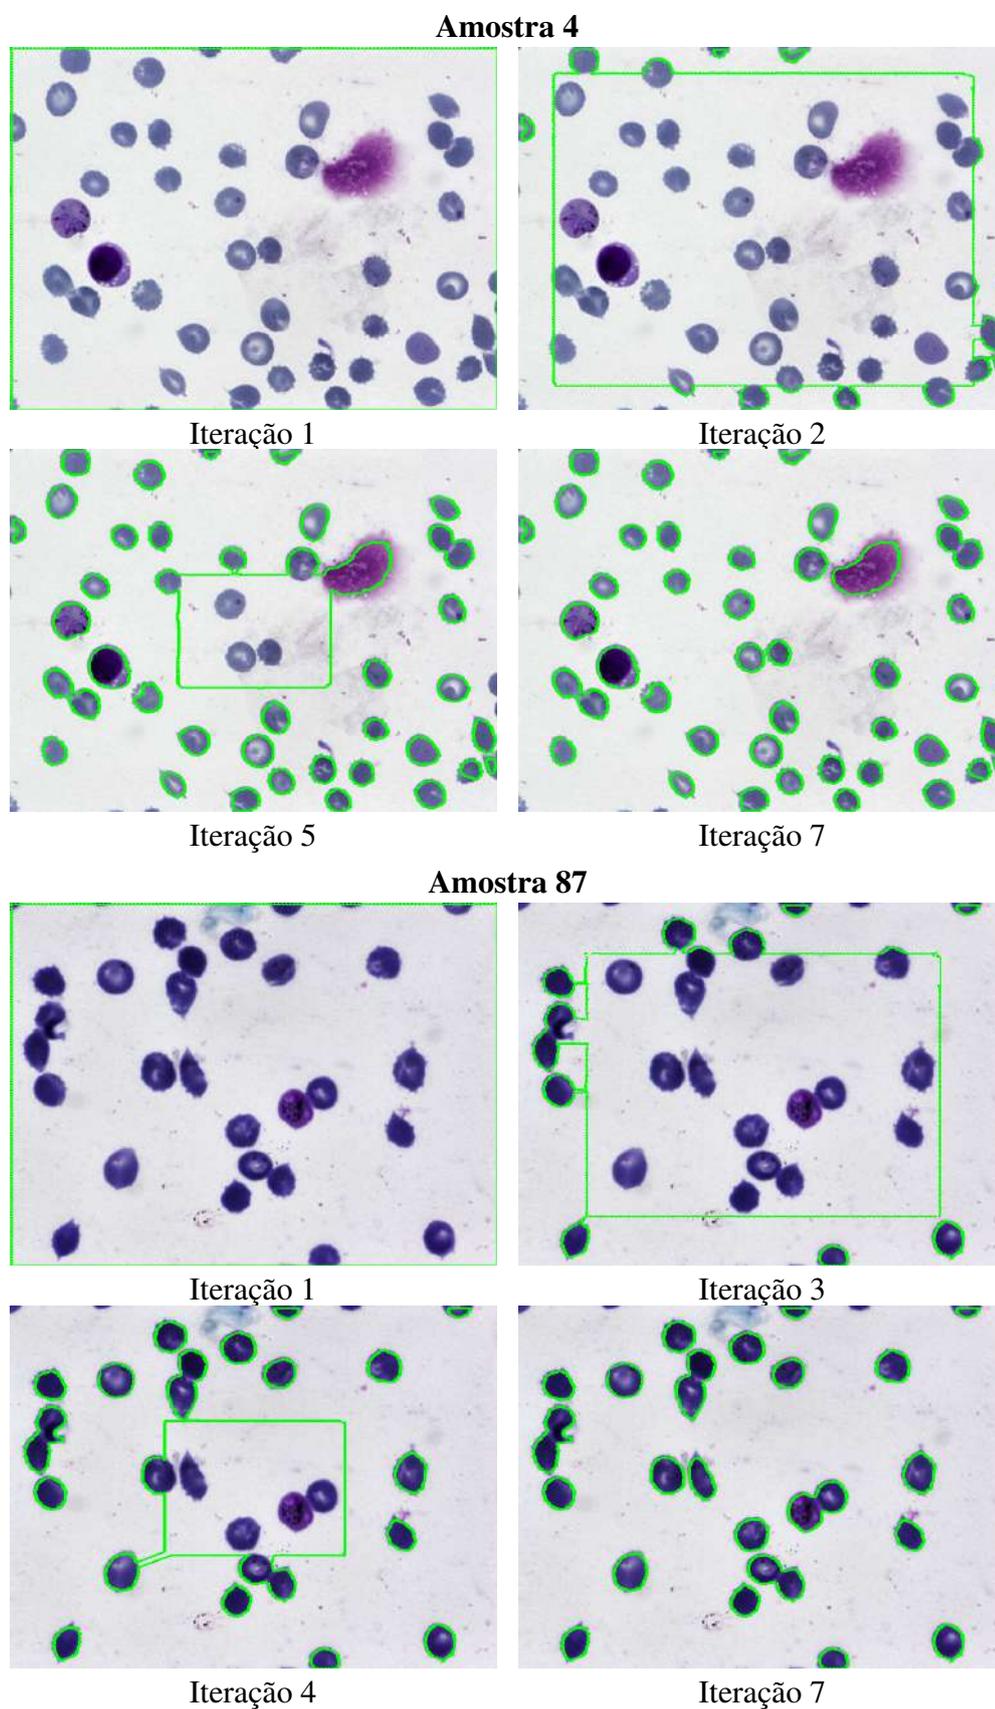
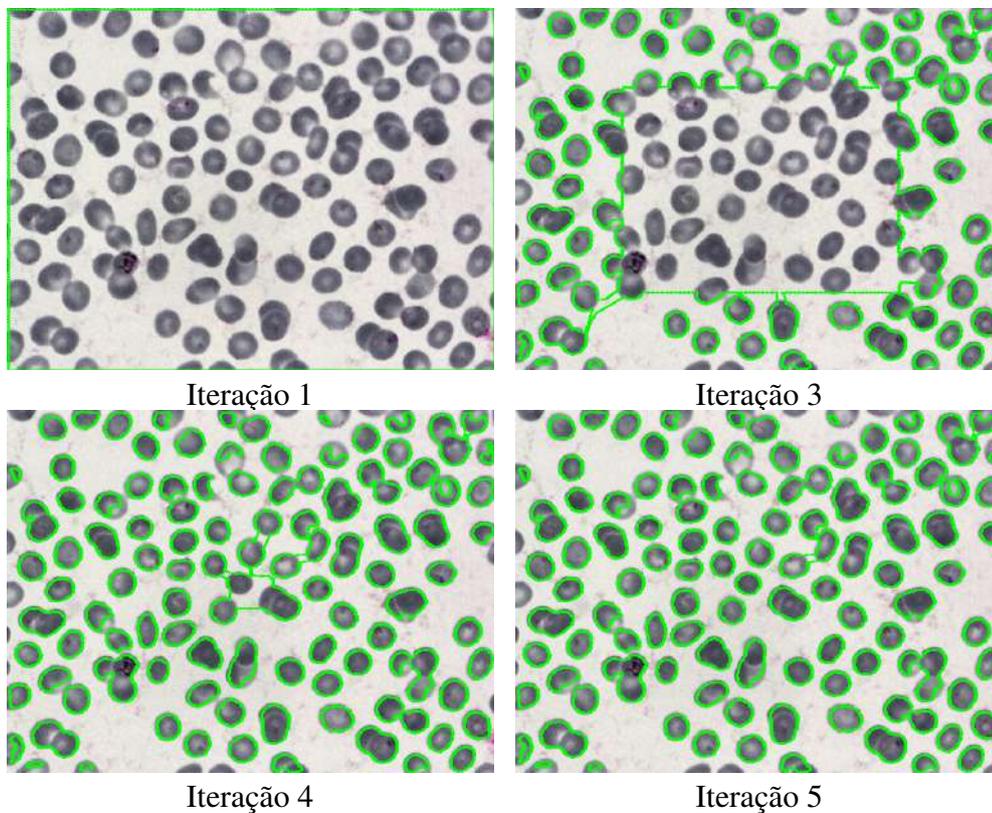


Figura 34 – Evolução do processo de segmentação em imagens de alta densidade celular pelo SEMAC. Nota-se a capacidade do método em preservar estabilidade topológica e coerência geométrica mesmo sob sobreposição e proximidade entre células, assegurando separação consistente das fronteiras.

Amostra 3



Amostra 61

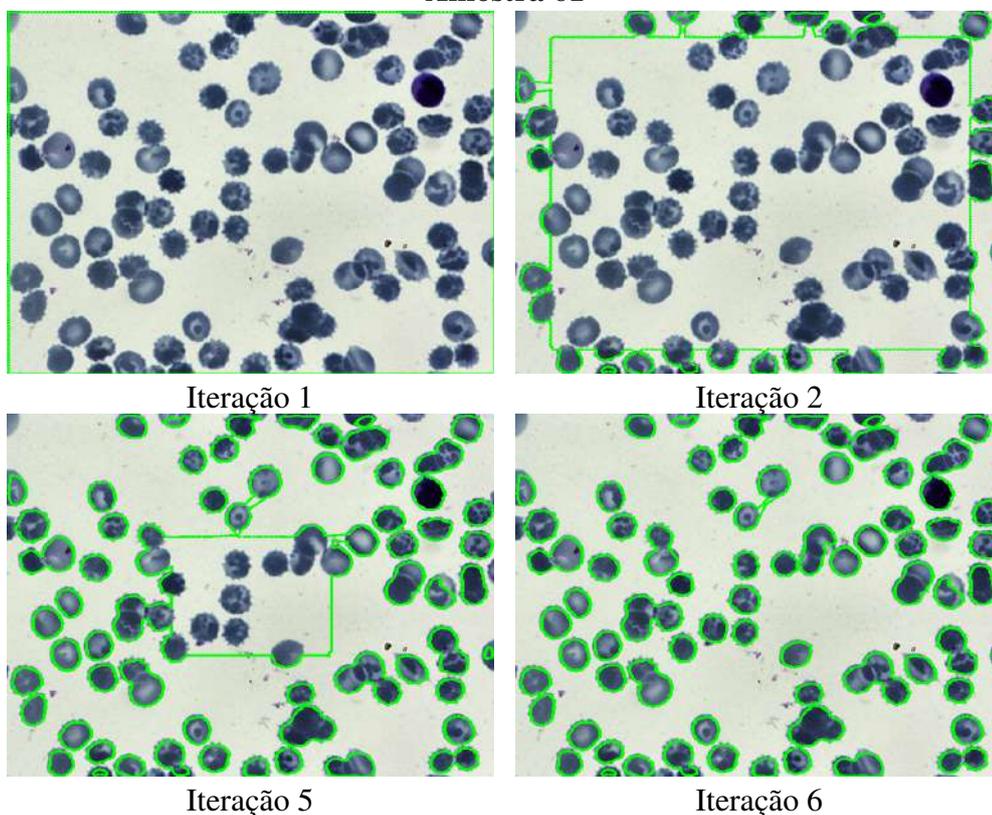
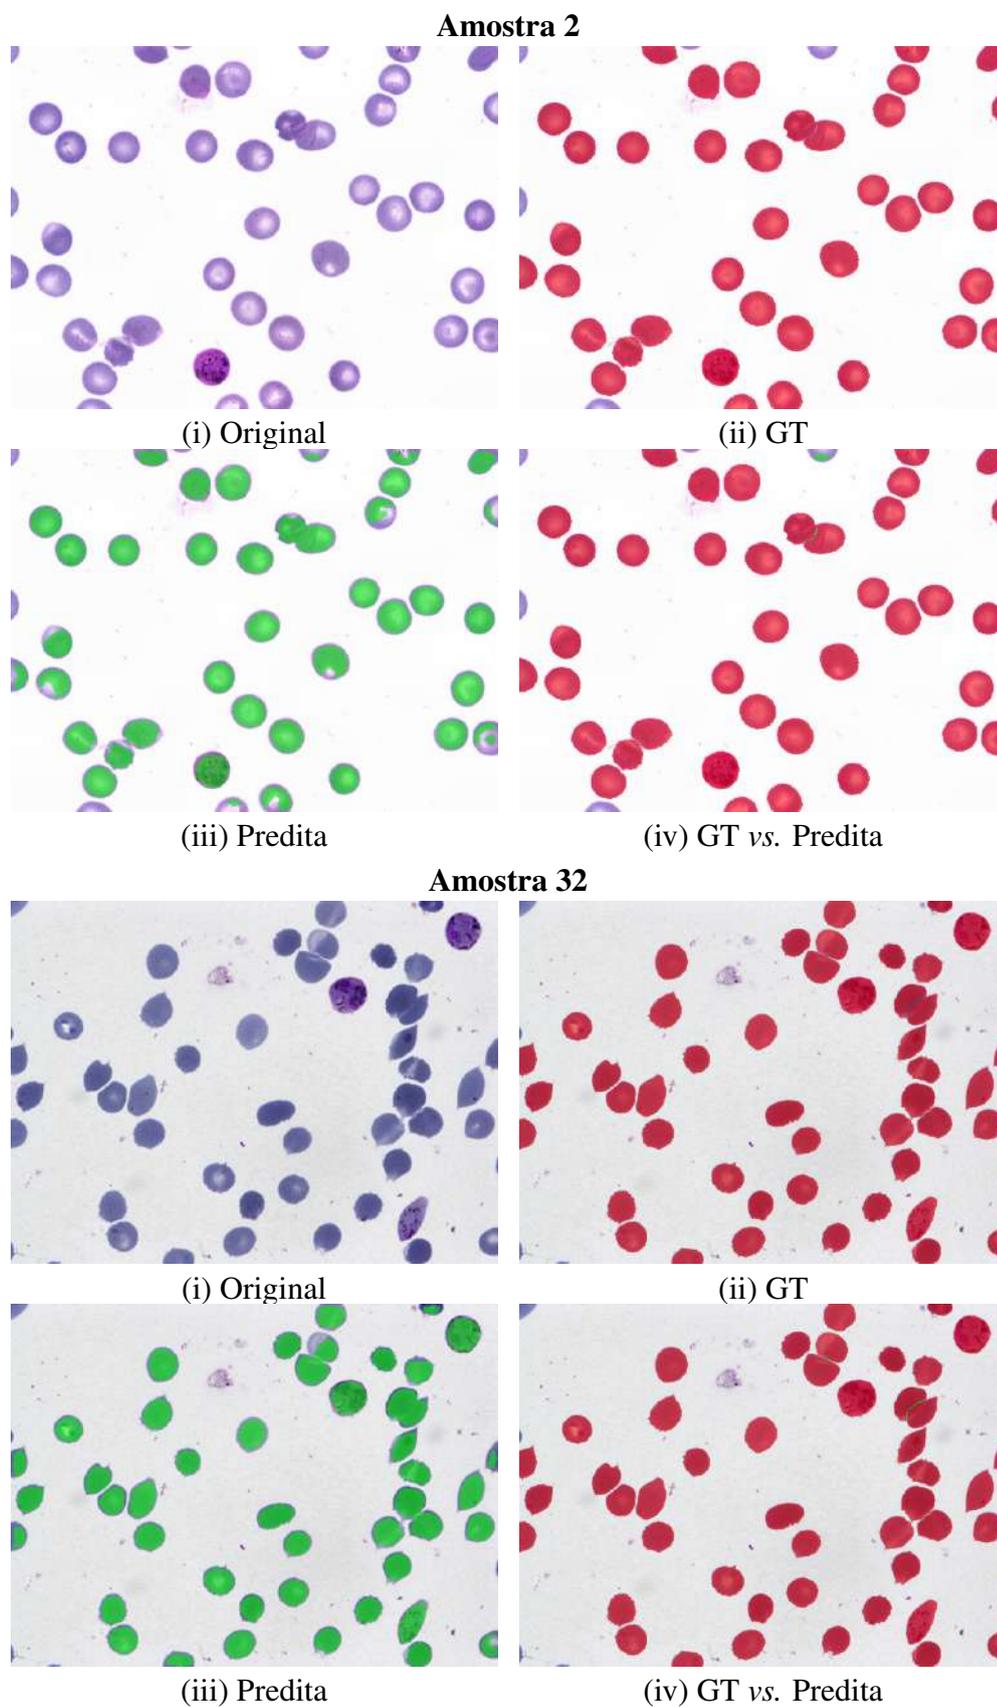


Figura 35 – Visualização qualitativa de duas amostras de células sanguíneas.



Fonte: Elaborado pelo autor.

vizinhos, equilibrando repulsão e aderência às bordas reais sem comprometer a integridade das regiões segmentadas.

O desempenho visualmente consistente, aliado à estabilidade morfológica observada, evidencia que o SEMAC constitui uma abordagem confiável e reproduzível para segmentação de células sanguíneas. Sua formulação energética orientada por evidência contextual promove coerência geométrica e previsibilidade de resposta, preservando as fronteiras celulares com fidelidade mesmo diante de ruído e sobreposição. Essas propriedades reforçam o potencial do método como uma solução eficiente e interpretável para aplicações biomédicas que demandam precisão de fronteira e consistência estrutural nas segmentações.

4.3 Análise Geral dos Resultados do SEMAC

Os resultados apresentados ao longo deste capítulo reforçam a consistência e a eficácia do SEMAC, evidenciando sua capacidade de reproduzir o comportamento esperado de acordo com os objetivos estabelecidos na Seção 1.3. Observa-se que o método mantém estabilidade evolutiva, precisão na delimitação das fronteiras e coerência geométrica entre múltiplas regiões, confirmando a adequação da proposta tanto em cenários sintéticos quanto em imagens clínicas reais.

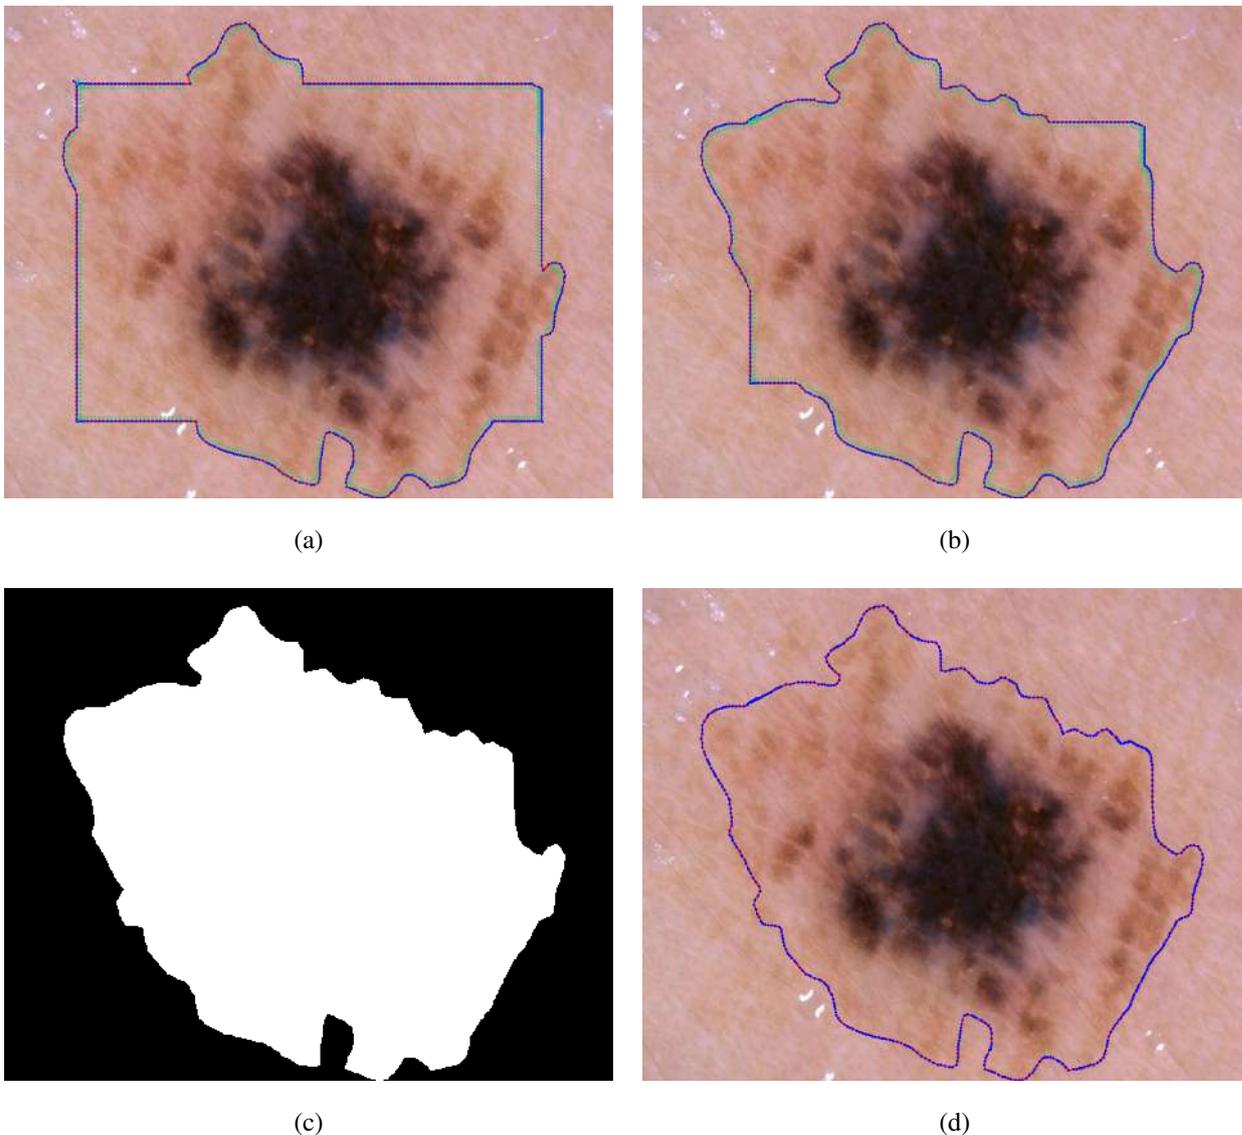
4.3.1 Desempenho do SEMAC em Bordas Complexas, Baixo Contraste e Ruído

Os resultados obtidos em regiões de baixo contraste, bordas irregulares e presença de ruído evidenciam a robustez e a estabilidade do SEMAC em condições adversas de segmentação. Tais situações são particularmente desafiadoras para abordagens baseadas apenas em gradiente, que tendem a perder precisão quando as transições fotométricas são suaves ou quando há variações internas de tonalidade na região de interesse.

Na Figura 36 apresenta-se um exemplo representativo de uma lesão dermatoscópica caracterizada por bordas pouco definidas e textura heterogênea. Observa-se que, ao longo da evolução, o SEMAC manteve aderência consistente às fronteiras reais da estrutura, ajustando-se de forma gradual às variações locais de intensidade sem ser significativamente afetado pelo ruído, neste caso decorrente da presença de gel sobre a superfície cutânea. O contorno final apresentou elevada correspondência com o GT fornecido por especialistas (Figura 36.c), preservando a coerência geométrica mesmo em regiões de baixo contraste e em transições sutis entre pele

saudável e lesão.

Figura 36 – Desempenho do SEMAC em uma imagem dermatoscópica caracterizada por baixo contraste, bordas irregulares e variação interna de tonalidade. (a–b) Evolução progressiva do contorno ativo sobre a lesão, com o campo de forças adaptativo ajustando-se às transições sutis de intensidade; (c) GT fornecido por especialistas, utilizado como referência; (d) Aderência do método às fronteiras reais mesmo em regiões com transições suaves e ruído de textura.



Fonte: Elaborado pelo autor.

Esse comportamento demonstra a eficiência do campo de forças adaptativo em redistribuir a energia evolutiva conforme o grau de evidência local, reforçando fronteiras com contraste reduzido e atenuando flutuações causadas por ruído de textura. Mesmo nas áreas em que o gradiente fotométrico é insuficiente para definir limites nítidos, o SEMAC manteve a regularidade e a continuidade das bordas, preservando a forma morfológica da região segmentada.

Esses resultados reforçam a contribuição do SEMAC para a segmentação de regiões complexas, evidenciando que a integração entre o campo de evidência e o modelo paramétrico proporciona uma dinâmica evolutiva estável e semanticamente coerente. A capacidade do método de preservar a coerência estrutural mesmo sob variações tonais e presença de ruído representa um avanço significativo em relação às formulações clássicas de contornos ativos, tornando-o particularmente adequado para aplicações clínicas e científicas em cenários de baixa definição e alta variabilidade morfológica.

4.3.2 Evolução dos Múltiplos Contornos Ativos e Divisão entre Múltiplas Regiões

Uma das principais capacidades do SEMAC é detectar e processar automaticamente a divisão entre regiões adjacentes durante o processo evolutivo. À medida que dois segmentos de contorno se aproximam dentro de uma mesma vizinhança energética, o método identifica a interseção e executa a operação de divisão, resultando na formação de novos contornos autônomos (Figura 37.c).

Essa propriedade de autoparticionamento representa um avanço em relação às formulações clássicas de contornos ativos, nas quais o tratamento de múltiplas regiões exige inicializações independentes ou heurísticas externas. No SEMAC, a divisão topológica emerge naturalmente da interação entre o campo de evidência e a dinâmica física do contorno, permitindo que um único contorno inicial se propague, fragmente e se estabilize de acordo com a estrutura real da imagem.

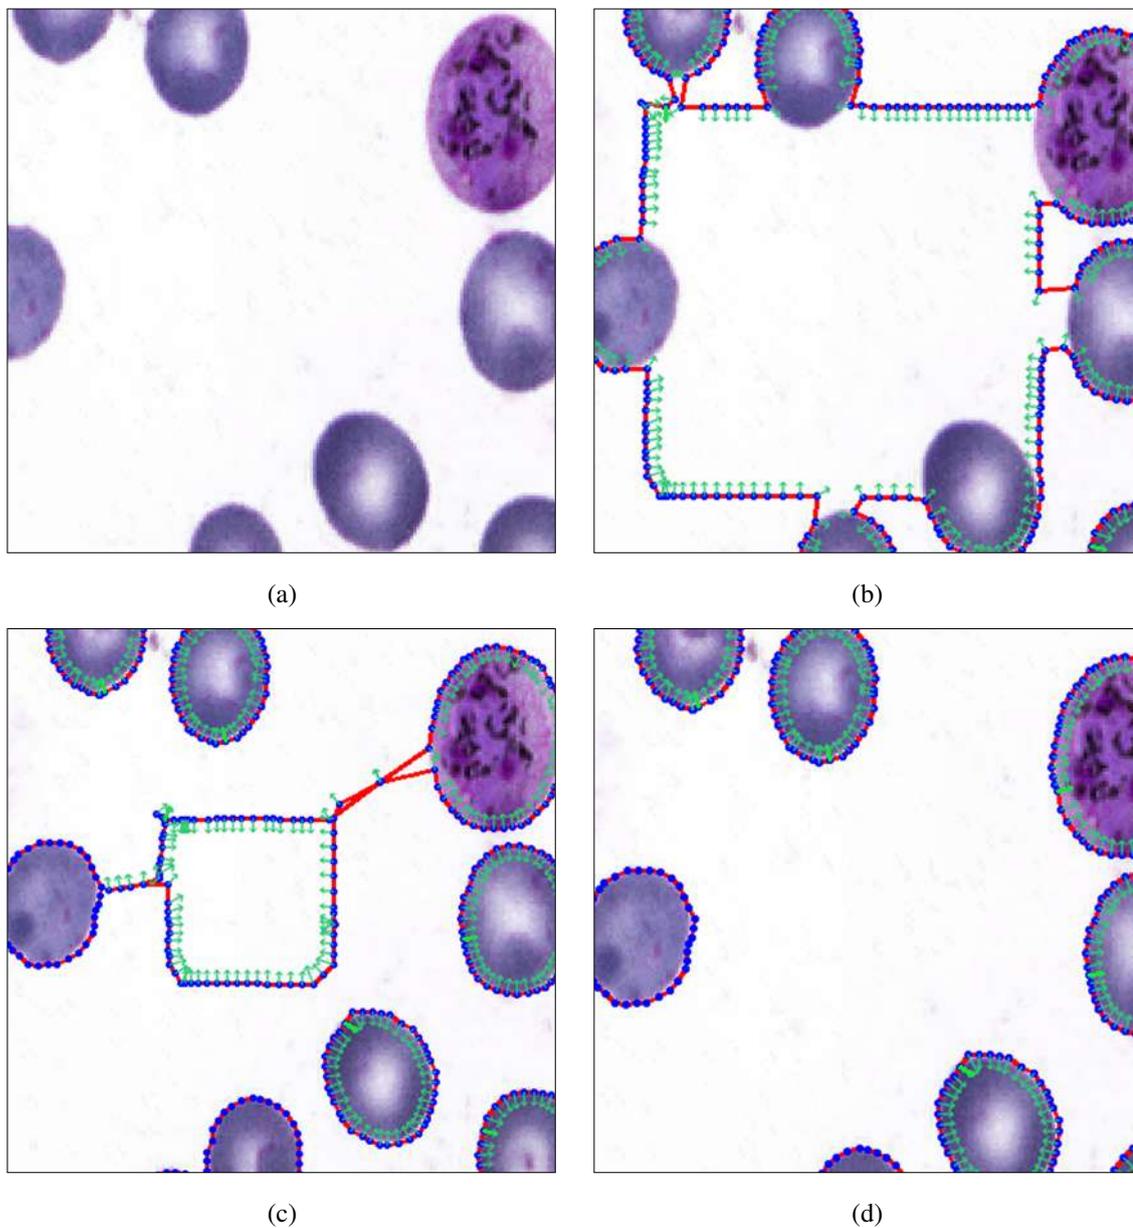
O resultado é um processo contínuo no qual divisão e estabilização ocorrem de forma integrada, mantendo a coerência geométrica e a integridade morfológica das regiões segmentadas. Esse comportamento demonstra o potencial do método para aplicações clínicas e científicas que exigem a segmentação precisa de múltiplas regiões interconectadas, com fronteiras próximas ou sobrepostas.

4.3.3 Estabilização Independente e Coerência entre Regiões Próximas

Após o particionamento topológico descrito anteriormente, os contornos resultantes evoluem de maneira independente e estável, mantendo coerência geométrica mesmo quando permanecem muito próximos.

A Figura 37 também evidencia essa estabilização local: observa-se a redução progressiva do módulo das forças externas aplicadas aos pontos do contorno até que o sistema

Figura 37 – Evolução local dos contornos ativos em imagem microscópica de sangue periférico, ilustrando o processo de divisão topológica e a estabilização subsequente: (a) aproximação de duas fronteiras dentro de uma mesma vizinhança energética; (b) interseção e divisão automática; (c) início da evolução independente dos contornos recém-divididos; (d) estabilização local sobre as respectivas fronteiras de interesse.



Fonte: Elaborado pelo autor.

atinge o equilíbrio, momento em que as forças resultantes se anulam e o contorno cessa sua movimentação. Esse fenômeno é visualmente indicado pelo desaparecimento dos vetores (setas), mostrando que cada fronteira se ajusta autonomamente à sua região de interesse.

Além disso, cada contorno estabiliza-se em momentos distintos, caracterizando o comportamento de parada independente. Como observado na Figura 37.d, determinadas regiões atingem o equilíbrio energético mais rapidamente, enquanto outras continuam ajustando-se

até alcançar sua configuração final. Esse mecanismo confirma que o SEMAC não depende de sincronização global entre os contornos, permitindo que cada um evolua e se estabilize de acordo com sua própria condição energética local.

O equilíbrio entre as forças internas e externas é alcançado de forma automática e adaptativa, garantindo estabilidade numérica e coerência geométrica mesmo em regiões de alta densidade estrutural. Essa capacidade de autorregulação geométrica constitui um dos diferenciais mais relevantes da proposta, demonstrando que o SEMAC é capaz de preservar simultaneamente a independência evolutiva e a coerência espacial das múltiplas fronteiras segmentadas.

A Figura 38 ilustra ainda a capacidade do SEMAC de distinguir e segmentar corretamente objetos espacialmente próximos, mesmo sob forte interferência de vizinhança. Observa-se que, à medida que os contornos evoluem, as forças adaptativas atuam de modo local e independente, impedindo a fusão entre fronteiras adjacentes e mantendo a delimitação precisa das células, inclusive em regiões de contato ou de pequeno espaçamento entre membranas. Esse comportamento demonstra a estabilidade do modelo diante de regiões densamente povoadas e reforça sua habilidade em preservar a coerência geométrica de cada instância, mesmo quando múltiplos objetos coexistem em um mesmo domínio energético.

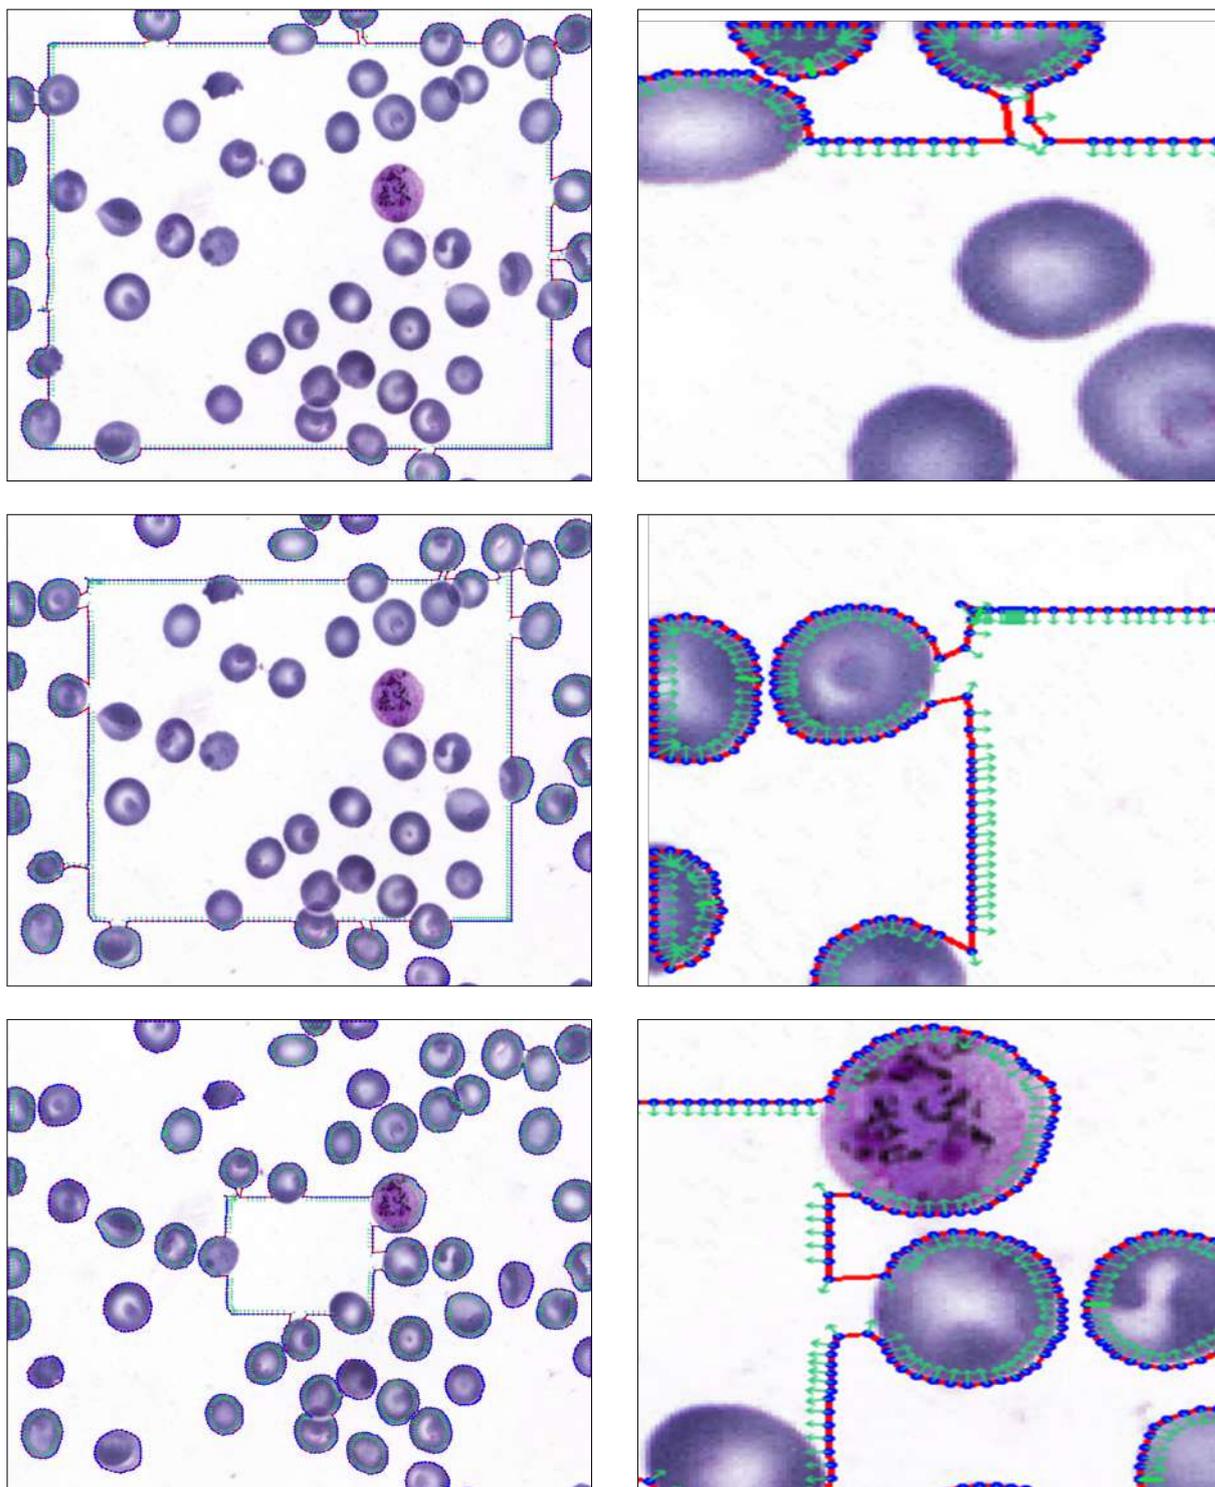
4.3.4 Validação do Campo de Evidência e da Proposta Multirregional

Os resultados experimentais apresentados nas subseções anteriores validam a formulação energética proposta pelo SEMAC, comprovando a coerência entre seus componentes conceituais e o comportamento observado durante a evolução dos contornos. A combinação entre o campo de evidência, o modelo físico baseado em contornos ativos paramétricos e a lógica de divisão topológica adaptativa resultou em um processo evolutivo estável, coerente e morfologicamente consistente.

A energia externa aprendida demonstrou desempenhar papel determinante na orientação das forças de atração, reforçando a capacidade do método em lidar com regiões de baixo contraste e ruído, sem comprometer a definição das fronteiras. Essa evidência confirma que o aprendizado supervisionado contribui para tornar o campo energético mais informativo, atuando como um guia semântico que complementa as propriedades físicas do modelo.

Entretanto, os resultados também evidenciam que o desempenho global do SEMAC não depende exclusivamente do termo de energia externa, mas do equilíbrio entre todas as forças que compõem sua formulação. A estrutura de múltiplos contornos adaptativos, associada à lógica

Figura 38 – Evolução multirregião em imagem microscópica de sangue, ilustrando a atuação dos vetores de força adaptativos após a divisão topológica. O SEMAC conduz a contração e a estabilização dos contornos de forma autônoma, mantendo separação estável entre fronteiras adjacentes. As colunas à direita mostram ampliações das áreas destacadas, evidenciando a orientação local das forças e sua redução progressiva até o equilíbrio final.



Fonte: Elaborado pelo autor.

de divisão automática e à estabilização independente, mostrou-se essencial para garantir que a evolução ocorra de forma coordenada e sem interferência entre regiões adjacentes. Essa sinergia entre aprendizado, física e topologia caracteriza a principal contribuição da proposta.

De modo geral, a análise dos resultados confirma que o SEMAC alcança segmentações multirregionais estáveis e coerentes sem necessidade de múltiplas inicializações ou ajustes manuais. A integração entre campo de evidência, dinâmica MCA e controle adaptativo de energia produz um modelo capaz de generalizar seu comportamento em diferentes contextos visuais, mantendo a coerência geométrica e a consistência semântica das fronteiras segmentadas.

5 CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho apresentou o *SEmantic Multi-Region Active Contour (SEMAC)*, um método de segmentação que combina uma formulação de energia externa aprendida, responsável por orientar a evolução semântica dos contornos, com um mecanismo dinâmico de divisão e estabilização autônoma, que permite a formação e evolução de múltiplos contornos em paralelo. A proposta integra a modelagem física dos contornos ativos com o aprendizado supervisionado de campos de evidência semântica, resultando em segmentações multirregionais com elevada coerência geométrica e consistência morfológica, mesmo em cenários complexos e sob condições adversas de ruído e baixo contraste.

A formulação proposta demonstrou que a fusão entre o campo de evidência semântico e a dinâmica dos contornos ativos gera um processo de segmentação simultaneamente físico e interpretável. O campo de evidência atua como energia externa semântica, traduzindo padrões visuais complexos em forças direcionais que guiam o contorno em direção às fronteiras de interesse. Em paralelo, a modelagem paramétrica assegura suavidade, continuidade e coerência topológica, prevenindo oscilações e colapsos que frequentemente comprometem abordagens puramente supervisionadas. Essa integração entre aprendizado semântico e modelagem de contornos redefine a segmentação multirregional como um processo dinâmico, adaptativo e explicável, no qual o comportamento geométrico emerge naturalmente do equilíbrio entre as forças internas e externas do sistema.

Os experimentos confirmaram a robustez, estabilidade e interpretabilidade do modelo em diferentes contextos. Em imagens sintéticas, o SEMAC apresentou comportamento controlado e previsível, respondendo de forma coerente a ruídos, irregularidades e perturbações geométricas. Nas imagens clínicas, obteve resultados expressivos em dermatoscopia e citologia sanguínea, mantendo a fidelidade das fronteiras mesmo em regiões de baixo contraste ou de conectividade estrutural complexa. Os mapas de evolução e campos vetoriais evidenciaram a coerência energética da proposta: as forças adaptativas concentraram-se progressivamente nas regiões de fronteira até desaparecerem, marcando o instante de equilíbrio e estabilização dos contornos. Essa característica de autorregulação, observada pelo desaparecimento das setas nas iterações finais, confirma que o método atinge o equilíbrio físico-energético previsto em sua formulação.

Outro aspecto de destaque é a autonomia do processo evolutivo. O método é capaz de iniciar com um único contorno, que se propaga e se divide naturalmente conforme

a distribuição energética, gerando novos contornos que evoluem e estabilizam-se de forma independente. Essa lógica de divisão topológica e estabilização autônoma elimina a necessidade de múltiplas inicializações, permitindo lidar com estruturas complexas e interconectadas sem perda de coerência geométrica. O resultado é uma segmentação multirregional fluida, contínua e morfologicamente consistente, na qual cada fronteira se ajusta de modo inteligente à estrutura real da imagem.

O SEMAC consolida, assim, uma abordagem integrada entre aprendizado supervisionado e modelagem paramétrica do ACM, demonstrando que é possível incorporar informação semântica em modelos variacionais sem comprometer a interpretabilidade ou a estabilidade numérica. A energia externa, tradicionalmente dependente apenas de gradientes fotométricos, passa a ser representada por um campo semântico, capaz de generalizar entre diferentes domínios e de se adaptar às características particulares de cada imagem. Essa formulação resultou em um método leve, explicável e robusto, que combina o raciocínio físico da evolução de contornos com a flexibilidade do aprendizado supervisionado, oferecendo uma alternativa sólida às segmentações puramente estatísticas ou empíricas.

Apesar dos resultados promissores, o SEMAC ainda apresenta limitações inerentes à sua formulação contínua e natureza iterativa. Em situações nas quais dois ou mais objetos distintos encontram-se estruturalmente conectados por pequenas pontes ou regiões de contato, o modelo tende a interpretá-los como uma única estrutura contínua, não realizando a separação explícita entre as instâncias. Essa limitação decorre da própria coerência topológica imposta pelo campo de energia, que privilegia a regularidade geométrica e a preservação da conectividade local em detrimento da fragmentação entre regiões adjacentes. Além disso, o custo computacional tende a crescer com o número de regiões e a resolução das imagens, sugerindo a necessidade de versões paralelas e implementações otimizadas para execução em GPU. Esses aspectos, contudo, não comprometem a consistência dos resultados, mas indicam caminhos naturais para o aprimoramento futuro do modelo.

De modo geral, o SEMAC apresentou desempenho consistente, comportamento previsível e alta coerência estrutural em distintos contextos de segmentação. Sua formulação contínua e semântico-geométrica constitui uma alternativa eficaz e interpretável para problemas multirregionais em imagens naturais e biomédicas, reforçando a importância de modelos que unem aprendizado supervisionado e dinâmica física como uma direção promissora para a segmentação baseada em energia.

5.1 Trabalhos Futuros

As contribuições apresentadas neste trabalho abrem diferentes perspectivas de continuidade e aprimoramento do SEMAC. Entre as direções mais promissoras, destacam-se:

- Extensão tridimensional: desenvolvimento de uma versão 3D do SEMAC, incorporando campos de evidência volumétricos e superfícies ativas multirregionais, com o objetivo de ampliar sua aplicabilidade em imagens médicas tomográficas e micrográficas;
- Generalização para novos domínios: avaliação do método em contextos industriais, ambientais e veterinários, a fim de investigar sua capacidade de adaptação a diferentes padrões de textura, contraste e ruído, bem como sua robustez frente a condições de aquisição heterogêneas;
- Aprimoramento do controle evolutivo: implementação de estratégias de ponderação adaptativa entre as forças internas e externas, com base em propriedades locais da imagem e no estado energético do contorno, permitindo maior autonomia e estabilidade na evolução;

Essas direções representam oportunidades tanto conceituais quanto tecnológicas, capazes de expandir o escopo de aplicação do SEMAC e consolidar sua contribuição no avanço da segmentação semântica explicável e multirregional.

REFERÊNCIAS

- ALOM, M. Z.; HASAN, M.; YAKOPCIC, C.; TAHA, T. M.; ASARI, V. K. Recurrent residual convolutional neural network based on u-net (r2u-net) for medical image segmentation. **CoRR**, abs/1802.06955, 2018. Disponível em: <http://arxiv.org/abs/1802.06955>.
- BADRINARAYANAN, V.; KENDALL, A.; CIPOLLA, R. **SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation**. 2016. Disponível em: <https://arxiv.org/abs/1511.00561>.
- BAO, M.; LYU, S.; XU, Z.; ZHAO, Q.; ZENG, C.; BAI, W.; CHENG, G. **ASP-VMUNet: Atrous Shifted Parallel Vision Mamba U-Net for Skin Lesion Segmentation**. 2025. Disponível em: <https://arxiv.org/abs/2503.19427>.
- BEUCHER, S.; MEYER, F. The morphological approach to segmentation: The watershed transformation. *In*: DOUGHERTY, E. R. (Ed.). **Mathematical Morphology in Image Processing**. New York: Marcel Dekker Inc., 1993. p. 433–481.
- BOYLE, P.; DORÉ, J. F.; AUTIER, P.; RINGBORG, U. Cancer of the skin: a forgotten problem in europe. **Annals of Oncology**, v. 15, n. 1, p. 5–6, jan. 2004.
- CANNY, J. A computational approach to edge detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, PAMI-8, n. 6, p. 679–698, 1986.
- CASELLES, V.; KIMMEL, R.; SAPIRO, G. Geodesic active contours. **International Journal of Computer Vision**, Springer, v. 22, n. 1, p. 61–79, 1997.
- CHAN, T. F.; VESE, L. A. Active contours without edges. **IEEE Transactions on Image Processing**, IEEE, v. 10, n. 2, p. 266–277, 2001.
- CHEN, L.-C.; ZHU, Y.; PAPANDREOU, G.; SCHROFF, F.; ADAM, H. Encoder-decoder with atrous separable convolution for semantic image segmentation. **Proceedings of the European Conference on Computer Vision (ECCV)**, p. 801–818, 2018.
- CHICCO, D.; JURMAN, G. The advantages of the matthews correlation coefficient (mcc) over f1 score and accuracy in binary classification evaluation. **BMC Genomics**, Springer, v. 21, n. 1, p. 6, 2020.
- COHEN, L. D. On active contour models and balloons. **CVGIP: Image Understanding**, v. 53, n. 2, p. 211–218, 1991. ISSN 1049-9660. Disponível em: <https://www.sciencedirect.com/science/article/pii/104996609190028N>.
- DEPTO, D. S.; RAHMAN, S.; HOSEN, M. M.; AKTER, M. S.; REME, T. R.; RAHMAN, A.; ZUNAIR, H.; RAHMAN, M. S.; MAHDY, M. Automatic segmentation of blood cells from microscopic slides: A comparative analysis. **Tissue and Cell**, v. 73, p. 101653, 2021. ISSN 0040-8166. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0040816621001695>.
- DICE, L. R. Measures of the amount of ecologic association between species. **Ecology**, Wiley, v. 26, n. 3, p. 297–302, 1945.
- DILDAR, M.; AKRAM, S.; IRFAN, M.; KHAN, H. U.; RAMZAN, M.; MAHMOOD, A. R.; ALSAIARI, S. A.; SAEED, A. H. M.; ALRADDADI, M. O.; MAHNASHI, M. H. Skin cancer detection: A review using deep learning techniques. **International Journal of Environmental Research and Public Health**, v. 18, n. 10, p. 5479, maio 2021.

- FILHO, P. P. R.; CORTEZ, P. C.; BARROS, A. C. D. S.; ALBUQUERQUE, V. H. C. D. Novel adaptive balloon active contour method based on internal force for image segmentation – a systematic evaluation on synthetic and real images. **Expert Systems with Applications**, v. 41, n. 17, p. 7707–7721, 2014. ISSN 0957-4174. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0957417414004114>.
- GLOROT, X.; BORDES, A.; BENGIO, Y. Deep sparse rectifier neural networks. *In: Proceedings of the 14th International Conference on Artificial Intelligence and Statistics (AISTATS)*. [S. l.: s. n.], 2011. p. 315–323.
- GONZALEZ, R. C.; WOODS, R. E. **Digital Image Processing**. New York, NY: Pearson, 2018.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. USA: MIT Press, 2016.
- HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. Upper Saddle River, NJ: Pearson, 2009.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. **Deep Residual Learning for Image Recognition**. 2015. Disponível em: <https://arxiv.org/abs/1512.03385>.
- HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. **Neural Networks**, Pergamon, v. 2, n. 5, p. 359–366, 1989.
- HUANG, Z.; DENG, H.; YIN, S.; ZHANG, T.; TANG, W.; WANG, Q. Adf-net: A novel adaptive dual-stream encoding and focal attention decoding network for skin lesion segmentation. **Biomedical Signal Processing and Control**, v. 91, p. 105895, 2024. ISSN 1746-8094. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1746809423013289>.
- KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes: Active contour models. **International Journal of Computer Vision**, ACM Journals, v. 1, n. 4, p. 321–331, 1988.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. **Communications of the ACM**, Association for Computing Machinery, v. 60, n. 6, p. 84–90, 2017.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015.
- LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, IEEE, v. 86, n. 11, p. 2278–2324, 1998.
- LEI, B.; JINMAN, K.; AHN, E.; KUMAR, A.; FENG, D.; FULHAM, M. Step-wise integration of deep class-specific learning for dermoscopic image segmentation. **Pattern Recognition**, Elsevier, v. 84, p. 63–74, 2018.
- LITJENS, G.; KOOI, T.; BEJNORDI, B. E.; SETIO, A. A. A.; CIOMPI, F.; GHAFOORIAN, M.; LAAK, J. A. van der; GINNEKEN, B. van; SÁNCHEZ, C. I. A survey on deep learning in medical image analysis. **Medical Image Analysis**, Elsevier, v. 42, p. 60–88, 2017.
- LONG, J.; SHELHAMER, E.; DARRELL, T. **Fully Convolutional Networks for Semantic Segmentation**. 2015. Disponível em: <https://arxiv.org/abs/1411.4038>.

MENDONÇA, T.; CELEBI, M.; MENDONÇA, T.; MARQUES, J. Ph2: A public database for the analysis of dermoscopic images. **Dermoscopy image analysis**, CRC Press Boca Raton, FL, USA, v. 2, 2015.

METLEK, S. Cellsegunet: an improved deep segmentation model for the cell segmentation based on unet++ and residual unet models. **Neural Computing and Applications**, v. 36, p. 5799–5825, abr. 2024.

METZ, C. E. Basic principles of roc analysis. **Seminars in Nuclear Medicine**, Elsevier, v. 8, n. 4, p. 283–298, 1978.

MINSKY, M.; PAPERT, S. **Perceptrons: An Introduction to Computational Geometry**. Expanded edition, 1988. Cambridge, MA: MIT Press, 1969.

MITTAL, H.; PANDEY, A. C.; SARASWAT, M.; KUMAR, S.; PAL, R.; MODWEL, G. A comprehensive survey of image segmentation: clustering methods, performance parameters, and benchmark datasets. **Multimedia Tools and Applications**, Springer, v. 81, n. 24, p. 35001–35026, 2022.

NAROTAMO, H.; SANCHES, J. M.; SILVEIRA, M. Segmentation of cell nuclei in fluorescence microscopy images using deep learning. *In*: MORALES, A.; FIERREZ, J.; SÁNCHEZ, J. S.; RIBEIRO, B. (Ed.). **Pattern Recognition and Image Analysis**. Cham: Springer International Publishing, 2019. p. 53–64. ISBN 978-3-030-31332-6.

NIERHAUS, A.; KLATTE, S.; LINSSEN, J.; EISMANN, N. M.; WICHMANN, D.; HEDKE, J.; BRAUNE, S. A.; KLUGE, S. Revisiting the white blood cell count: immature granulocytes count as a diagnostic marker to discriminate between SIRS and sepsis—a prospective, observational study. **BMC Immunology**, v. 14, p. 8, 2013. Disponível em: <https://doi.org/10.1186/1471-2172-14-8>.

NIXON, M.; AGUADO, A. S. **Feature Extraction & Image Processing for Computer Vision, Third Edition**. USA: Academic Press, Inc., 2012.

OBUCHOWICZ, R.; LASEK, J.; WODZIŃSKI, M.; PIÓRKOWSKI, A.; STRZELECKI, M.; NURZYŃSKA, K. Artificial intelligence-empowered radiology—current status and critical review. **Diagnostics**, MDPI, v. 15, n. 3, p. 282, 2025.

OKTAY, O.; SCHLEMPER, J.; FOLGOC, L. L.; LEE, M.; HEINRICH, M.; MISAWA, K.; MORI, K.; MCDONAGH, S.; HAMMERLA, N. Y.; KAINZ, B.; GLOCKER, B.; RUECKERT, D. Attention u-net: Learning where to look for the pancreas. *In*: **Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support**. [S. l.]: Springer International Publishing, 2018. p. 215–223. ISBN 978-3-030-00889-5.

OKUR, E.; DEEBA, F.; FU, J.; FU, Y. Hybrid deep active contour models for medical image segmentation. **Computerized Medical Imaging and Graphics**, Elsevier, v. 107, p. 102220, 2023.

OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 9, n. 1, p. 62–66, 1979.

PHAM, D. L.; XU, C.; PRINCE, J. L. Current methods in medical image segmentation. **Annual Review of Biomedical Engineering**, v. 2, p. 315–337, 2000.

- PINTO-COELHO, L. How artificial intelligence is shaping medical imaging technology: A survey of innovations and applications. **Bioengineering**, MDPI, v. 10, n. 12, 2023.
- QIU, S.; LI, C.; FENG, Y.; ZUO, S.; LIANG, H.; XU, A. Gfanet: Gated fusion attention network for skin lesion segmentation. **Computers in Biology and Medicine**, v. 155, p. 106462, 2023. ISSN 0010-4825. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0010482522011702>.
- RAHMAN, M. A.; WANG, Y. Optimizing intersection-over-union in deep neural networks for image segmentation. *In: Advances in Visual Computing - 12th International Symposium (ISVC), Las Vegas, NV, USA, December 12-14, 2016, Proceedings, Part I*. Las Vegas, NV, USA: Springer, 2016. v. 10072, p. 234–244.
- REBOUÇAS FILHO, P. P.; CORTEZ, P. C.; HOLANDA, M. A. Active contour modes crisp: new technique for segmentation the lungs in ct images. **Revista Brasileira de Engenharia Biomédica**, Sociedade Brasileira de Engenharia Biomédica, v. 27, n. 4, 2011.
- REBOUÇAS, E. de S.; de Medeiros, F. N. S.; MARQUES, R. C. P.; CHAGAS, J. V. S.; GUIMARÃES, M. T.; SANTOS, L. O.; MEDEIROS, A. G.; PEIXOTO, S. A. Level set approach based on parzen window and floor of log for edge computing object segmentation in digital images. **Applied Soft Computing**, v. 105, p. 107273, 2021. ISSN 1568-4946. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1568494621001964>.
- RONG, J.; LIU, Y. Advances in medical imaging techniques. **BMC Methods**, BioMed Central, v. 1, n. 1, p. 10, 2024.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. *In: SPRINGER. Medical Image Computing and Computer-Assisted Intervention (MICCAI)*. [S. l.], 2015. p. 234–241.
- ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, p. 386–408, 1958.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, v. 323, n. 6088, p. 533–536, oct 1986. Disponível em: <https://doi.org/10.1038/323533a0>.
- SCHADENDORF, D.; AKKOOI, A. C. J. van; BERKING, C.; GRIEWANK, K. G.; GUTZMER, R.; HAUSCHILD, A.; STANG, A.; ROESCH, A.; UGUREL, S. Melanoma. **The Lancet**, v. 392, n. 10151, p. 971–984, set. 2018. Erratum in: *The Lancet*. 2019 Feb 23;393(10173):746. doi: 10.1016/S0140-6736(19)30361-7.
- SERRA, J. **Image Analysis and Mathematical Morphology**. London: Academic Press, 1982. ISBN 9780126372403.
- SINGHA, A.; BHOWMIK, M. K. Alexsegnet: an accurate nuclei segmentation deep learning model in microscopic images for diagnosis of cancer. **Multimedia Tools Appl.**, Kluwer Academic Publishers, USA, v. 82, n. 13, p. 20431–20452, dez. 2022. ISSN 1380-7501. Disponível em: <https://doi.org/10.1007/s11042-022-14098-y>.
- SZEGEDY, C.; LIU, W.; JIA, Y.; SERMANET, P.; REED, S.; ANGUELOV, D.; ERHAN, D.; VANHOUCHE, V.; RABINOVICH, A. Going deeper with convolutions . *In: 2015*

IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Los Alamitos, CA, USA: IEEE Computer Society, 2015. p. 1–9. ISSN 1063-6919. Disponível em: <https://doi.ieeecomputersociety.org/10.1109/CVPR.2015.7298594>.

TOPTAŞ, M.; HANBAY, D. Mikroskopik kan hücre görüntülerinin güncel derin Öğrenme mimarileri ile bölütlemesisegmentation of microscopic blood cell images with current deep learning architectures. **Mühendislik Bilimleri ve Araştırmaları Dergisi**, v. 5, 04 2023.

TSCHANDL, P.; ROSENDAHL, C.; KITTLER, H. The ham10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. **Scientific Data**, v. 5, p. 180161, 2018.

VASCONCELOS, F. X.; MEDEIROS, A.; PEIXOTO, S.; FILHO, P. P. Automatic skin lesions segmentation based on a new morphological approach via geodesic active contour. **Cognitive Systems Research**, v. 55, 12 2018.

WU, H.; CHEN, S.; CHEN, G.; WANG, W.; LEI, B.; WEN, Z. Fat-net: Feature adaptive transformers for automated skin lesion segmentation. **Medical Image Analysis**, v. 76, p. 102327, 2022. ISSN 1361-8415. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1361841521003728>.

YU, Y.; WANG, C.; FU, Q.; KOU, R.; HUANG, F.; YANG, B.; YANG, T.; GAO, M. Techniques and challenges of image segmentation: A review. **Electronics**, v. 12, n. 5, 2023.

ZHOU, Z.; SIDDIQUEE, M. M. R.; TAJBAKSH, N.; LIANG, J. Unet++: A nested u-net architecture for medical image segmentation. *In*: STOYANOV, D.; TAYLOR, Z.; CARNEIRO, G.; SYEDA-MAHMOOD, T.; MARTEL, A.; MAIER-HEIN, L.; TAVARES, J. M. R.; BRADLEY, A.; PAPA, J. P.; BELAGIANNIS, V.; NASCIMENTO, J. C.; LU, Z.; CONJETI, S.; MORADI, M.; GREENSPAN, H.; MADABHUSHI, A. (Ed.). **Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support**. Cham: Springer International Publishing, 2018. p. 3–11. ISBN 978-3-030-00889-5.

ZOU, K. H.; WARFIELD, S. K.; BHARATHA, A.; TEMPANY, C. M.; KAUS, M. R.; HAKER, S. J.; WELLS, W. M.; JOLESZ, F. A.; KIKINIS, R. Statistical validation of image segmentation quality based on a spatial overlap index: scientific reports. **Academic Radiology**, Elsevier, v. 11, n. 2, p. 178–189, 2004.