



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

LUÍS FABRÍCIO DE FREITAS SOUZA

DIVISIBLE CELL-SEGMENTATION: UMA NOVA ABORDAGEM FINE-TUNING
ADAPTATIVA PARA SEGMENTAÇÃO EM TOMOGRAFIAS COMPUTADORIZADAS
POR MEIO DE CÉLULAS COMPUTACIONAIS SINTÉTICAS

FORTALEZA

2023

LUÍS FABRÍCIO DE FREITAS SOUZA

DIVISIBLE CELL-SEGMENTATION: UMA NOVA ABORDAGEM *FINE-TUNING*
ADAPTATIVA PARA SEGMENTAÇÃO EM TOMOGRAFIAS COMPUTADORIZADAS POR
MEIO DE CÉLULAS COMPUTACIONAIS SINTÉTICAS

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

FORTALEZA

2023

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)

- D32d de Freitas Souza, Luís Fabrício.
Divisible Cell-Segmentation: Uma Nova Abordagem Fine-Tuning Adaptativa para Segmentação em Tomografias Computadorizadas por meio de Células Computacionais Sintéticas / Luís Fabrício de Freitas Souza. – 2023.
134 f. : il. color.
- Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia de Teleinformática, Fortaleza, 2023.
Orientação: Prof. Dr. Pedro Pedrosa Rebouças Filho.
1. AVC Hemorrágico. 2. Imagens Pulmonares. 3. Tomografia Computadorizada. 4. Segmentação adaptativa Divisible Cell-Segmentation. I. Título.

CDD 621.38

LUÍS FABRÍCIO DE FREITAS SOUZA

DIVISIBLE CELL-SEGMENTATION: UMA NOVA ABORDAGEM FINE-TUNING
ADAPTATIVA PARA SEGMENTAÇÃO EM TOMOGRAFIAS COMPUTADORIZADAS POR
MEIO DE CÉLULAS COMPUTACIONAIS SINTÉTICAS

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

Avaliado em:

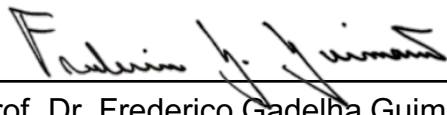
BANCA EXAMINADORA



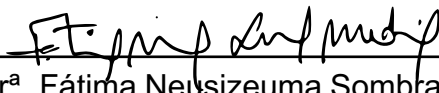
Prof. Dr. Pedro Pedrosa Rebouças Filho (Orientador)
Universidade Federal do Ceará (UFC)



Prof. Dr. Rodrigo de Melo Souza Veras
Universidade Federal do Piauí (UFPI)



Prof. Dr. Frederico Gadelha Guimarães
Universidade Federal de Minas Gerais (UFMG)



Prof. Dr.ª Fátima Neusizeuma Sombra de Medeiros
Universidade Federal do Ceará (UFC)

Documento assinado digitalmente



FABRÍCIO GONZALEZ NOGUEIRA

Data: 11/04/2023 17:46:54-0300

Verifique em <https://validar.itl.gov.br>

Prof. Dr. Fabrício Gonzalez Nogueira
Universidade Federal do Ceará (UFC)

Aos meus pais, pela luta e dedicação em prol da minha educação e formação humana. A minha esposa por todo apoio, dedicação e carinho, e ao meu filho que me inspira a cada dia em ACREDITAR no possível, e que há ESPERANÇA no mundo. Grato a todos!

AGRADECIMENTOS

Durante grande parte de minha vida, muitas pessoas foram fundamentais no processo de formação profissional. Mas foi com base na formação humana onde pude sentir o alicerce dos grandes passos a serem dados na vida, foi no lar de minha casa onde tudo iniciou e permanece com os principais aspectos humanos da vida; o amor, o carinho, o respeito e os valores humanos (a honestidade, a humildade, a empatia, a solidariedade, a ética e o senso de justiça). Tal formação, foi a chave de todo esforço diário e persistência.

Após mencionar todos estes aspectos que me ajudaram no caminhar na jornada da vida, gostaria de agradecer a Deus pelos caminhos guiados, pela lutas vencidas e pelas batalhas que me fizeram crescer e me fortalecer. Grato pelas bênçãos, pelas conquistas, e muito mais pela minha família.

Gostaria de agradecer aos meus pais, que foram base fundamental em todo o processo de minha vida. Ao meu pai, Sr. Luiz Antônio Marçal de Souza, que é exemplo como pai, formador de pilar de proteção e carinho. Agradecer a minha mãe, mulher de garra e de luta, que nunca me deixou desistir de meus objetivos, grato por todo carinho e atenção. Grato a minha família, que foi base para minha formação humana e educacional.

Em especial, à minha esposa, amiga e namorada, Camila Maria Cunha de Souza Freitas, pelo carinho, paciência e amor de sempre. Foi com seu apoio onde busquei impulso para alcançar os meus sonhos, bem como os objetivos de vida. Grato pro sua vida, por nossa história. Gostaria de agradecer meu filho, Bernardo Luís Cunha de Souza Freitas, que me ensinou que o amor é transformador e que pode ser personificado.

Gostaria de agradecer ao Prof^o. Dr. Pedro Pedrosa Rebouças Filho, pela orientação, dedicação, incentivo e paciência. Grato por todo apoio e atenção, quem o conhece sabe o quanto é comprometido naquilo que acredita. Grato ao laboratório LAPISCO-Laboratório de Processamento de Imagem, Sinais e Computação Aplicada, por todo o apoio acadêmico e jornada durante o doutorado. Grato a minha banca de defesa pela disponibilidade e contribuições.

Aos meus colegas de pesquisa: Adriell Gomes, José Jerovane, Matheus Santos, Guilherme Brilhante, Lucas Silva, Solon Alves, Aldísio e Yasmim Rodrigues, pelo apoio e participação em diferentes pesquisas durante o período do doutorado. Suas contribuições foram valiosas em minha jornada acadêmica.

Meus sinceros agradecimentos!

"A persistência é o menor caminho do êxito!"

(Charles Chaplin)

RESUMO

Segundo a Organização Mundial da Saúde (OMS), diversas patologias são fatores da causa de milhões de mortes por ano no mundo, mortes como a de Acidente Vascular Cerebral (AVC) e doenças pulmonares. Com o objetivo de otimizar e facilitar o processo de detecção e segmentação da região em imagens médicas, os sistemas de auxílio ao diagnóstico computadorizado *Computer Aided Diagnosis* (CAD) estão sendo cada vez mais utilizados, aumentando a segurança dos diagnósticos e o desempenho dos especialistas. O estudo desta tese tem como objetivo, apresentar uma nova abordagem para segmentação e inicialização automática em imagens de Tomografia Computadorizadas (TCs) de AVC hemorrágico e TCs pulmonares, o experimento utilizou 100 imagens de TCs de AVC hemorrágico e 1.265 pulmonares, com 80% para treinamento e 20% para testes, realizados teste de validação cruzadas com 3 *k-folds*. O estudo propõe um novo método eficaz totalmente automático e adaptativo para segmentação, denominado *Divisible Cell-Segmentation*. O método proposto é uma nova abordagem eficaz baseado na inicialização automática para detecção e segmentação da região de interesse, onde células computacionais sintéticas capazes de se dividirem (multiplicarem) com o objetivo de encontrar as bordas do objeto de interesse, segmentam com eficácia e precisão as regiões de contorno em imagens médicas de TCs. Os experimentos obtiveram grande eficácia em segmentar as regiões nas mais diferentes imagens médicas, obtendo 99.80% de acurácia para segmentação em AVC hemorrágico, com 99.81% de Especificidade (ESP), demonstrado eficácia na segmentação nas diferentes TCs cerebrais. Para imagens pulmonares, o método proposto obteve 99.01% de acurácia, sendo capaz de identificar diferentes regiões pulmonares e suas estruturas pulmonares. Assim com no AVC hemorrágico, a segmentação nas imagens de pulmão obtiveram resultados relevantes com 99.28% de ESP, demonstrando a robustez do novo método com o tempo médio de segmentação de 1.89 segundo para as imagens de Tomografia Computadorizada (TC) de AVC e 2.03 para TC pulmonar. A fim de validar os experimentos, os resultados foram comparados à diferentes métodos encontrados no estado da arte, superando assim conceituados modelos computacionais de segmentação da literatura; não automáticos, semiautomáticos e automáticos, equiparando-se a métodos consolidados do estado da arte em tempo de segmentação bem como na eficácia nos resultados de segmentação.

Palavras-chave: AVC hemorrágico; imagens pulmonares; tomografia computadorizada; segmentação adaptativa *divisible cell-segmentation*.

ABSTRACT

According to the World Health Organization (WHO), various pathologies are factors causing millions of deaths per year worldwide, such as stroke and lung diseases. In order to optimize and facilitate the process of detection and segmentation of regions in medical images, computer-aided diagnosis (CAD) systems are being increasingly used, increasing the safety of diagnoses and the performance of specialists. The aim of this thesis study is to present a new approach for segmentation and automatic initialization in CT images of hemorrhagic stroke and pulmonary CTs. The experiment used 100 images of CTs of hemorrhagic stroke and 1,265 pulmonary CTs, with 80% for training and 20% for testing, and performed cross-validation tests with 3 k-folds. The study proposes a new effective and fully automatic adaptive method for segmentation, called Divisible Cell-Segmentation. The proposed method is an effective new approach based on automatic initialization for detecting and segmenting the region of interest, where synthetic computational cells capable of dividing (multiplying) to find the edges of the object of interest effectively and accurately segment the contour regions in medical images of CTs. The experiments achieved great efficacy in segmenting regions in various medical images, obtaining 99.80% accuracy for segmentation in hemorrhagic stroke, with 99.81% sensitivity, demonstrating efficacy in segmentation in different cerebral CTs. For pulmonary images, the proposed method achieved 99.01% accuracy, being able to identify different pulmonary regions and their structures. As in hemorrhagic stroke, segmentation in lung images obtained relevant results with 99.28% sensitivity, demonstrating the robustness of the new method with an average segmentation time of 1.89 seconds for CT images of stroke and 2.03 for pulmonary CTs. In order to validate the experiments, the results were compared to different methods found in the state of the art, thus surpassing renowned computational segmentation models in the literature; non-automatic, semi-automatic and automatic, equaling to consolidated state-of-the-art methods in segmentation time as well as in segmentation result efficacy.

Keywords: hemorrhagic stroke; pulmonary images; computed tomography; adaptive segmentation *divisible cell-segmentation*.

LISTA DE FIGURAS

Figura 1 –	Imagens de diferentes fatias de TC de lesão cerebral por AVC Hemorrágico. É possível identificar as variações de textura e área da região do AVC, que se modificam de acordo com a fatia do exame, e a região de sangue coagulado na massa cerebral.	27
Figura 2 –	Imagens de diferentes fatias de TC de tórax, com diferentes formas e tamanhos de estruturas do pulmão. O pulmão tem sua área modificada de acordo com a fatia do exame, baseado no ciclo respiratório do paciente no momento da captura das imagens. Algumas imagens apresentam patologias no pulmão do paciente causando diferentes texturas de anormalidades internas.	28
Figura 3 –	Ilustração representativa distinguindo os dois tipos de AVCs: Acidente Vascular Cerebral Isquêmico (AVCi) e do Acidente Vascular Cerebral Hemorrágico (AVCh).	42
Figura 4 –	Representação ilustrativa de possíveis problemas de saúde pulmonar em humanos.	43
Figura 5 –	Ilustração de machine learning e suas aplicações.	47
Figura 6 –	Ilustração de diferentes camadas encarregadas em um processo de convolucional em uma rede.	50
Figura 7 –	Representação da arquitetura da <i>Detectron2, framework</i> para detecção de objetos usada neste estudo.	52
Figura 8 –	Ilustração da interpretação da equação Polar da Reta, na qual ρ representa a distância da linha perpendicular que liga a respectiva reta à origem do plano, e θ representa o ângulo da reta em relação à origem do plano, dessa forma, com ambos os parâmetros, é possível localizar qualquer reta existente no plano.	53
Figura 9 –	Figura com a representação das retas passando por todos os <i>thetas</i>	53
Figura 10 –	Representação dos pontos localizados no plano da imagem, na qual os pontos enumerados de 1 à 4, corresponde as senoides também enumeradas no plano da imagem, cujos parâmetros são ρ e θ	53
Figura 11 –	Processo de detecção da reta que conecta os pontos alinhados, na qual a mesma se manifesta no plano de parâmetros na forma de ponto, com coordenadas ρ e θ	54

Figura 12 – Ilustração do método proposto. Em (A) abordagem do treinamento para detecção da região de interesse, pela abordagem da inicialização automática inteligente. Etapa 2(B), Inicialização Automática, que tem como finalidade detectar a região a ser segmentada, Etapa 3 (C) Segmentação - Método <i>Divisible Cell-Segmentation</i> . E na Etapa 4 (D), ilustra o resultado final da segmentação pelo Método <i>Divisible Cell-Segmentation</i>	57
Figura 13 – Etapa de escolha do extrator de características (<i>ResNet</i>) bem como aplicação do processo <i>Feature Pyramid Network</i> (FPN), que gera em conjunto com o extrator, um mapa de características extraídas de cada imagem médica. . . .	58
Figura 14 – Aplicação do processo de <i>Region Proposal Network</i> (RPN) no mapa de características extraídas e geradas no processo A2 para gerar possíveis regiões que podem ou não ser as áreas de interesse.	60
Figura 15 – Aplicação do processo <i>ROI Pooling</i> , que une a saída do processo da Figura 14 Etapa A3 com a imagem de entrada em cada nova dimensão. A imagem de entrada é redimensionada pelo processo FPN, que pode ser visto na Etapa A2.	61
Figura 16 – Aplicação do processo de ROI Heads que consiste em duas etapas: Aplicação de um regressor, que é responsável por reduzir a imagem de entrada para o padrão que a rede de classificação recebe. Aplicação do classificador para atribuir às marcações obtidas na Etapa A3 da referida figura.	62
Figura 17 – Processo de divisão da imagem em quadrantes. Processo recursivo na qual realizada a parada quando um ponto $P_i(x,y)$ é encontrado, obedecendo aos critérios estabelecidos na Equação 3.10	65
Figura 18 – Representação da área (mapa de limiar) a ser calculada pelo gerando o <i>threshold</i> para parâmetro de parada celular.	67
Figura 19 – Demonstração do processo de criação do mapa do limiar, com a aplicação do gradiente morfológico sobre a imagem do exame, onde será extraída o <i>threshold</i> sendo o valor médio do limiar, para o parâmetro de parada condicional da célula sintética.	69

- Figura 20 – Representação em escala de uma célula computacional sintética, representando seus parâmetros internos. Em $B1_I$ é possível notar a região de interesse com as células computacionais sintéticas iniciais, em $B1_{II}$, as células computacionais sintéticas iniciais tem sua escala ampliada para ilustrar os parâmetros de função, e Em $B1_{III}$, tem-se a ilustração da ampliação de uma única célula computacional sintética inicial, com seus respectivos parâmetros de função, isto é V_D , D_C e V_L 71
- Figura 21 – Processo de região de movimentação das células computacionais sintéticas, na qual cada célula tem sua direção e sentido indicado pelo variante de direção de acordo com o seu respectivo índice. Em $B1^{IIII}$ é possível visualizar o objeto de interesse definido e a aplicação das células computacionais sintéticas iniciais. Em $B1^{IIII}$ está destacada a visualização ampliada das células computacionais sintéticas na matriz, composta por 8 células iniciais. Em $B1^{IIIII}$ está a representação da região variante de direção V_D a ser percorrido na imagem. 72
- Figura 22 – Imagem da aplicação do método *Divisible Cell-Segmentation*, onde as células sintéticas computacionais são inseridas nas respectivas imagens de TC de pulmão e AVC com base no parâmetro, gerado na etapa 3.1.7 (A6) pela inicialização automática adaptativa. 73
- Figura 23 – Representação da aplicação e multiplicação do método proposto *Divisible Cell-Segmentation*, na qual a imagem em $B2^I$ ilustra o centroide da *Bounding Box*, cujas células sintéticas computacionais c_i com seus respectivos V_D^* . A imagem $B2^{II}$ ilustra o perímetro total, com uma angulação simétrica entre as mesmas de $\frac{2\pi}{8}$. Na imagem $B2^{III}$ está a combinação de ambas. Já Na imagem $B2^{IIII}$, é representado o processo de divisão celular computacional. 75
- Figura 24 – Representação da Divisão celular de uma célula sintética computacional inicial, na qual o processo de divisão gera duas novas células, cujos ângulos das respectivas variantes de direção se dão $\pm \frac{2\pi}{8}$ em relação à célula mãe. (Fonte: Autor) 75
- Figura 25 – Imagem da aplicação do método, *Divisible Cell-Segmentation* onde as células sintéticas computacionais iniciaram o processo de movimentação de acordo com o respectivo v_D^* 76

Figura 26 – Imagem da aplicação do método, <i>Divisible Cell-Segmentation</i> onde as células sintéticas computacionais iniciaram o processo de divisão de acordo com os parâmetros de divisão adaptativos pela inicialização automática adaptativa.	76
Figura 27 – Processo de divisão realizado pelas células sintéticas computacionais. Na imagem $B4^I$ representa o processo de divisão celular que vai acontecendo à medida que a célula avança no plano da imagem, as setas indicam a direção a ser seguida pelas células até que as mesmas alcancem as bordas da região de interesse. Note que o ângulo entre as células é constante, de $\frac{2\pi}{8}$. Já em $B4^{II}$ está ilustrado o processo de parada das células sintéticas computacionais, na qual ao detectarem a região de interesse, começam a se aglomerar de maneira a demarcar toda a borda fechada da região de interesse.	78
Figura 28 – Imagem da aplicação do método, <i>Divisible Cell-Segmentation</i> para imagem de TC de pulmão e AVC, onde as células sintéticas computacionais localizadas no limite da borda da região de interesse encontraram o parâmetro de paradas de divisão adaptativos.	79
Figura 29 – Processo de criação de uma nova imagem com base no centroide das células computacionais sintéticas localizadas nas bordas da região de interesse. A imagem resultante consiste na binarização das células computacionais de maneira a demarcar, com um conjunto de células, as bordas da região de interesse.	79
Figura 30 – Processo de conexão entre as regiões centrais das células computacionais localizadas na borda da região de interesse. Na imagem ilustrada em (A), é realizada a convolução da imagem binária na busca de <i>pixels</i> com nível de cinza diferente de zero. Quando encontrado o centro da célula computacional sintética, é iniciado o processo descrito pelas imagens B até (G), cujo ângulo da reta θ oscila de 0-360 para cada <i>pixel</i> encontrado na imagem binária. Desta forma, o plano de parâmetros da imagem é criado, e as retas que conectam os centros celulares são definidas.	80
Figura 31 – Demonstração do processo realizado pelo acumulador na qual demarca os pontos representados pelas células computacionais em um plano, demarcando retas sobre cada célula computacional sintética.	80

Figura 32 – Método proposto, <i>Divisible Cell-Segmentation</i> sobre a Figura geométrica. Cada imagem na figura ocorre o avanço e divisão das células computacionais sintéticas, que se movem até detectar as regiões de borda do objeto, e assim, com a conexão celular onde delimita a máscara binária do objeto em questão na imagem, segmentada. A imagem tem dimensões de 1421 <i>pixels</i> de largura por 981 <i>pixels</i> de altura.	86
Figura 33 – Resultado visual gerado pelos ensaios experimentais do método <i>Divisible Cell-Segmentation</i>	87
Figura 34 – Resultado da inicialização automática inteligente que tem como abordagem a detecção da região do AVC hemorrágico para segmentação em diferentes imagens de TCs cerebrais. Na coluna (A) são apresentados as TCs, na coluna (B) são apresentados resultados da detecção da região das bordas da lesão do AVC hemorrágico.	90
Figura 35 – Ilustração dos resultados obtidos com a segmentação automática de AVC Hemorrágico - Método <i>Divisible Cell-Segmentation</i>	92
Figura 36 – Resultado da segmentação do AVC hemorrágico em diferentes momentos, de forma gradual, usando o novo método <i>Divisible Cell-Segmentation</i> baseado em células computacionais sintéticas. Na imagem é ilustrado o resultado de método de segmentação, onde é iniciado o processo de inserção das células no centroide da região de interesse, processo de divisão celular e encontro bordas do AVC.	94
Figura 37 – Resultado da segmentação com uso do método <i>Divisible Cell-Segmentation</i> em diferentes imagens pulmonares em TCs. A imagem apresentada resultados da segmentação da região das bordas dos AVCs hemorrágicos uso do método proposto.	95
Figura 38 – Métricas de desempenho obtidas com o método proposto <i>Divisible Cell-Segmentation</i> e outros métodos encontrados e analisados na literatura com os métodos de (XU <i>et al.</i> , 2020).	101
Figura 39 – Métricas de False Positive Rate (FPR) obtidas com o método proposto <i>Divisible Cell-Segmentation</i> e outros métodos encontrados e analisados na literatura com os métodos de (XU <i>et al.</i> , 2020).	101

Figura 40 – Métricas de desempenho obtidas com o método proposto <i>Divisible Cell-Segmentation</i> e outros métodos encontrados e analisados na literatura com os métodos de (MARQUES <i>et al.</i> , 2022).	102
Figura 41 – Ilustração dos valores métricos obtidos referente a inicialização inteligente para detecção da região pulmonar baseado na inicialização automática para detecção da região pulmonar.	105
Figura 42 – Resultado da inicialização inteligente para detecção da região pulmonar em imagens de TCs. As regiões detectadas apresentam a sobreposição por meio de <i>bounding box</i> , uma espécie de caixa delimitadora demarcando a área limite dos Pulmões.	107
Figura 43 – Ilustração dos valores métricos obtidos referente a segmentação da região pulmonar com uso do método <i>Divisible Cell-Segmentation</i> referente a Tabela 8.	108
Figura 44 – Segmentação pulmonar em imagem de TC realizada pelo método <i>Divisible Cell-Segmentation</i> . Ao longo das imagens, é possível observar a evolução da movimentação das células computacionais sintéticas, além da sua divisão, de forma a detectar as bordas dos pulmões. Na última imagem, encontra-se o resultado da segmentação dos pulmões com uso do método após a etapa de conexão entre os pontos centrais de cada célula na borda do pulmão.	110
Figura 45 – Resultado da segmentação com uso do método <i>Divisible Cell-Segmentation</i> em diferentes imagens pulmonares em TCs. Na coluna (a) são apresentadas as TCs, e na coluna (B) são apresentados os resultados da segmentação da região das bordas pulmonares com uso do método proposto.	111
Figura 46 – Ilustração dos valores métricos obtidos referente a segmentação da região pulmonar com uso do método <i>Divisible Cell-Segmentation</i> referente a Tabela 8.	116

LISTA DE TABELAS

Tabela 1 – Resultados obtidos pela inicialização automática inteligente, realizadas pela nova abordagem do método proposto para segmentação do AVC Hemorrágico em imagens de TC - Método <i>Divisible Cell-Segmentation</i>	89
Tabela 2 – Resultados obtidos pelo método proposto (<i>Divisible Cell-Segmentation</i>) para a segmentação de imagens de AVC Hemorrágico em imagens de TC	91
Tabela 3 – Comparação entre o método proposto (<i>Divisible Cell-Segmentation</i>) e métodos com diferentes abordagens para segmentação de AVC hemorrágico.	97
Tabela 4 – Comparação dos resultados obtidos na segmentação do AVC Hemorrágico nas imagens de TC propostas por este estudo <i>Divisible Cell-Segmentation</i> , em comparação com os resultados de Xu <i>et al.</i> (2020) com a rede <i>Mask R-CNN</i>	100
Tabela 5 – Comparação dos resultados obtidos na segmentação do AVC Hemorrágico nas imagens de TC propostas por este estudo, em comparação com os resultados de (MARQUES <i>et al.</i> , 2022) com a rede <i>Mask R-CNN</i> e <i>fine-tuning</i>	102
Tabela 6 – Comparação do tempo de segmentação entre o método proposto e os métodos comparados nesta seção.	103
Tabela 7 – Resultados gerados pela abordagem com inicialização inteligente para detecção da região pulmonar em imagens de TCs.	104
Tabela 8 – Resultados gerados pelo Método <i>Divisible Cell-Segmentation</i> para segmentação de pulmões em imagens de TCs.	108
Tabela 9 – Tempo de segmentação médio do método proposto <i>Divisible Cell-Segmentation</i> para a segmentação de pulmonar em imagens de TC.	109
Tabela 10 – Comparação da segmentação pulmonar entre os métodos FPLS, VFC, GVF, THR mod, THR multi, NBLS, MLS, FGAC, OPS-Euclidean, SISDEP, CRISP e CRAD.	113
Tabela 11 – Tempo médio de segmentação do <i>Divisible Cell-Segmentation</i> em relação a outros métodos.	114
Tabela 12 – Comparação do método proposto, a métodos com abordagem <i>deep learning</i> e <i>fine-tuning</i> para segmentação pulmonar.	115
Tabela 13 – Tempo médio de segmentação do <i>Divisible Cell-Segmentation</i> em relação aos métodos baseados em <i>deep learning</i> e <i>fine-tuning</i> para segmentação pulmonar	116

Tabela 14 – Tabela de teste estatístico de Kolmogorov-Smirnov realizada nos resultados métricos dos métodos utilizados na segmentação de imagens de pulmão de TC, sendo essas técnicas, o método proposto <i>Divisible Cell-Segmentation</i> e os métodos desenvolvidos por Hu <i>et al.</i> (2020): Detectron- $f\lambda$, Detectron- $f\delta$ e Detectron- $f\mu$	117
Tabela 15 – Comparação entre os resultados do método proposto <i>Divisible Cell-Segmentation</i> para as bases de TC de cérebro e TC de pulmão. Na tabela, é possível analisar os resultados da abordagem de inicialização inteligente para detecção e segmentação das regiões de interesse.	119
Tabela 16 – Comparação do tempo de segmentação entre as diferentes abordagens obtidas pelo método proposto <i>Divisible Cell-Segmentation</i>	121

LISTA DE ABREVIATURAS E SIGLAS

ACC	Acurácia
Ada-MGAC	Adaptive Morphological Geodesic Active Contour
AG	Algoritmo Genético
AVC	Acidente Vascular Cerebral
AVCh	Acidente Vascular Cerebral Hemorrágico
AVCi	Acidente Vascular Cerebral Isquêmico
CAD	<i>Computer Aided Diagnosis</i>
CCV	Convolução de Campo Vetorial
CNN	<i>Convolutional Neural Networks</i>
CNNs	Redes Neurais Convolucionais
CR	Crescimento de Região
DICOM	<i>Digital Imaging and Communications in Medicine</i>
ESP	Especificidade
FCM	<i>Fuzzy-C means</i>
FGAC	<i>Morphological Geodesic Active Contour</i>
FLPS	FLog Parzen Level Set
FPLS	FLog Parzen Level Set
FPN	<i>Feature Pyramid Network</i>
FPR	False Positive Rate
FVG	Fluxo Vetorial Gradiente
GFV	gradient vector flow
GPUs	<i>Graphics processing units</i>
HTSCS	Health-of-Things System for the Classification and Segmentation of Medical Images
IA	Inteligência Artificial
IRM	Imagem por Ressonância Magnética
JAC	índice Jaccard
KNN	<i>k-Nearest Neighbor</i>
LSCPM	<i>Level set based on the Method of Coherent Propagation</i>
LSDRC evol	evolução do level set baseado nas densidades radiológicas do crânio
LSFCM evol	evolução do level set baseado no algoritmo Fuzzy C-means

LSFCM parzen	Level set utilizando Fuzzy C-means combinado com a Janela de Parzen
MGAC	Morphological Geodesic Active Contour
MLP	<i>Multilayer Perceptron</i>
MLPs	<i>Multilayer Perceptrons</i>
NPV	<i>Negative Predictive Value</i>
OPS	<i>Optimum Path Snakes</i>
PDI	Processamento Digital de Imagens
PH	<i>Personalized Healthcare</i>
PPV	<i>Negative Predictive Value</i>
PRELU	Parametric Rectified Linear Unit
RM	Ressonância Magnética
RMs	Ressonâncias Magnéticas
RNA	Rede Neural Artificial
RNAs	Redes Neurais Artificiais
RNNs	<i>Recurrent Neural Networks</i>
ROI	<i>Region of Interest</i>
ROIs	<i>Regions of Interest</i>
RPN	<i>Region Proposal Network</i>
SAR	Synthetic aperture radar
SDEP	<i>Computational Vision System for Detection and Quantification of the Pulmonary Emphysema</i>
SEN	Sensitividade
SLIC	<i>Simple Linear Iterative Clustering</i>
SRAG	Síndrome Respiratória Aguda Grave
TC	Tomografia Computadorizada
TCDF	Computadorizada de Dupla Fonte
TCs	Tomografia Computadorizadas
UH	Unidades Hounsfield
VD	Variante de Direção
VFC	vector field convolution
YOLO	You Only Look Once

SUMÁRIO

1	INTRODUÇÃO	22
1.1	Contextualização	22
1.2	Motivação	25
1.3	Descrição do problema	26
<i>1.3.1</i>	<i>AVC hemorrágico - TCs</i>	<i>27</i>
<i>1.3.2</i>	<i>Pulmões - TCs</i>	<i>27</i>
1.4	Estado da Arte	28
1.5	Objetivos	35
<i>1.5.1</i>	<i>Objetivo Geral</i>	<i>35</i>
<i>1.5.2</i>	<i>Objetivos Específicos</i>	<i>35</i>
1.6	Contribuições	36
1.7	Produção Científica	36
1.8	Organização da Tese	39
2	FUNDAMENTAÇÃO TEÓRICA	41
2.1	Revisão clínica das doenças abordadas	41
<i>2.1.1</i>	<i>Acidente Vascular Cerebral</i>	<i>41</i>
<i>2.1.2</i>	<i>Doenças Pulmonares</i>	<i>43</i>
2.2	Tomografia Computadorizada - TC	45
2.3	Reconhecimento de Padrões	46
2.4	Machine Learning	47
2.5	Redes Neurais Artificiais	48
2.6	Deep Learning	49
2.7	Framework Detectron2	50
2.8	Transformada de Hough	51
2.9	Aquisição de Imagens Médicas	54
<i>2.9.1</i>	<i>Dataset AVC Hemorrágico</i>	<i>54</i>
<i>2.9.2</i>	<i>Dataset Pulmonar</i>	<i>55</i>
2.10	Considerações Finais Seção:	55
3	METODOLOGIA	56

3.1	Etapa 1 (A): Inicialização Automática adaptativa: Abordagem em Imagens Médicas	56
3.1.1	<i>Etapa 1 (A1): Uso de Imagens Médicas de TC e AVC</i>	56
3.1.2	<i>Etapa 1 (A2): e FPN</i>	58
3.1.3	<i>Etapa 1 (A3): RPN</i>	60
3.1.4	<i>Etapa 1 (A4): Combinação de Region of Interest (ROI)</i>	61
3.1.5	<i>Etapa 1 (A5): ROI Head ou Box Head</i>	62
3.1.6	<i>Etapa 1 (A6): Geração de Parâmetros da Aplicação Celular</i>	64
3.1.7	<i>Etapa 1 (A7): Geração de Parâmetros de Parada Celular Adaptativo</i>	67
3.2	Etapa 2 (B): Segmentação — Método <i>Divisible Cell-Segmentation</i>	70
3.2.1	<i>Etapa 2 (B1) - Aplicação Celular (Célula Computacional Sintética)</i>	70
3.2.2	<i>Etapa 2 (B2) — Movimentação e Divisão Celular — (Célula Computacional Sintética)</i>	73
3.2.3	<i>Etapa 2 (B3) — Segmentação (Parâmetro de Parada)</i>	76
3.2.4	<i>Etapa 2 (B4) - Segmentação (Conexões via células Computacionais Sintéticas)</i>	79
3.3	Métricas de Avaliação	81
3.4	Considerações Finais	84
4	EXPERIMENTOS, RESULTADOS E DISCUSSÃO	85
4.1	Ensaio Experimental — Método <i>Divisible Cell-Segmentation</i>	85
4.2	Configurações e Parâmetros	86
4.3	Resultados — Segmentação em Imagens Médicas	88
4.3.1	Resultados — Acidente Vascular Cerebral Hemorrágico.	88
4.3.1.1	<i>Inicialização da abordagem - AVC Hemorrágico</i>	89
4.3.1.2	<i>Segmentação - AVC Hemorrágico (<i>Divisible Cell-Segmentation</i>)</i>	91
4.3.1.3	<i>Validação dos Resultados (AVC Hemorrágico) - Comparação com Trabalhos da Literatura</i>	96
4.3.1.4	<i>Considerações Finais — (Segmentação de AVC Hemorrágico)</i>	100
4.3.2	Resultados — Abordagem Pulmonar	103
4.3.2.1	<i>Segmentação Pulmonar</i>	106
4.3.2.2	<i>Validação dos Resultados (Imagens Pulmonares) - Comparação com Trabalhos da Literatura</i>	112
4.3.2.3	<i>Considerações Finais — (Segmentação Pulmonar)</i>	118

4.4	Análise Geral dos Resultados do Método Proposto.	118
4.5	Considerações Finais	122
5	CONCLUSÕES E TRABALHOS FUTUROS	124
5.1	Conclusões	124
5.2	Trabalhos Futuros	126
	REFERÊNCIAS	127

1 INTRODUÇÃO

Esta tese apresenta uma nova abordagem eficaz para segmentação em imagens médicas. O novo método é capaz de identificar e segmentar com profunda precisão, regiões da borda do objeto de interesse em imagens de tomografia computadorizada TC para auxílio ao diagnóstico médico. O novo método apresenta uma eficaz abordagem *deep learning* para sua inicialização automática inteligente, que propõe a detecção na imagem médica para a segmentação adaptativa da região de interesse com profunda precisão. O método denominado *Divisible Cell-Segmentation*, método proposto, é aplicado em imagens de TCs de AVC hemorrágico e TCs de pulmão.

Neste capítulo, apresentamos a contextualização, motivação, a descrição do problema, os desafios e os objetivos desta tese, bem como as principais contribuições e produção científica.

1.1 Contextualização

Com o avanço tecnológico nas últimas décadas e o investimento em tecnologia, bem como o vasto crescimento em acesso a *hardwares* com grande capacidade de processamento, tornaram possíveis grandes avanços em diversas áreas e sistemas computacionais, sendo fundamental o papel desta área tecnológica e parte inerente da vida da sociedade atual. A diversidade de soluções aponta um campo amplo em sistemas computacionais inteligentes com uso em vários eixos de uma sociedade moderna, seja ela na educação, indústria, segurança, saúde, dentre outras. O fato é que, aplicações inteligentes tornaram o meio em que vivemos uma sociedade interligada a novas tecnologias, embasadas na construção de dados propícios a serem utilizados em sistemas inteligentes com grande poder de processamento (FILHO *et al.*, 2017).

Com a grande difusão em sistemas que ajudam a interpretação médica em imagens, que aborda sistemas de diagnóstico auxiliados por computador. Esse processo em imagens médicas proporciona uma diversidade de aplicações, onde destacam-se a detecção e classificação de doenças, bem como a segmentação em imagens médicas utilizando aquisições de TCs, Ressonâncias Magnéticas (RMs) e Raio-X. Tais metodologias podem ser abordadas por diferentes métodos, incluindo os mais clássicos em visão computacional, com uso de Processamento de Imagens Digitais Processamento Digital de Imagens (PDI), *Machine learning*, Redes Neurais Artificiais (RNAs) e uso de Redes Neurais Convolucionais (CNNs) por meio de métodos *Deep Learning* (MARQUES *et al.*, 2022).

O desenvolvimento de aplicações inteligentes e sistemas computacionais, associados ao conhecimento médico por meio de especialistas, fornece ferramentas poderosas (grande capacidade de processamento) no auxílio ao diagnóstico de doenças e acompanhamento dos tratamentos de pacientes (REBOUÇAS FILHO, 2013). Na atualidade, as TCs são imagens geradas por técnicas de aquisição realizadas em exames por imagens, tornando-se ferramenta chave para aplicações de sistemas computacionais por meio de métodos baseados em visão computacional. Com o avanço tecnológico e estudo na área médica com o objetivo de auxiliar o diagnóstico, as TCs estão entre os métodos de aquisição por imagem mais utilizados para diagnóstico clínico (HOLMES *et al.*, 2017). A técnica de aquisição proporciona em sua abordagem, informações de forma detalhada sobre o objeto de interesse na imagem capturada, seja ela um AVC hemorrágico, um tumor cerebral, pulmonar, ou qualquer outra região de interesse. Permitindo, ainda, analisar com precisão outros fatores correlacionados a região de interesse (EL-KOUSSY *et al.*, 2014; HAAN *et al.*, 2015).

Várias pesquisas foram desenvolvidas para auxiliar o diagnóstico médico por meio de processamento digital de imagem, aprendizado de máquina com o de ullah *et al.* (2019) e aprendizado profundo de Skourt *et al.* (2018). Como o trabalho de Pehrson *et al.* (2019) que propuseram um estudo geral sobre técnicas de *Machine Learning* e *Deep Learning*, aplicadas a um banco de dados de imagens pulmonares disponíveis na literatura, como a detecção de nódulos pulmonares em imagens de TC. Métodos Computacionais baseados em Inteligência Artificial (IA) tem se tornado uma realidade cada vez mais recorrente nos mais variados eixos da tecnologia e serviços, isso é devido ao surgimento de novas tecnologias e adaptação social, aparato computacional e maior velocidade de comunicação entre os dispositivos tecnológicos nos últimos anos. Essas aplicações estão em áreas como robótica como a de Shin *et al.* (2019), segurança como no estudo de Santamaria *et al.* (2019) e até saúde, chamado de *Personalized Healthcare* (PH), uma nova abordagem em saúde no campo do monitoramento. Em outros aspectos relacionados, diferentes trabalhos da literatura usam, em visão computacional, diferentes combinações de Rede Neural Artificial (RNA) para a obtenção de bons resultados com uso de *fine-tuning*, uma espécie de refinamento dos dados para obter melhores resultados. O uso da segmentação em imagens médicas em TCs é um desafio complexo no processamento de imagens, como mostra o trabalho de Souza *et al.* (2019) que propuseram técnicas baseadas na rede convolucional *Mask R-CNN* para segmentação de regiões pulmonares em TCs.

O problema de segmentação em imagens médicas é um problema clássico e desafia-

dor, diversos métodos de PDI trazem soluções de forma não automáticas, que por meio de várias combinações de processamento nas imagens, chegam a resultados satisfatórios. Levando em consideração todo o pré-processamento e processamento para assim atingir níveis de qualidade em seus resultados, técnicas como estas são muito relevantes no pós-processamento das redes *deep learning*, na qual combinações de métodos clássicos no pós-resultado gerado pelas redes, trazem grandes melhorias por meio de métodos com técnicas com uso *fine-tuning*, tornando os resultados mais relevantes e significativos para o processamento com redes de processamento profundo. O método baseado em *fine-tuning* é uma técnica que pode ser usada combinadas a técnicas computacionais, cujo objetivo é a melhora nos resultados.

O processo de segmentação é a etapa na qual é realizada a delimitação da área de interesse, identificando as bordas do objeto, a imagem da região de interesse são pré-definidas estabelecendo contornos (bordas). O processo desta fase é fundamental para quaisquer sistemas de CAD, pois é neste processo que podem ser aplicados métodos computacionais para extração de atributos na região específica na qual se pretende classificar algum tipo de dado (NIXON; AGUADO, 2008). Na etapa de detecção apresentada na literatura, o objetivo, em grande parte, é realizar de forma automática, ou semi-automática, a identificação dos objetos que compõem a imagem, identificando os objetos previamente estabelecidos. Normalmente esse processo é realizado por técnicas de *machine learning* e IA (DUDA; HART, 2006; GONZALEZ *et al.*, 2009). Em geral, os dados obtidos são apresentados da forma mais conveniente para a aplicação, podendo ser por meio de sistemas inteligentes capazes de auxiliar a tomada de decisão, bem como a identificação de regiões de patologias.

Os sistemas de auxílio ao diagnóstico médico denominado CAD, aplicados a exames de imagens digitais de TCs para se obtenção de melhores resultados em diagnósticos, são amplamente utilizados na medicina, sendo capazes de detectar, classificar ou segmentar tipos de patologias em diferentes exames médicos através do uso de técnicas de visão computacional, seja com processamento digital de imagem, *machine learning* ou *deep learning*. Ambos têm como objetivo, o desenvolvimento de técnicas cada vez mais robustas e com grande eficácia para solucionar problemas reais (CHAN *et al.*, 2020). As técnicas usadas em CAD avançam de acordo com o surgimento de novos modelos de IA, possibilitando novos avanços e experimentos em desafios no eixo da visão computacional, bem como diferentes soluções por meio de aplicações. Estudos como o de (JIJJA; RAI, 2019) demonstram esta forte correlação entre técnicas de visão computacional e o surgimento de ferramentas CAD cada vez mais robustas, onde os autores

utilizaram CNNs para realizar a segmentação de tumor e AVC cerebral em imagens médicas.

Algumas técnicas tem como objetivo não só a detecção da região de interesse na imagem do exame, mas também a delimitação da região com precisão, este processo recebe o nome de segmentação. A segmentação se torna um dos problemas mais relevantes na área de auxílio ao diagnóstico médico, tendo em vista que o objetivo da técnica é delimitar a região lesionada com a maior riqueza de detalhes possível até a borda (HU *et al.*, 2020). Embora muitas técnicas difundidas para auxílio ao diagnóstico médico realizem apenas um tipo de problema em imagem médica, cada vez mais abordagens generalizadas vem se difundindo no estado da arte. Tais modelos não somente são capazes de realizar a detecção, classificação e segmentação da patologia em imagens médicas, o processo de automatização e uso de novas técnicas otimizadas é um desafio real atual, principalmente na medicina que necessita de aparato e inovação para novos problemas e soluções em diagnóstico. (HAN *et al.*, 2020).

Nesta introdução contempla uma visão sobre diferentes pontos que abrangem a área da visão computacional, bem como problemas em imagens médicas em TCs. A subseção a seguir proporciona uma visão de motivação e diferentes âmbitos, seja ela na área da saúde, do impacto social e econômico, impacto na saúde do indivíduo, bem como em diferentes soluções encontradas na literatura.

1.2 Motivação

Métodos de segmentação são muito utilizadas em imagens médicas, e tem realizado um importante papel no diagnóstico por imagem. O auxílio ao diagnóstico em AVC e pulmão com métodos eficazes, proporcionam uma contribuição significativa para a saúde da sociedade, possibilitando indicativo de tratamento adequado, hábil e preciso. Ao analisar a pluralidade de patologias em imagens de TC, a complexidade é um atrativo para inovação, bem como os desafios em diferentes problemas de saúde por meio de análise automática através sistemas CAD. Diversas técnicas propuseram diferentes soluções, a generalização de técnicas para soluções destes problemas trazem um arcabouço na fundamentação da otimização de sistemas, proporcionando um maior uso por meio de uma só aplicação e resolução de diferentes problemas.

Neste contexto, na literatura, várias abordagens foram propostas para a tarefa de segmentação dessas regiões de interesse. As abordagens da literatura mencionadas e comparadas neste trabalho para os pulmões são; Rebouças *et al.* (2021), Xu e Prince (1998), Li e Acton (2006), Alexandria *et al.* (2010), Braga *et al.* (2021), Braga *et al.* (2017), Medeiros *et al.* (2019), Filho *et*

al. (2019a), Felix *et al.* (2009), Filho *et al.* (2011), Filho *et al.* (2014), Rebouças *et al.* (2018), Hu *et al.* (2020), Han *et al.* (2020), para AVC hemorrágico são; Rebouças *et al.* (2021), Braga *et al.* (2021), Braga *et al.* (2017), Rebouças *et al.* (2017), Rouhi *et al.* (2015), Korbes ANDRÉ (2010), Rebouças *et al.* (2018), Hu *et al.* (2020), Marques *et al.* (2022), Han *et al.* (2020). Todas essas abordagens são comparadas na Seção 4, especificamente encontradas nas respectivas subseções: Subseção 4.3.1.3 Validação dos Resultados (AVC Hemorrágico) — Comparação com Trabalhos da Literatura, e 4.3.2.2 Validação dos Resultados (Imagem Pulmonares) — Comparação com Trabalhos da Literatura.

Motivados por esta extensa lista, propusemos uma nova abordagem baseada em inicialização automática para segmentação de regiões de interesse em imagens médicas, o método denominado *Divisible Cell Segmentation* realiza por meio de detecção inteligente da região de interesse em imagens de TC.

As principais características do método proposto geradas a partir das contribuições são:

- abordagem de inicialização automática inteligente para detecção em alto desempenho da região de interesse a ser segmentada;
- abordagem adaptativa para segmentação pulmonar em imagens de TC;
- nova abordagem baseada em conceitos de aplicações generalistas com o intuito de otimizar futuras aplicações para diferentes problemas;
- solução de segmentação otimizada entre polígonos aplicados por células computacionais sintéticas inspiradas na transformada de Hough para promover uso de novas técnicas em sistemas CADs;
- segmentação com alta precisão em imagens de TC de AVC hemorrágico e TC pulmonar;


1.3 Descrição do problema

Nesta seção são apresentados os diferentes problemas de imagens médicas, trazendo uma breve descrição da problemática em segmentação por meio de modelos computacionais. Assim, buscará trazer os mais diferentes aspectos, bem como as limitações para o problema de segmentação em imagens médicas, frisando TCs de AVC hemorrágico e Pulmonares. Ao fim desta seção espera-se proporcionar uma visão mais ampla da diversidade de cada problema.

1.3.1 AVC hemorrágico - TCs

Diversas características podem ser interpretadas com base nos dados extraídos em uma imagem de TC craniana, o AVC hemorrágico que se trata de um coágulo de sangue em uma determinada região do cérebro pode ser tratado e acompanhado por médicos especialistas. Mas é com base na análise das imagens relacionados, bem como fatores em paralelo, podem obter informações com exatidão em diferentes pacientes.

Figura 1 – Imagens de diferentes fatias de TC de lesão cerebral por AVC Hemorrágico. É possível identificar as variações de textura e área da região do AVC, que se modificam de acordo com a fatia do exame, e a região de sangue coagulado na massa cerebral.



Fonte: Fonte: Elaborada pelo autor.


A imagem da Figura 1 apresenta diferentes imagens de TC de AVC hemorrágico que abordam problemáticas específicas para cada paciente. É possível identificar visualmente a região do AVC, mas os limites da borda do AVC podem ser difíceis de definir, pois em alguns casos, assemelham-se aos *pixels* da massa cerebral. A detecção visual pode ser visível a olho nu em alguns casos, mas a precisão da real localização dos *pixels* que pertencem à hemorragia cerebral é crucial para o acompanhamento do quadro clínico. A complexidade da segmentação varia de acordo com a problemática de encontrar contornos semelhantes às regiões da massa cefálica, e assim acompanhar a evolução do quadro clínico com exatidão.

1.3.2 Pulmões - TCs

As imagens de TC são amplamente utilizadas na detecção e diagnóstico de doenças pulmonares. No entanto, existem alguns problemas que podem surgir na identificação de

anomalias pulmonares em imagens de TC, o que pode levar a diagnósticos incorretos ou atrasos no tratamento.

Figura 2 – Imagens de diferentes fatias de TC de tórax, com diferentes formas e tamanhos de estruturas do pulmão. O pulmão tem sua área modificada de acordo com a fatia do exame, baseado no ciclo respiratório do paciente no momento da captura das imagens. Algumas imagens apresentam patologias no pulmão do paciente causando diferentes texturas de anormalidades internas.



Fonte: Fonte: Elaborada pelo autor.

Um dos principais problemas na identificação de anomalias pulmonares em imagens de TC é a presença de artefatos na imagem, que podem ser causados por vários fatores, como movimentos respiratórios do paciente, materiais metálicos próximos ao corpo do paciente, mau funcionamento do equipamento de TC ou uso incorreto de contrastes de imagem, como demonstra a Figura 2. O processo de segmentação dos pulmões é uma etapa fundamental para classificação de doenças pulmonares.

1.4 Estado da Arte

Nesta seção são apresentados o Estado da Arte dos diferentes problemas para segmentação de imagens médicas. Na perspectiva do estudo apresentado, busca-se trazer diferentes trabalhos encontrados na literatura, bem como as diferentes temáticas e soluções no estado da arte. Levando em consideração a crescente pesquisa na área médica voltada para o auxílio ao diagnóstico médico para patologias, mais especificamente o AVC e pulmão, nesta subsecção, serão abordadas técnicas computacionais, bem como métodos consolidados encontrados no estado da arte.

A segmentação de imagens ROI usando abordagens baseadas em contorno ativo

tem se mostrado promissora na literatura, especialmente para exames de TC de AVC cerebral e doença pulmonares. No entanto, a busca por melhorias na segmentação dessas imagens ainda está em andamento, uma abordagem interessante é o uso de técnicas de aprendizado profundo para segmentação, como CNNs. Essas técnicas têm mostrado grande potencial para melhorar a precisão e robustez das tarefas de segmentação em imagens médicas. Por exemplo, em um estudo recente de Filho *et al.* (2017), foi proposta uma abordagem inovadora utilizando uma *Convolutional Neural Networks* (CNN) de duas etapas para a segmentação de imagens de TC de pulmão, alcançando alta precisão e superando métodos de segmentação clássicos.

Além disso, várias abordagens foram propostas na literatura para melhorar a segmentação de imagens de TC para AVC cerebral usando contornos ativos baseados em funções de nível. O algoritmo usa a densidade cerebral e a adaptabilidade com base na faixa de intensidade apresentada nos exames para inicializar e evoluir a região. Em Rouhi *et al.* (2015), o limite para o crescimento da região e subsequente segmentação da ROI é baseado em uma RNA treinada, que usa recursos de intensidade, textura e forma da imagem. O estudo de Korbes ANDRÉ (2010), foi realizada uma revisão e análise do algoritmo de transformação da *watershed* clássica, com o objetivo de minimizar a influência da ordem de varredura dos *pixels* na imagem. Essas abordagens baseadas em contornos ativos, combinadas a outras técnicas, como CNNs e RNAs, têm o potencial de melhorar ainda mais a segmentação de imagens da ROI para AVC cerebral, pulmões e outras condições médicas. No entanto, o desenvolvimento de novos algoritmos mais eficientes, robustos e capazes de lidar com conjuntos de dados maiores deve ser o foco da pesquisa futura nesta área.

A segmentação em imagens médicas podem ser realizadas por diferentes abordagens. Algumas delas utilizam técnicas de processamento de imagens, como o algoritmo de Triangulação de Delaunay proposto por Pennisi *et al.* (2016) e o algoritmo *Simple Linear Iterative Clustering* (SLIC) que se baseia na intensidade média dos canais RGB, referenciado por Patino *et al.* (2018). Já as abordagens baseadas em *deep learning*, como as propostas por Badrinarayanan *et al.* (2017), podem ser classificadas em alta ou baixa resolução, dependendo da estrutura adotada. Essas abordagens não requerem etapas de pré-processamento, mas exigem um grande número de amostras para treinamento. O trabalho de Reboucas *et al.* (2018) traz uma comparação com trabalhos da literatura, o método proposto é comparado com métodos de iniciação automática e outros com iniciação manual. Os métodos aplicados na segmentação do AVC hemorrágico por iniciação manual foram Crescimento de Região (CR), *Watershed*, *Level set based on the*

Method of Coherent Propagation (LSCPM) e *Fuzzy-C means* (FCM). O estudo propõe iniciar automaticamente o método de definição de nível dentro da região, usando uma abordagem de estimativa não paramétrica baseada no janelamento de *Parzen* para segmentação.

O trabalho de Korbes ANDRÉ (2010) aborda análise de algoritmos da transformada *watershed*, onde são apresentados as principais definições de transformada *watershed*, que incluem a inundação *Flooding-WT*, distância topográfica (TD-WT), condição local (LC-WT), transformada imagem floresta com custo máximo de caminho (IFT-WT), zona de empate (TZ-IFT-WT) e *watershed cut* (WC-WT). Essas definições são fundamentais para os algoritmos disponíveis na literatura, e seus resultados influenciam diretamente o comportamento das aplicações e as saídas esperadas. Foram observadas melhorias na segmentação de imagens de ROI em exames de tomografia computadorizada de derrame cerebral com o uso de diferentes abordagens de definição de nível. O artigo de Filho *et al.* (2017) apresenta mais informações sobre segmentação com abordagens em níveis de cinza.

No estudo de Rouhi *et al.* (2015), é apresentado um método de segmentação que utiliza um crescimento de região automatizado com limite obtido por uma CNN treinada. Além disso, é proposto um segundo método de segmentação por meio de uma CNN celular, com parâmetros definidos por um Algoritmo Genético (AG). Neste estudo, características como intensidade, textura e forma foram extraídas de tumores segmentados e o AG foi utilizado para selecionar características apropriadas. Os resultados obtidos indicaram uma precisão de 99% com desvio padrão de 04.46% e uma especificidade de 92.84% com desvio padrão de 21.88%, demonstrando uma segmentação eficaz da região de interesse.

Após validar o uso de contornos ativos Geodésicos em diversos tipos de imagens médicas e reconhecer a importância de sistemas CAD para AVC Hemorrágico, Medeiros *et al.* (2020) realizaram uma validação do MGAC na segmentação de AVC Hemorrágico em um *dataset* de 100 imagens de Tomografia computadorizada de crânio. Todas as imagens apresentavam AVC Hemorrágico em alguma parte da massa cinzenta do paciente. O modelo utilizado, denominado Contorno Ativo Geodésico Morfológico adaptativo Adaptive Morphological Geodesic Active Contour (Ada-MGAC), aplicou o Morphological Geodesic Active Contour (MGAC) automaticamente na região de interesse. O método obteve uma acurácia média de 99% e um tempo baixo de segmentação, demonstrando a eficácia do método para essa aplicação, além de compará-lo com outras abordagens da literatura que utilizaram a mesma base de dados.

No estudo de Braga *et al.* (2021) foi realizada a segmentação de núcleos hierárquicos

em células cervicais com base em análise multiescala e conjunto de nível de banda estreita. O método foi avaliado em três bancos de dados públicos de imagens de células cervicais e superou seis métodos de ponta em relação ao número de núcleos segmentados corretamente. Além disso, o algoritmo proposto foi adequado para integrar sistemas de apoio à decisão para triagem de células cervicais, como evidenciado pelos resultados de classificação alcançados. O coeficiente de *Dice* atingiu valores iguais ou superiores a 86%, e a precisão média foi igual a 99%. Braga *et al.* (2017) apresentaram um algoritmo eficiente de processamento de imagem para segmentação multirregional de imagens Synthetic aperture radar (SAR) utilizando conhecimento de dados e modelos. O algoritmo proposto é um conjunto de nível hierárquico que utiliza um filtro de mediana não paramétrico para regularização de curva e operações morfológicas em vez de derivadas de propagação frontal, reduzindo o tempo de computação. O desempenho do algoritmo foi avaliado em imagens SAR sintéticas e reais, demonstrando resultados mais rápidos e precisos em comparação com outros métodos. As medidas de avaliação incluíram tempo de computação, precisão de segmentação e distância estocástica. Sua abordagem apresentou resultados em uma precisão de 97%, demonstrando a performance do método.

O trabalho de Rebouças *et al.* (2021) propuseram o uso de *edge computing* e uma nova abordagem baseada em contornos ativos chamada FLog Parzen Level Set (FPLS) para direcionar o ROI em imagens médicas. O trabalho demonstrou eficácia para segmentação de AVC hemorrágico, com precisão acima de 99% e 88% obtidos em coeficiente de *Dice*. Na mesma temática, o estudo de Han *et al.* (2020) propuseram o método Health-of-Things System for the Classification and Segmentation of Medical Images (HTSCS) para imagens de TC do pulmão e AVC hemorrágico, baseado na saúde das coisas. O sistema utiliza aprendizado de transferência entre modelos de aprendizado profundo, combinado com métodos clássicos para ajuste fino, os modelos apresentaram desempenho excepcional na segmentação, com *Dice* acima de 97% nos melhores casos e tempo médio de segmentação 1.7 segundos. Também inspirados pela alta performance das CNNs o trabalho de Marques *et al.* (2022) trouxeram a discussão sobre o desenvolvimento de uma ferramenta para segmentar AVC Hemorrágico em imagens de TC utilizando a rede *Mask R-CNN* e técnicas de janelamento de Parzen e crescimento de região. O método atingiu uma acurácia média acima de 99% quando combinadas no processo de *fine-tuning*. Os autores destacam a importância do uso de *cross-validation* para a obtenção de métricas de avaliação mais confiáveis e precisas.

Em seus estudos, Pereira *et al.* (2016) desenvolveram um método de segmentação

automática de imagens médicas em exames de Imagem por Ressonância Magnética (IRM) baseado em Redes Neurais Convolucionais CNN com o uso de *kernels* pequenos de 3×3 . O emprego de *kernels* menores, segundo os autores, permitiu a construção de uma arquitetura mais profunda, de maneira a reduzir a probabilidade de *overfitting*. Além disso, foi investigado o uso da normalização de intensidade como etapa de pré-processamento, o que se mostrou eficaz em conjunto com o aumento de dados. A proposta foi validada através dos bancos de dados BRATS 2013 e BRATS 2015, obtendo um *Dice* médio de 88% para a segmentação em imagens de Ressonância Magnética (RM). Vale ressaltar que, embora o método se utilize de uma arquitetura de rede eficaz, o pré-processamento aplicado com parâmetros mal selecionados pode acarretar a perda de eficiência dos resultados do modelo.

Em Dipu *et al.* (2021) propuseram duas abordagens baseadas em *Deep Learning* para detecção e classificação de imagens médicas na base BRATS 2018, a primeira técnica conta com o uso da You Only Look Once (YOLO) na versão 5. Já a segunda abordagem desenvolvida, se deu com base na biblioteca *FastAi* (HOWARD; GUGGER, 2020). As redes foram treinadas com todas as classes presentes nas 1.992 imagens da base, sendo capazes de segmentar com uma precisão de 85.95% para a *YoloV5* e 95.78% para a *FastAi*.

Em Tripathi *et al.* (2021) propuseram um método de aprendizado profundo automático para quantificar a região de interesse em imagens de ressonância magnética cerebral, que foca na delimitação da região irregular para preservar os detalhes precisos das bordas e dos *pixels*. O método incorpora conexões residuais internas, normalização cruzada e unidade retificadora linear paramétrica Parametric Rectified Linear Unit (PRELU) para equilibrar o desempenho da rede. A validação externa foi realizada através da comparação com a segmentação manual feita por um radiologista experiente. A rede foi denominada como CCN-PR-Seg-net. Para validar seus resultados, os autores realizaram o treinamento das redes *U-net* e *seg-net*. A *U-net* foi projetada para tarefas de segmentação de imagem, comumente usada em aplicações de imagens médicas. Sua arquitetura possui um caminho descendente, que usa convoluções para reduzir a resolução da imagem e extrair características de baixo nível, e um caminho ascendente, que usa camadas de *up-sampling* para aumentar a resolução e reconstruir a imagem segmentada (RONNEBERGER *et al.*, 2015). Já a *seg-net* incorpora módulos de pooling máximo, que são usados para reduzir a resolução espacial da imagem, e módulos de unpooling, que aumentam a resolução espacial da imagem (BADRINARAYANAN *et al.*, 2017). O estudo de Reboucas *et al.* (2018) propuseram uma abordagem utilizando a Rede Neural Convolucional Baseada em Máscaras (*Mask R-CNN*)

combinada com técnicas de processamento de imagem e ajuste fino para segmentação de imagens médicas. Os modelos propostos alcançaram resultados satisfatórios em termos de precisão, *Dice*, sensibilidade e *Negative Predictive Value* (PPV) em diferentes bancos de dados de TC pulmonar, demonstrando a eficácia do método.

A segmentação em imagens de TC para detectar patologias pulmonares é um desafio na área da medicina computacional, devido à mudança constante, do formato e da textura do pulmão em cada fatia do exame. Nesta perspectiva, Reboucas *et al.* (2018) propuseram um novo método denominado *Optimum Path Snakes* (OPS) baseado em contornos ativos, obtendo métricas de segmentação, mais especificamente *Hausdorff* e Coeficiente *Dice*, obtendo média de 84% para a segmentação de pulmão e AVC Hemorrágico em imagens de TC. No entanto, o modelo mostrou ser superado por técnicas mais recentes nas métricas mencionadas. Vale ressaltar, que a maior parte dos trabalhos abordados nesta secção realizaram a mesma base de dados para a segmentação da região pulmonar.

Na literatura, diversos trabalhos aplicaram técnicas de contorno ativo diferenciado para segmentar a região de interesse. As contribuições destacadas incluem o uso de um *Fuzzy Border Detector* sem treinamento prévio em Medeiros *et al.* (2019) para melhorar os critérios de crescimento da região. Em Felix *et al.* (2009), Filho *et al.* (2011), Filho *et al.* (2014), a topologia definida pela densidade dos *pixels* do contorno foi adotada como referência. Em Xu e Prince (1998), Li e Acton (2006), os autores aplicaram variações do vetor de imagem, como o Fluxo Vetorial Gradiente (FVG) e a Convolução de Campo Vetorial (CCV), para parametrizar os critérios de evolução. Por fim, em Alexandria *et al.* (2010), os autores utilizaram a Transformada de *Hilbert* e raios ativos representados em coordenadas polares para segmentar a imagem.

O trabalho de (MEDEIROS *et al.*, 2019), consciente da eficácia dos métodos de segmentação, empregaram a combinação de um método de contorno ativo adaptativo chamado *Morphological Geodesic Active Contour* (FGAC) e uma energia externa adaptativa usando aprendizado profundo, com 98% de acurácia. O método *Computational Vision System for Detection and Quantification of the Pulmonary Emphysema* (SDEP), desenvolvido por (FELIX, 2007), é uma ferramenta de segmentação automática de pulmão em imagens de TC, que utiliza métodos clássicos combinados com processamento digital de imagens. Além disso, conta com a ferramenta complementar "máscara colorida", que realça áreas hipoaeradas de difícil percepção. O trabalho de (FILHO *et al.*, 2017) propôs o uso de contornos ativos para segmentação de imagens de TC de pulmão, desenvolvendo um modelo denominado *3D Adaptive Crisp Active*

Contour Method (3D ACACM). O método utiliza uma semente para iniciar a segmentação e expande iterativamente a região de interesse com base na energia do modelo deformável 3D, obtendo 99% de *F-measure*. No entanto, para uma discussão mais profunda, seria interessante o uso de outras métricas de avaliação.

Diferentes estudos têm sido realizados, dentre eles, Hu *et al.* (2020) propôs o uso da rede *Mask-RCNN* e aprendizado de máquina para a segmentação de TC de pulmão por meio de *fine-tuning*. A rede automática obteve bons resultados com uma acurácia de 97,68%, porém com grande custo computacional devido ao processo de *transfer learning* proporcionou custo computacional elevado, elevando o tempo de segmentação. (SOUZA *et al.*, 2020) propõem um novo modelo com uso de *transfer learning* para classificação e a rede *Mask R-CNN* para segmentação pulmonar, obtendo 98% de precisão e valores métricos de segmentação, porém os autores não realizaram validação cruzada, o que levaria a outras discussões.

O estudo de Xu *et al.* (2020) se concentrou na segmentação da ROI usando *deep learning* e as inovações tecnológicas trazidas pelo grupo de *Health of Things*. Os autores propuseram um método para detectar AVC Hemorrágico em imagens de TC. O método realizou uma pré-classificação da imagem de entrada em lesão ou não lesão por AVC hemorrágico e, posteriormente, segmentou a região lesionada usando técnicas de *transfer learning* para a região de interesse detectada na saída da *Mask R-CNN*. Para a segmentação, foram utilizadas técnicas de criação de mapas de região do AVC, como *k-Nearest Neighbor (KNN)*, *Naive Bayes*, *Multilayer Perceptron (MLP)* e outros algoritmos de *machine learning*. O método obteve resultados satisfatórios em 356 imagens de TC, alcançando uma média de 99% de precisão na segmentação. No entanto, é importante ressaltar que o modelo teve pouco treinamento e seria necessário mais bases de dados para validação dos resultados, além de grande poder de processamento, com elevado custo computacional. Além disso, novos estudos podem considerar o uso de outras modalidades de imagens médicas, como a ressonância magnética, para aumentar a diversidade e a precisão dos resultados.

O uso de técnicas de processamento digital de imagens para aprimorar a segmentação em modelos de *deep learning* é uma área de pesquisa em constante evolução. A segmentação é uma etapa importante em muitas aplicações de imagens médicas, incluindo o diagnóstico assistido por computador e a detecção de lesões. No entanto, a segmentação manual é um processo demorado e suscetível a erros, o que motivou o desenvolvimento de métodos de segmentação automáticos. Entre as técnicas mais recentes, destaca-se o uso de redes neurais convolucionais,

como a *Mask R-CNN*, para segmentação de objetos em imagens médicas. Esses modelos têm mostrado resultados promissores, mas ainda apresentam limitações, como a necessidade de um grande número de amostras para treinamento e a sensibilidade a variações de iluminação e contraste (SOUZA *et al.*, 2020). Para superar essas limitações, pesquisadores têm explorado o uso de técnicas de processamento digital de imagens para aprimorar a segmentação em modelos de *deep learning* e uso de *fine-tuning* como o trabalho de Marques *et al.* (2022). Apesar dos avanços ainda há desafios a serem superados, um deles é o tempo de treinamento dos modelos que pode ser bastante elevado, especialmente quando se trabalha com grandes conjuntos de dados. Além disso, a criação de amostras por meio da técnica de *data argumentation* demonstraram ser essenciais para aumentar a diversidade e a robustez na segmentação por modelos com uso da técnica, porém, pode também pode ser um processo demorado e oneroso (HU *et al.*, 2020).

Considerando essas investigações preliminares que visam aproximar a questão das possíveis soluções, esta seção explora várias dimensões, incluindo aspectos sociais, econômicos, computacionais e tecnologias relacionadas ao problema de processamento de imagens médicas em diferentes soluções. Além disso, como parte da análise apresentada nesta seção, a proposta é fornecer uma visão contextualizada sobre o estudo proposto.

1.5 Objetivos

1.5.1 *Objetivo Geral*

Esta tese possui o objetivo geral de propor um novo método para segmentar regiões de interesse em imagens de TC, através de células computacionais sintéticas com abordagem automática e adaptativa, por meio de múltiplas divisões celulares capazes de percorrer a imagem até a borda da região de interesse, para gerar a segmentação por meio de conexão celular.

1.5.2 *Objetivos Específicos*

Além do foco geral, este trabalho possui outros objetivos específicos, tais como:

- propor uma nova abordagem de inicialização automática adaptativa para detecção de regiões de interesse em imagens de TCs;
- propor um novo método de segmentação e otimização *fine-tuning* através de células computacionais sintéticas divisíveis, denominado *Divisible Cell-Segmentation*;
- aplicar e avaliar o método proposto *Divisible Cell-Segmentation* para diferentes base de

dados composta por diferentes exames de TC; AVC hemorrágico e Pulmonar;

- realizar um estudo comparativo entre diversos métodos de segmentação juntamente com o método proposto, a fim de identificar a robustez e eficiência na segmentação em imagens de TCs;

1.6 Contribuições

As principais contribuições desta tese são:

1. inicialização automática adaptativa baseada em *deep learning* capaz de detectar AVC hemorrágico para segmentação em TCs;
2. inicialização automática adaptativa baseada em *deep learning* capaz de detectar pulmões para segmentação em TCs;
3. novo método para segmentação em imagens de TCs proposta por células computacionais sintéticas divisíveis, denominado *Divisible Cell-Segmentation*;
4. método adaptativo de otimização para conexões entre células computacionais sintéticas para segmentação de pulmões em TC;
5. método adaptativo de otimização para conexões entre células computacionais sintéticas para segmentação de AVC hemorrágico de TC;
6. método de segmentação eficiente, robusto, que pode ser integrado a sistemas CAD;
7. método eficaz para segmentação em imagens bidimensionais capazes de serem pré-configurados para diferentes problemas;

1.7 Produção Científica

A produção científica durante o doutorado resultou na publicação e submissão de artigos científicos a periódicos e congressos. A seguir estão listadas as publicações:

- **Artigos Publicados em *Journals & Magazines*:**

1. **SOUZA, LUÍS FABRÍCIO DE FREITAS, SILVA, IÁGSON CARLOS LIMA ; MARQUES, ADRIELL GOMES ; SILVA, FRANCISCO HÉRCULES DOS S. ; NUNES, VIRGÍNIA XAVIER ; HASSAN, MOHAMMAD MEHEDI ; ALBUQUERQUE, VICTOR HUGO C. DE ; FILHO, PEDRO P. REBOUÇAS . *Internet of Medical Things: An Effective and Fully Automatic IoT Approach Using Deep Learning and Fine-Tuning to Lung CT Segmentation. SENSORS*, v. 20, p. 6711,**

2020.(**Qualis A1 em Engenharias IV**).

2. **de F. Souza, Luís Fabrício**; HOLANDA, GABRIEL BANDEIRA ; DOS S. SILVA, FRANCISCO HÉRCULES ; ALVES, SHARA S.A. ; FILHO, PEDRO PEDROSA REBOUÇAS . *Automatic lung segmentation in CT images using Mask R-CNN for mapping the feature extraction in supervised methods of machine learning using transfer learning. INTERNATIONAL JOURNAL OF HYBRID INTELLIGENT SYSTEMS*, v. 1, p. 1-17, 2021. (**Qualis b1 em Engenharias IV**).
3. XU, YONGZHAO ; HOLANDA, GABRIEL ; **SOUZA, LUIS FABRICIO. DE F.**, SILVA, HERCULES ; GOMES, ADRIELL ; SILVA, IAGSON ; FERREIRA, MARCOS ; JIA, CHUANYU ; HAN, TAO ; DE ALBUQUERQUE, VICTOR HUGO C. ; FILHO, PEDRO P. REBOUCAS . *Deep Learning-Enhanced Internet of Medical Things to Analyze Brain CT Scans of Hemorrhagic Stroke Patients: A New Approach. IEEE SENSORS JOURNAL*, v. 21, p. 24941-24951, 2021.).
4. **SOUZA, LUÍS FABRÍCIO DE FREITAS**, CASTRO, TASSIANA MARINHO ; SANTOS, LUCAS DE OLIVEIRA ; MARQUES, ADRIELL GOMES ; NASCIMENTO, JOSÉ JEROVANE DA COSTA ; SANTOS, MATHEUS ARAÚJO ; SEVERIANO, GUILHERME F. BRILHANTE ; REBOUÇAS FILHO, PEDRO PEDROSA . *Detection and Segmentation of Damaged Photovoltaic Panels Using Deep Learning and Fine-tuning in Images Captured by Drone. LEARNING AND NONLINEAR MODELS*, v. 19, p. 4-14, 2021.). (**Qualis B1**)
5. XU, YONGZHAO; **SOUZA, LUÍS F.F.**, SILVA, IÁGSON C.L. ; MARQUES, ADRIELL G. ; SILVA, FRANCISCO H.S. ; NUNES, VIRGÍNIA X. ; HAN, TAO ; JIA, CHUANYU ; DE ALBUQUERQUE, VICTOR HUGO C. ; FILHO, PEDRO P. REBOUÇAS . *A soft computing automatic based in deep learning with use of fine-tuning for pulmonary segmentation in computed tomography images. APPLIED SOFT COMPUTING*, v. 112, p. 107810, 2021.).
6. XU, YONGZHAO ; DOS SANTOS, MATHEUS A.; **F. SOUZA, LUÍS FABRÍCIO**, MARQUES, ADRIELL G. ; ZHANG, LIJUAN ; DA COSTA NASCIMENTO, JOSÉ JEROVANE ; DE ALBUQUERQUE, VICTOR HUGO C. ; REBOUÇAS FILHO, PEDRO P. . *New fully automatic approach for tissue identification in histopathological examinations using transfer learning. Iet Image Processing*, v. 1, p. 1, 2022.). (**Qualis A2**)

• **Artigos Publicados em Congressos e Conferências:**

1. MARQUES, ADRIELL GOMES; **DE F. SOUZA, LUIS FABRICIO**; DOS SANTOS, MATHEUS ARAUJO ; DA COSTA NASCIMENTO, JOSE JEROVANE ; SARMENTO, ROGER MOURA ; LUCENA, IAGO BELARMINO ; SILVA, IAGSON CARLOS L. ; FILHO, PEDRO P. REBOUCAS . *Automatic Segmentation of Hemorrhagic Stroke on Brain CT Images Using Convolutional Neural Networks Through Fine-Tuning. In: 2022 International Joint Conference on Neural Networks (IJCNN), 2022, Padua. 2022 International Joint Conference on Neural Networks (IJCNN), 2022. p. 01. (Qualis A1)*
2. **Luís Fabrício de F. Souza**, NASCIMENTO, J. J. C.; Cyro M. G. Sabóia ; GOMES, ADRIELL ; BRILHANTE, G. F. ; SANTOS, L. O. ; REGO, P. A. L. ; FILHO, PEDRO P. REBOUÇAS . *New Approach in LPR Systems Using Deep Learning to Classify Mercosur License Plates with Perspective Adjustment. In: 22nd Intelligent Systems Design and Applications 2022, Auburn, Washington, USA. Machine Intelligence Research Labs (MIR Labs), 2022. (Qualis B1)*
3. NUNES, VIRGINIA XAVIER ; MEDEIROS, ALDISIO G. ; DE LIMA, RAYLSON SILVA; **DE F. SOUZA, LUIS FABRICIO**, DE ALBUQUERQUE, VICTOR HUGO C. ; FILHO, PEDRO P. REBOUCAS . *A Novel Web Platform for COVID-19 diagnosis using X-Ray exams and Deep Learning Techniques. In: 2021 International Joint Conference on Neural Networks (IJCNN), 2021, Shenzhen. 2021 International Joint Conference on Neural Networks (IJCNN), 2021. p. 1. (Qualis A1)*
4. LIMA, R. S. ; NUNES, VIRGÍNIA X. ; MARQUES, ADRIELL G.; **SOUZA, L. F. F.**, ROCHA NETO P. D ; BRAYNER, A. R. A ; REBOUÇAS FILHO, PEDRO P. . *New AIoT-Based Approach for Automatic Detection of COVID-19 Using Deep Learning Techniques in CT Images. In: In: International Conference on Systems, Signals and Image Processing (IWSSIP), 2021, Bratislava, Eslováquia. 28th International Conference on Systems, Signals and Image Processing, 2021. v. v. 28. (Qualis A2)*
5. SILVA, F. H. S. ; GOMES, ADRIELL ; **Luís Fabrício de F. Souza**, NUNES, VIRGÍNIA X. ; NASCIMENTO, J. J. ; ROCHA NETO, P. D ; REBOUCAS FILHO, P. P. . *New Approach Detection of COVID-19 by Cough Spectrogram Using IoT and Learning Transfer Technique for Classification. In: In: International Conference on Systems, Signals and Image Processing (IWSSIP), 2021, Bratislava, Eslováquia.*

- 28th International Conference on Systems, Signals and Image Processing, IWSSIP 2021, 2021. v. v. 28. (Qualis A2)*
6. ALMEIDA, J. S. ; BEZERRA, GABRIEL M. ; **DE FREITAS SOUZA, LUIS FABRICIO**, REBOUÇAS FILHO, PEDRO P. . *An Optimized Approach to COVID-19 Detection via Cough Audio Signals and Dimensionality Reduction.. In: In: International Conference on Systems, Signals and Image Processing (IWSSIP),, 2021, Bratislava, Eslováquia. 28th International Conference on Systems, Signals and Image Processing, IWSSIP 2021, 2021. v. v. 28. (Qualis A2)*
 7. BARROSO, C. B. ; SILVEIRA, A. L. B. ; CHAVES, J. M. ; **Luís Fabrício de F. Souza** ; GOMES, ADRIELL ; OHATA, ELENE FIRMEZA ; REBOUÇAS FILHO, PEDRO P. . *Stroke detection and segmentation in CT images using Convolutional Neural Networks and Active Contour Geodesic Method. CONTROLE AUTOMATIZAÇÃO*, In: In: XXIV Congresso Brasileiro de Automática (CBA 2022).
 8. **DE F. SOUZA, LUIS FABRICIO**; JOEL R MICHALLISZEN; MARQUES; ADRIELL GOMES; DOS SANTOS, YASMIM O. RODRIGUES; DA COSTA NASCIMENTO, JOSE JEROVANE ; GUILHERME BRILHANTE; FILHO, PEDRO P. REBOUCAS . *Divisible Cell-Segmentation: A New Approach for Stroke Detection and Segmentation in CT Scans Using Fine-tuning. In: 2023 International Joint Conference on Neural Networks (IJCNN), 2023, Queensland, Australia., 2023. p. 01. (Qualis A1)*

1.8 Organização da Tese

Além do capítulo introdutório, esta tese conta com outros quatro capítulos e está dividida conforme se segue:

Capítulo 2: este capítulo discorre os principais aspectos relativos ao AVC hemorrágico e Imagens pulmonares, bem como a etiopatogenia e epidemiologia, tipos, tratamentos e recomendações. Apresenta conceitos sobre imagens médicas, tomografia computadorizada. Por fim, apresenta conceitos temáticos do Estado da Arte seguida de métodos da literatura.

Capítulo 3: são abordadas as contribuições deste trabalho: Nova abordagem baseada em inicialização automática, e a principal contribuição desta tese com o Novo método de segmentação de TC de AVC hemorrágico e pulmonar, denominado *Divisible Cell-Segmentation*.

Capítulo 4: são apresentados os resultados obtidos, bem como as discussões e comparações entre trabalhos da literatura.

Capítulo 5: são apresentadas as conclusões, principais contribuições desta tese e as recomendações para a continuidade dos trabalhos nesta área de estudo.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, primeiramente, são apresentados os principais aspectos do AVC e pulmão, sua etiopatogenia, epidemiologia, descrição, tratamentos e recomendações. A Seção 2.1 faz uma breve introdução sobre as doenças abordadas, evolução e os princípios básicos da revisão clínica. Na seção seguinte são apresentados os conceitos introdutórios relacionados às imagens de TC. Em seguida é abordado de forma introdutória, técnicas conceituais de visão computacional inspirados para o desenvolvimento da metodologia desta tese.

2.1 Revisão clínica das doenças abordadas

Nas seções seguintes, serão abordadas brevemente as doenças que motivam as segmentações das regiões em análise desta tese, visando o auxílio ao diagnóstico médico com a proposta de realizar a segmentação automática destas regiões de interesse.

2.1.1 *Acidente Vascular Cerebral*

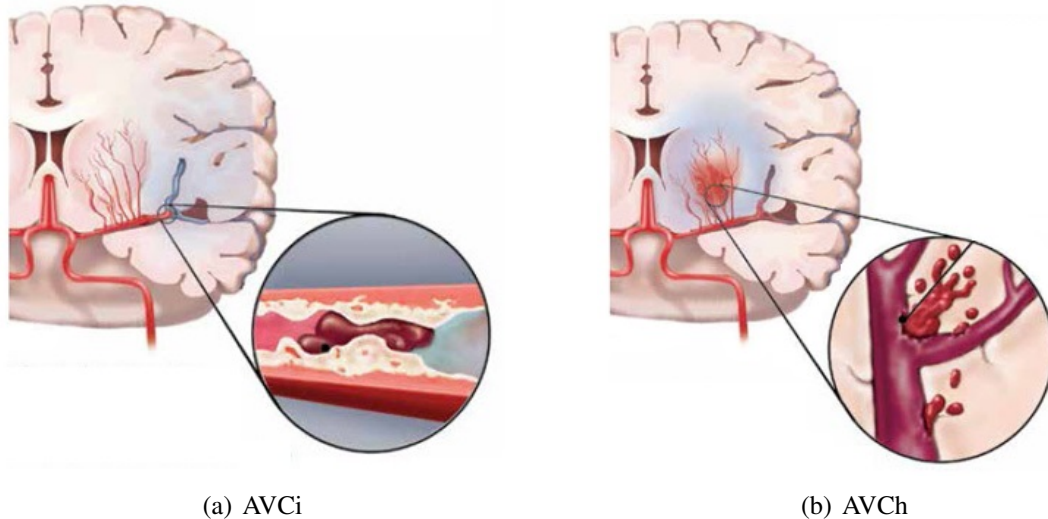
Segundo o neurologista e pesquisador americano Louis Caplan, publicado no livro *Stroke Essentials* de Goldszmidt e Caplan (2009), a compreensão do AVC evoluiu lentamente ao longo do tempo, com muitas teorias e tratamentos ineficazes sendo convencionais. Ele destaca que foi somente no final do século XIX que os médicos reconheceram o AVC como uma entidade clínica distinta. No início do século XX, o neurologista austríaco Julius Wagner-Jauregg realizou estudos sobre a relação entre o AVC e a pressão arterial alta, o que foi um passo importante para entender os fatores de risco para a doença (HAAS, 2002). Nos anos seguintes, outros pesquisadores também aprenderam a entender o AVC, como o médico americano Charles Miller Fisher, que identificou a relação entre coágulos sanguíneos e AVC (CAPLAN *et al.*, 2012).

Com o desenvolvimento de novas terapias, como a terapia endovascular, que utiliza cateteres para remover coágulos sanguíneos, a taxa de mortalidade e incapacidade associada ao AVC tem diminuído. No entanto, como destacado no artigo "*Thrombolytic therapy for acute ischemic stroke: past and future*" de Shibata *et al.* (2019), ainda há muito a ser feito para prevenir e tratar o AVC. Os autores argumentam que a pesquisa continua a ser realizada para desenvolver novas soluções e abordagens para melhorar a recuperação do paciente, bem como a prevenção por meio de diagnósticos rápidos e precisos.

Na literatura são apresentados dois tipos de AVC: o AVC isquêmico e o AVC

hemorrágico, ambos ilustrados na Figura 3. O AVC isquêmico, representado pelas iniciais (AVCi) na imagem (a), ocorre quando um coágulo de sangue obstrui um vaso sanguíneo no cérebro, impedindo o fluxo sanguíneo e privando as células aéreas de oxigênio e nutrientes. Já o AVC hemorrágico, representados pela sigla (AVCh) na imagem (b), ocorre quando um vaso sanguíneo no cérebro se rompe, causando sangramento no tecido cerebral.

Figura 3 – Ilustração representativa distinguindo os dois tipos de AVCs: AVCi e do AVCh.



Fonte: Imagem adaptada de HEART AND STROKE FOUNDATION OF CANADA (2023).

Segundo (SARMENTO *et al.*, 2019), os fatores de risco mais comuns para o AVC são hipertensão arterial, diabetes, tabagismo, obesidade, sedentarismo, colesterol elevado e consumo excessivo de álcool. Além disso, a idade avançada e a história familiar de AVC também aumentam o risco da condição. O diagnóstico do AVC é feito através de exames de imagem, como TC ou RM, que podem detectar a presença de danos no cérebro causados pelo AVC.

De acordo com a publicação de Grotta *et al.* (2021), em seu livro "*STROKE: Pathophysiology, Diagnosis, and Management*" publicado pela revista *Elsevier*, as causas mais comuns de AVC hemorrágico incluem hipertensão arterial, aneurismas respiratórios, malformações arteriovenosas e coagulopatias. A hipertensão arterial é a principal causa de AVC hemorrágico, pois pode levar a danos nas paredes dos vasos sanguíneos do cérebro, causados em sua ruptura e sangramento. A presença de aneurismas aéreos (dilatações dos vasos sanguíneos) e malformações arteriovenosas (anomalias no sistema de vasos sanguíneos) também aumenta o risco de AVC hemorrágico. Os sintomas do AVC hemorrágico incluem dor de cabeça súbita e intensa, náusea, vômito, sonolência, convulsões, perda de consciência e paralisia ou dormência em um lado do corpo. Como mencionado anteriormente, o diagnóstico pode ser feito com base

nos sintomas, exames neurológicos e exames de imagem, como TC ou RM.

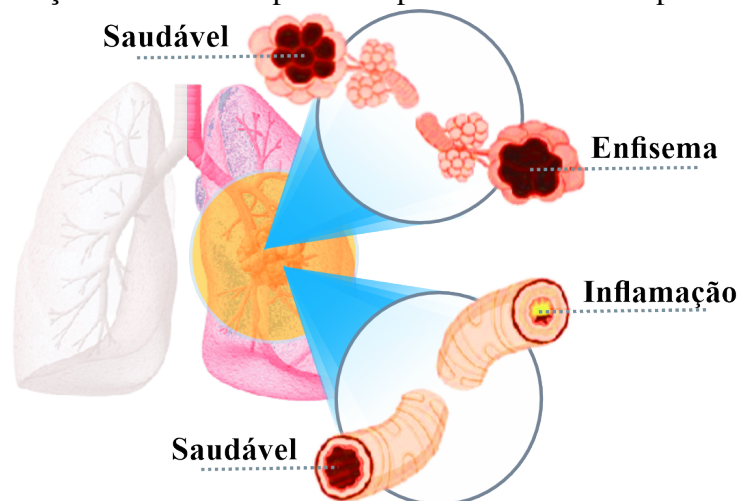
Segundo o artigo "*Management of Intracerebral Hemorrhage*" Thabet *et al.* (2017), o tratamento do AVC hemorrágico depende da causa subjacente da hemorragia e da gravidade dos sintomas. Em alguns casos, a cirurgia pode ser necessária para remover o sangue e aliviar a pressão no cérebro. Em outros casos, os médicos podem optar por medidas conservadoras, como monitoramento da pressão intracraniana e tratamento dos sintomas. Em geral, o AVC hemorrágico tem uma taxa de mortalidade mais alta do que o AVC isquêmico (causado por um coágulo sanguíneo), mas com o tratamento adequado, é possível melhorar a sobrevivência e minimizar a incapacidade associada à condição.

Em resumo geral, o AVC é uma condição médica grave que afeta o cérebro e pode ter consequências devastadoras. A prevenção do AVC passa por um estilo de vida saudável, que inclui uma dieta equilibrada, atividade física regular e abstinência do tabagismo e do consumo excessivo de álcool. O diagnóstico e o tratamento precoce são essenciais para minimizar os danos causados pelo AVC e melhorar as chances de recuperação do paciente.

2.1.2 Doenças Pulmonares

As doenças pulmonares têm uma longa história que remonta à antiguidade. Hipócrates, conhecido como o "pai da medicina", descreveu uma série de doenças respiratórias, incluindo a asma e a pneumonia, nas quais ainda não se tinham detalhes devido ao arcabouço científico da época. No entanto, foi apenas no final do século XIX que os avanços na tecnologia médica permitiram um maior entendimento das doenças pulmonares (SCLAR, 2007).

Figura 4 – Representação ilustrativa de possíveis problemas de saúde pulmonar em humanos.



Fonte: Elaborada pelo autor.

No entanto, a história das doenças pulmonares não é apenas uma história de progresso, a poluição do ar, por exemplo, tem sido associada a um aumento significativo no número de doenças respiratórias. Segundo estudos de Guo *et al.* (2018), a exposição a partículas finas de poluição do ar pode causar doenças pulmonares como a asma e a bronquite crônica.

As doenças pulmonares podem ser denominadas como um grupo de patologias que afetam o sistema respiratório, podendo ocasionar diversos fatores, como; infecções, exposição a substâncias tóxicas, fatores genéticos e hábitos de vida, como o tabagismo, dentre outros. Na literatura podem ser encontrados diversos tipos de patologias entre as mais comuns de doenças pulmonares, bem como suas características. A Figura 4 ilustra diferentes problemas pulmonares causadores de doenças que podem acarretar em sequelas definitivas ou até mesmo levar ao óbito caso não sejam diagnosticadas e tratadas com rapidez.

Recentemente a pandemia de COVID-19, causada pelo novo coronavírus SARS-CoV-2, trouxe muitos desafios para a saúde pública em todo o mundo. Segundo o estudo de Chate *et al.* (2020), desde o início da pandemia, milhões de pessoas foram infectadas e muitas morreram como resultado da doença. Além disso, a pandemia também teve um impacto significativo na economia global e nas relações sociais. Uma das principais complicações da COVID-19 é a Síndrome Respiratória Aguda Grave (SRAG), que pode levar à insuficiência respiratória e à necessidade de ventilação mecânica. A pandemia de COVID-19 tem afetado significativamente a saúde pública em todo o mundo. Um aspecto importante no diagnóstico e tratamento da doença é a utilização de imagens médicas para avaliar a extensão e gravidade da infecção. A TC e a radiografia de tórax são os exames de imagem mais comumente utilizados para avaliar a COVID-19 (MEIRELLES, 2020). A segmentação da região do pulmão em imagens médicas é fundamental para um diagnóstico preciso, delimitar a região de interesse é um fator de extrema importância para classificação de tipos de doenças no pulmão e a relação com o tratamento adequado.

Métodos computacionais são recentemente utilizados nas últimas décadas para diagnóstico com uso de IA para identificar regiões pulmonares, bem como possíveis patologias (SOUZA *et al.*, 2020). Além das técnicas de imagem, também é possível utilizar outros métodos para o diagnóstico de doenças pulmonares, como a espirometria, que avalia a função pulmonar, e a broncoscopia, que permite a visualização direta das vias aéreas e a coleta de amostras para análise.

2.2 Tomografia Computadorizada - TC

A radiografia é uma técnica de diagnóstico por imagem que revolucionou a medicina, permitindo a visualização de órgãos internos, fraturas ósseas e tumores. Com o avanço da tecnologia de diagnóstico radiológico, surgiram equipamentos mais potentes e eficientes, como a TC, que permite a reconstrução tridimensional de estruturas anatômicas com base em dados de transmissão de raios-X. A TC foi desenvolvida pelos cientistas Allan McLeod Cormack e Godfrey Newbold Hounsfield, que receberam o Prêmio Nobel de Medicina e Fisiologia em 1979 por suas contribuições. Cormack foi responsável por desenvolver o conceito matemático fundamental da TC, que envolve a utilização de algoritmos matemáticos para reconstruir imagens tridimensionais do corpo humano a partir de uma série de imagens bidimensionais obtidas por raios-X (HOUNSFIELD, 1980).

A TC funciona como a radiografia convencional, usando a absorção de radiação pelos tecidos para gerar imagens. Um sistema computacional usa algoritmos matemáticos para transformar as informações de densidade radiológica em imagens digitais em tons de cinza. Cada *pixel* recebe um valor numérico inteiro, que representa a densidade radiológica em Unidades Hounsfield (UH). As imagens da TC mostram a espessura da área examinada, e cada ponto da imagem representa um pequeno volume de tecido, chamado de *voxel*. Enquanto o *pixel* representa uma área da imagem, o *voxel* é a menor quantidade de informação que uma imagem pode ter em um espaço tridimensional. Com esses dados, é possível reconstruir imagens em 2D e 3D em diferentes planos, como axial, coronal e sagital.

Uma das tecnologias mais recentes de TC é a tomografia computadorizada de dupla fonte Computadorizada de Dupla Fonte (TCDF), que utiliza dois tubos de raios-X e dois detectores para adquirir imagens em alta velocidade. De acordo com um estudo de Luo e Li (2022), a TCDF oferece melhor qualidade de imagem, menor dose de radiação e maior cobertura corporal em comparação com a TC convencional. Além disso, a TCDF também é capaz de fornecer imagens precisas de áreas do corpo que antes eram difíceis de avaliar, como a região cardíaca e pulmonar. Outra tecnologia promissora é a TC de baixa dose, que utiliza técnicas de reconstrução de imagem avançadas para reduzir a dose de radiação do paciente.

Em geral, as imagens de TCs tem um papel fundamental para o diagnóstico clínico, tornando o processo de decisão mais preciso e possível de acompanhamento do quadro dos pacientes.

2.3 Reconhecimento de Padrões

A busca por padrões em dados tem sido uma área de pesquisa científica que tem como objetivo principal o desenvolvimento de algoritmos e técnicas computacionais para a identificação e classificação de padrões em diferentes categorias ou classes. Tou 1974 define padrões como propriedades que possibilitam o agrupamento de objetos semelhantes dentro de uma determinada classe ou categoria. Embora o reconhecimento de padrões seja um processo natural para o ser humano, é uma tarefa extremamente complexa no contexto da inteligência artificial (JESAN, 2004).

As complexidades cognitivas por trás do reconhecimento de padrões se tornam evidentes quando se tenta reproduzir artificialmente tais habilidades em um computador, o que desafia a comunidade científica interessada no assunto (THEODORIDIS; KOUTROUMBAS, 2003). Com os avanços tecnológicos e a disponibilidade de recursos computacionais, tem sido possível o desenvolvimento e a utilização de importantes métodos e técnicas de reconhecimento de padrões para solucionar problemas pontuais e específicos. Durante as últimas décadas, essa metodologia tem sido aplicada em diversas áreas, como no auxílio ao diagnóstico médico por imagem (SIQUEIRA, 2010; AMBRÓSIO, 2010).


Um sistema de reconhecimento de padrões geralmente é dividido em duas etapas fundamentais: (i) extração e seleção de características ou atributos; e (ii) identificação e classificação de padrões (DUDA; HART, 2006). Os padrões são características de regularidades que podem ser utilizadas para classificar os dados em diferentes categorias (BISHOP; NASRABADI, 2006). Reconhecimento de padrões é, na realidade, uma questão de estimar a probabilidade relativa de um conjunto de dados ser associados a um de um conjunto de populações estatísticas conhecidas que dependem da experiência passada e que formam as informações a priori para o reconhecimento (TOU; GONZALEZ, 1974).

O reconhecimento de padrões é uma área em constante evolução, com novas técnicas e algoritmos sendo desenvolvidos continuamente. Com a crescente disponibilidade de dados e a capacidade computacional cada vez maior, a aplicação de técnicas de reconhecimento de padrões tem o potencial de resolver problemas complexos e melhorar a tomada de decisões em diversas áreas.

2.4 Machine Learning

Machine Learning é uma subárea da IA que se concentra em fornecer às máquinas a capacidade de aprender sem serem explicitamente programadas. Segundo (MITCHELL, 2007), “*machine learning* é um conjunto de métodos que podem detectar padrões em dados e, em seguida, usar esses padrões para interpretar(classificar) dados futuros”. Essa capacidade de aprender e prever a partir de dados históricos tem se mostrado extremamente útil em diversas áreas, como reconhecimento de fala, visão computacional, diagnóstico médico e previsão financeira, entre outras.

Figura 5 – Ilustração de machine learning e suas aplicações.



Fonte: Elaborada pelo autor.

Conforme mostra a figura 5 na parte em vermelho, uma das técnicas de *machine learning* é o uso de algoritmos de aprendizado supervisionado, onde o modelo é treinado com exemplos rotulados e, em seguida, é capaz de fazer previsões precisas para novos exemplos. Segundo (MOHRI *et al.*, 2018), "o objetivo do aprendizado supervisionado é aprender uma função que mapeia as entradas para as saídas correspondentes, dado um conjunto de exemplos rotulados". Isso permite que o modelo generalize para novos dados e possa ser usado em várias aplicações. A técnica de aprendizado de reforço, na parte laranja, permite que aprenda a tomar decisões em um ambiente desconhecido, maximizando uma recompensa acumulada ao longo do tempo. Essa técnica se baseia em um modelo de tentativa e erro, no qual o agente aprende por meio da interação com o ambiente e da obtenção de *feedback* sobre suas ações.

Outra técnica importante em *machine learning* é o aprendizado não supervisionado, como a Figura demonstra 5 na parte azul, onde o modelo é treinado em dados não rotulados e busca encontrar padrões e estruturas nos dados. Esse tipo de técnica é muito útil em aplicações de clusterização e redução de dimensionalidade. A partir do aprendizado não supervisionado, temos as técnicas de redução de dimensionalidade, usadas para reduzir a quantidade de recursos em um conjunto de dados. Essa técnica é útil para lidar com grandes conjuntos de dados que contém muitas características, mas que nem todas essas características são relevantes para a análise. Assim, permitindo que a quantidade de características seja reduzida, mantendo a maioria das informações importantes do conjunto de dados, bem como a clusterização, que é uma técnica para agrupar dados em *clusters* ou grupos semelhantes. De acordo com Jain *et al.* (1999), "a clusterização é o processo de particionar um conjunto de dados em subconjuntos (*clusters*), de modo que os itens em um *cluster* sejam semelhantes entre si e diferentes dos itens em outros *clusters*".

2.5 Redes Neurais Artificiais

Redes neurais artificiais são modelos computacionais inspirados no sistema nervoso biológico que permitem o processamento de dados complexos. Cada neurônio artificial é composto por um conjunto de entradas, pesos sinápticos e uma função de ativação. Segundo Haykin (1998), "uma rede neural é um processador paralelo distribuído, constituído por unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso".

Existem diversos tipos de redes neurais, tais como perceptrons multicamadas, redes neurais convolucionais e redes neurais recorrentes. Cada uma dessas arquiteturas possui suas próprias características e aplicações, sendo que a escolha do modelo adequado depende das necessidades do projeto. As redes neurais perceptrons multicamadas, também conhecidas como *Multilayer Perceptrons* (MLPs), são redes neurais *feedforward* que possuem camadas intermediárias de neurônios, chamadas de camadas ocultas. Essas camadas são responsáveis por aprender representações mais complexas dos dados de entrada, permitindo que a rede possa modelar relações não-lineares entre as variáveis. Segundo (BENGIO *et al.*, 2013), as MLPs são capazes de aprender funções complexas e de alta dimensão, e têm sido aplicadas com sucesso em várias tarefas, como classificação de imagens, reconhecimento de fala, entre outras. Já as redes neurais convolucionais, ou *CNNs*, é pode ser um tipo de rede neural especialmente projetado

para processamento de imagem. Elas possuem camadas de convolução, que são responsáveis por extrair características relevantes das imagens de entrada. Conforme (LECUN *et al.*, 1998), as CNNs são altamente eficazes na tarefa de reconhecimento de objetos em imagens, e têm sido aplicadas em áreas como visão computacional e processamento de linguagem natural. E temos também, as redes neurais recorrentes, ou *Recurrent Neural Networks* (RNNs), possuem conexões recorrentes entre neurônios, permitindo que informações de estados anteriores sejam mantidas na rede. Essa característica torna as RNNs especialmente adequadas para tarefas que envolvem sequências, como previsão de séries temporais e tradução automática. (GRAVES *et al.*, 2013) descreve que as RNNs têm sido aplicadas em várias áreas, como *chatbots*, sistemas de recomendação e análise de sentimento.

2.6 Deep Learning

A ciência trata o entendimento sobre o funcionamento do cérebro, como atividade com extrema complexidade em relação à capacidade de processamento de informação por parte dos neurônios (WALLACE, 2006). A atividade cerebral desempenha inúmeras tarefas simples que requerem percepção, reconhecimento de padrões, tomada de decisões, dentre outras tarefas afins desenvolvidas pelo corpo humano induzida por uma rede de neurônios.

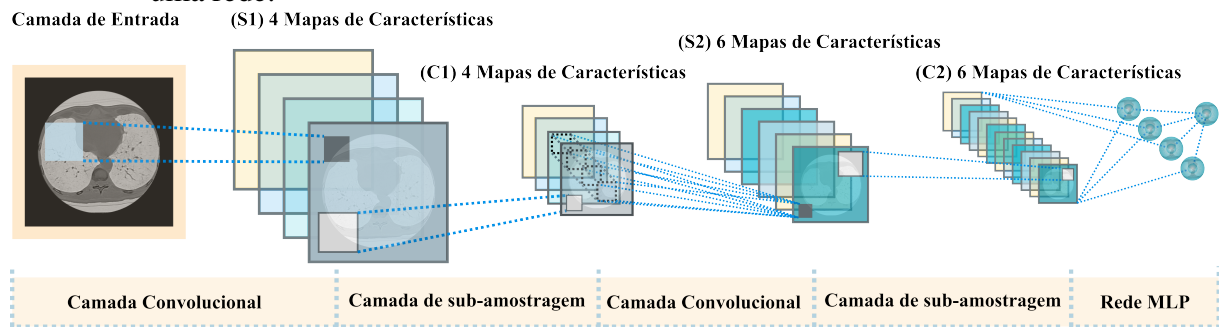
Baseada na rede neural, a computação aplicada a métodos matemáticos e estatísticos por meio da linguagem de programação, simula determinadas atividades de inteligência por meio de máquinas baseadas em conceitos computacionais, envolvendo a lógica computacional, probabilidade e estatística (HAYKIN, 2001). A área de inteligência artificial é uma das principais ramificações da ciência da computação e tem como objetivo construir sistemas capazes de executar tarefas que, para os seres humanos, exigem inteligência, como o reconhecimento de fala, a compreensão da linguagem natural, a tomada de decisão, entre outras (RUSSELL, 2010).

As RNAs têm sido objeto de estudo de diversos pesquisadores nas últimas décadas. Conforme aponta (LECUN *et al.*, 2015), às redes CNNs obtiveram um grande impulso após o sucesso alcançado na competição *ImageNet* em 2012, na qual foram utilizadas mais de 1 milhão de imagens para treinamento e validação. Esse sucesso reforçou a importância das RNAs para tarefas de visão computacional e incentivou o desenvolvimento de novas técnicas e modelos de processamento profundo.

De acordo com (BENGIO *et al.*, 2013), a atividade cerebral é extremamente complexa em relação à capacidade de processamento de informações pelos neurônios. Porém,

as redes neurais artificiais são projetadas para simular o funcionamento do cérebro e realizar atividades específicas, como destaca Haykin (2001). Com o avanço da tecnologia, as RNAs evoluíram para modelos com capacidade de processamento profundo, que apresentam resultados cada vez mais precisos em diversas áreas, como processamento de imagens, reconhecimento de fala e processamento de linguagem natural. Além disso, a capacidade de processamento em *Graphics processing units* (GPUs) têm contribuído significativamente para o desenvolvimento de novas arquiteturas de RNAs (LECUN *et al.*, 2015). Outro aspecto importante é o uso de grandes conjuntos de dados (*big data*) para treinamento, que possibilitam a extração de padrões e a melhoria dos resultados (BENGIO *et al.*, 2013).

Figura 6 – Ilustração de diferentes camadas encarregadas em um processo de convolucional em uma rede.



Fonte: Elaborada pelo autor.

A imagem mostrada na Figura 6 representa o processo das camadas convolucionais intercaladas com camadas de *max-pooling*. As camadas superiores são totalmente conectadas, ou seja, a camada oculta é conectada à regressão logística, sendo que a entrada para a primeira camada é composta por todos os mapas de características da camada.

2.7 Framework Detectron2

A *Detectron2* é um *framework* fomentado pelo grupo de pesquisa em Inteligência Artificial do Facebook (*Facebook AI Research – FAIR*), que foi elaborado a partir de redes neurais convolucionais (WU *et al.*, 2023). Entram em sua implementação algumas redes neurais convolucionais CNNs, como é o caso da *Mask R-CNN*, que já demonstrou alta eficácia em segmentar imagens médicas com base em regiões de interesse (HU *et al.*, 2020).

Esse modelo, pré-treinado com o *dataset* COCO em Lin *et al.* (2014), pode operar em duas etapas de funcionamento: como detector, onde a saída é um *bounding box* que delimita

região da detecção do objeto e sua respectiva classe (XU *et al.*, 2021); e como segmentador, onde a partir da região detectada na etapa anterior, a rede segmenta apenas a forma desejada, a partir de uma classificação dos *pixels* da região interna. Essa classificação dos *pixels* ocorre através da extração de inúmeros atributos *deep*, resultando em uma segmentação de alta performance, com a máscara de saída bem definida (HAN *et al.*, 2020).

Em Marques *et al.* (2022) para ambas as formas de uso, a *Detectron2* pode ter seu treinamento refinado através de uso de *fine-tuning*, onde a rede tem parte de suas camadas treinadas novamente com um *dataset* específico. Assim, o refinamento da *Detectron2* para uma melhor performance na detecção de imagens médicas, pode ser usada através de um *fine-tuning* usando informações de saída da camada da rede.

A arquitetura da *Detectron2*, usada como detector de objetos, pode ser visualizada pela ilustração da Figura 7, onde abordam os diferentes processos para a detecção da região de interesse previamente treinada pelo *framework*.

A arquitetura é subdividida em etapas, sendo elas: (I) *Backbone Network*, onde acontece a extração de atributos e as sucessivas convoluções; (II) FPN, que gera uma pirâmide com os atributos extraídos na etapa anterior; (III) RPN, que gera *Regions of Interest* (ROIs) de detecção para os objetos de interesse; (IV) *ROI Pooling*, onde as ROIs geradas na etapa anterior são redimensionadas para as dimensões específicas da rede da etapa seguinte; (V) *Head*, onde acontece uma classificação das *bounding boxes* detectadas e uma regressão, a partir das detecções em dimensões diferentes, para melhor ajustá-las ao objeto de interesse.

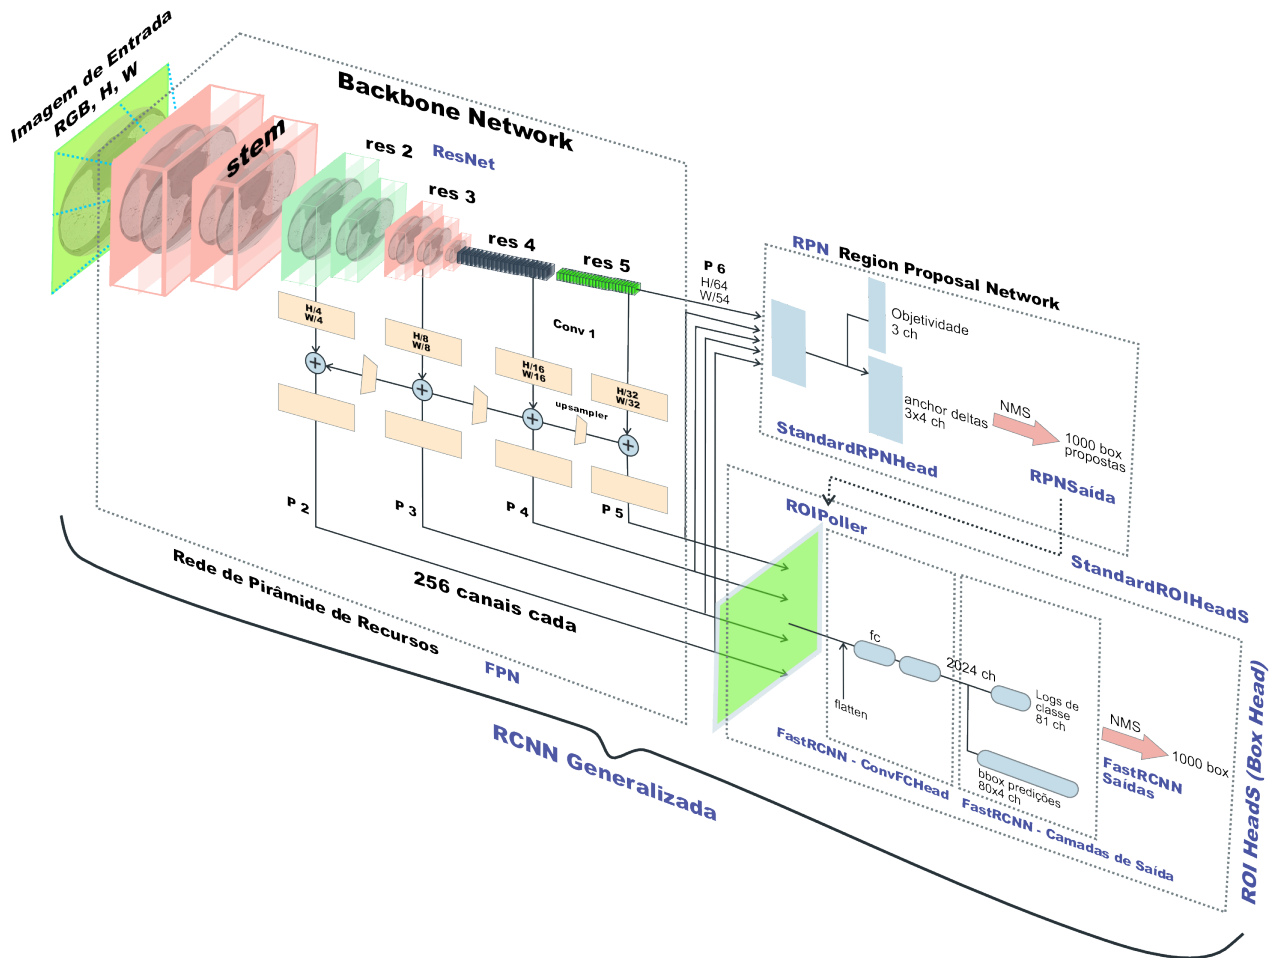
2.8 Transformada de Hough

A Transformada de Hough é uma técnica matemática utilizada em processamento de imagem, capaz de extrair informações, e assim detectar formas geométricas na imagem. A técnica se Hough para detecção de linhas se utiliza da transformação pontos da imagem, em senoides, uma vez que reinterpreta a imagem através da mudança de planos, na qual o plano cartesiano da imagem é reinterpretado através da equação polar da reta utilizadas no estudo de Illingworth e Kittler (1988) que é vista em 2.1.

$$\rho = x.\cos\theta + y.\sen\theta \quad (2.1)$$

onde ρ é a distância da origem da imagem à reta, e θ é o ângulo formado pela reta e

Figura 7 – Representação da arquitetura da *Detectron2*, *framework* para detecção de objetos usada neste estudo.




Fonte: Elaborada pelo autor.

o eixo x , conforme Figura 8. Assim, o processo de transformada de Hough visa encontrar os valores de ρ e θ , que determinam as retas capazes de conectar os pontos da imagem (PAO *et al.*, 1992).

O plano de parâmetros é constituído com base na equação polar da reta, que é aplicada em na imagem digital que passou por processo de binarização, substituindo as coordenadas x e y dos *pixels* com nível de cinza alto (255) por ρ e θ . Sabendo que os valores de θ variam de 0 à 360, conforme ilustrado na Figura 9, além de ter ciência dos valores de X e Y de cada pixel, o valor de ρ dos *pixels* é mapeado no plano de parâmetros (AGGARWAL; KARL, 2006).


Utilizando a equação polar da reta com as coordenadas x e y dos *pixels* presentes no plano da imagem, tais *pixels* são representados na forma de senoide no plano de parâmetros, conforme ilustrado na Figura 10. Dessa forma, após a delimitação de todos os *pixels* do plano da imagem no plano de parâmetros, a reta que traça os *pixels* é definida mediante seleção do ponto

Figura 8 – Ilustração da interpretação da equação Polar da Reta, na qual ρ representa a distância da linha perpendicular que liga a respectiva reta à origem do plano, e θ representa o ângulo da reta em relação à origem do plano, dessa forma, com ambos os parâmetros, é possível localizar qualquer reta existente no plano.



Fonte: Elaborada pelo autor.

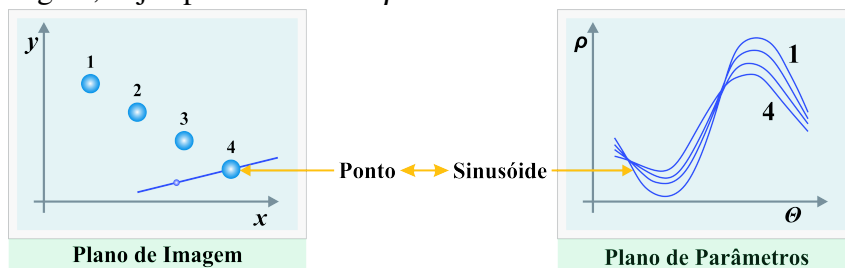
Figura 9 – Figura com a representação das retas passando por todos os *thetas*.



Fonte: Elaborada pelo autor.

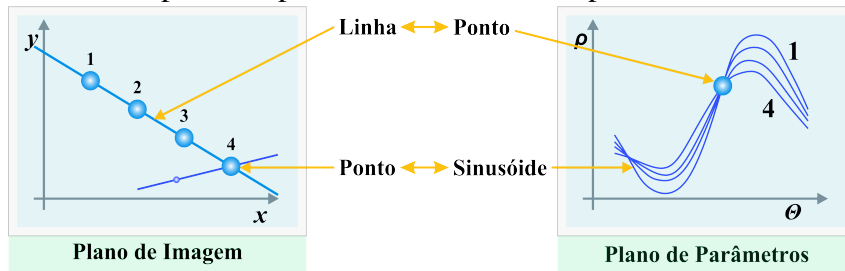
de encontro das senoides no plano de parâmetros, conforme ilustrado na Figura 11.

Figura 10 – Representação dos pontos localizados no plano da imagem, na qual os pontos enumerados de 1 à 4, corresponde as senoides também enumeradas no plano da imagem, cujos parâmetros são ρ e θ .



Fonte: Elaborada pelo autor.

Figura 11 – Processo de detecção da reta que conecta os pontos alinhados, na qual a mesma se manifesta no plano de parâmetros na forma de ponto, com coordenadas ρ e θ .



Fonte: Elaborada pelo autor.

2.9 Aquisição de Imagens Médicas

Esta seção apresenta os diferentes *datasets* utilizados nos experimentos desta tese, onde são divididos por subseções; *dataset* de TC de imagens de AVC hemorrágico, e *dataset* de TC de imagens pulmonares.

2.9.1 Dataset AVC Hemorrágico

O modelo tomográfico utilizado para adquirir as imagens foi o *HiSpeed CT/e Dual* do fabricante General Electric. No processo de aquisição de imagens, os cortes tomográficos foram realizados na base do plano axial, sob as seguintes condições: espessura do corte 0,7 mm, campo de visão 230 mm, tensão elétrica no tubo 120 Kv, corrente elétrica no tubo 80 mA, dimensões 512x512 *pixels* e janelamento do *voxel* 0,585x0,585x1,5 mm com uma quantificação de 16 bits, nível de janelamento de 40 UH e amplitude da janela igual a 80 UH.

As imagens de TC foram obtidas com o apoio da Clínica Trajano Almeida - Diagnóstico por Imagem, e utilizadas em diversos estudos (SARMENTO *et al.*, 2015; REBOUÇAS FILHO *et al.*, 2017b; REBOUÇAS *et al.*, 2017; REBOUÇAS FILHO *et al.*, 2017a; FILHO *et al.*, 2019b; VASCONCELOS *et al.*, 2020; SARMENTO *et al.*, 2020; MEDEIROS *et al.*, 2020; HAN *et al.*, 2020). A base de dados de exames de TC cerebral é composta por 25 exames de pacientes sadios e com AVC (Isquêmico ou Hemorrágico). Por questões de ética, os dados de identificação dos pacientes foram omitidos. Para base de dados de teste foram selecionadas 420 imagens de exames de TC do cérebro. Contendo 140 imagens de pacientes saudáveis e 280 de pacientes com AVC, sendo 100 do tipo AVCh e 140 do tipo AVC isquêmico. As imagens apresentam padrões não-regulares, iluminação irregular e características estruturais diferentes.

2.9.2 *Dataset Pulmonar*

O conjunto de dados usado neste estudo é um conjunto de 39 exames de TC de pulmão no formato *Digital Imaging and Communications in Medicine* (DICOM). Cada exame tem aproximadamente ≈ 333 imagens, portanto, o conjunto de dados é composto por 13.000 imagens: 512×512 *pixels* e resolução de 16 bits. Dessas 13.000 imagens, 1.265 foram segmentadas por um especialista, onde são denominadas na literatura de *ground truth*. O conjunto de dados foi obtido em colaboração com o Hospital Walter Cantídio da Universidade Federal do Ceará (UFC), Brasil, analisado e aprovado pelo Comitê de Ética em Pesquisa. Comitê - COMEPE (Protocolo nº 35/06), dentro dos parâmetros exigidos pela Resolução 196/96 do Conselho Nacional de Saúde. Esse mesmo conjunto de dados também foi usado em alguns dos trabalhos relacionados relatados neste estudo (REBOUCAS *et al.*, 2015; SOUZA *et al.*, 2020; FILHO *et al.*, 2014; FILHO *et al.*, 2017; FILHO *et al.*, 2019b; SOUZA *et al.*, 2020; XU *et al.*, 2021; HAN *et al.*, 2020).

2.10 **Considerações Finais Seção:**

Neste capítulo foi abordada a fundamentação teórica desta tese, trazendo uma breve revisão clínica dos tipos de doenças, bem como as imagens médicas de TC. Foram abordados a delimitação da região afetada por quadro clínico, bem como apresentados conceitos computacionais de contexto para fundamentos teóricos e aquisição das imagens de TC, bem como a descrição dos *datasets* de AVC hemorrágico e imagens pulmonares. O próximo capítulo apresentará a metodologia proposta para segmentação de imagens médicas de TC de AVC e pulmão, que consiste de uma nova abordagem baseada em iniciação automática para método de *Divisible Cell-Segmentation* por meio de células computacionais sintéticas.

3 METODOLOGIA

Neste Capítulo é apresentado o novo método *Divisible Cell-Segmentation* que traz como uma nova abordagem a inicialização automática inteligente adaptativa, baseada em *Deep Learning* para detecção em imagens médicas de TC. O novo método composto por células computacionais sintéticas tem como objetivo encontrar as bordas do objeto de interesse, segmentando-a por meio de conexão celular. O método é uma analogia inspirada no processo de divisão celular biológica realizado pela citocinese, onde uma célula biológica se divide, multiplicando-se em outras células.

Neste capítulo, são apresentadas diferentes seções relacionadas a Metodologia desta tese, como ilustrado na Figura 12. Na seção inicial são apresentadas as aquisições das imagens médicas (TCs. Em seguida são apresentadas as etapas; Etapa 1 (A): na subseção 3.1 Inicialização Automática Adaptativa Inteligente - Abordagem em Imagens Médicas. Etapa 2 (B): subseção 3.2 Segmentação - Método *Divisible Cell-Segmentation*, e Etapa 3 (C): Resultado da Segmentação em TC de AVC hemorrágico e Pulmão.

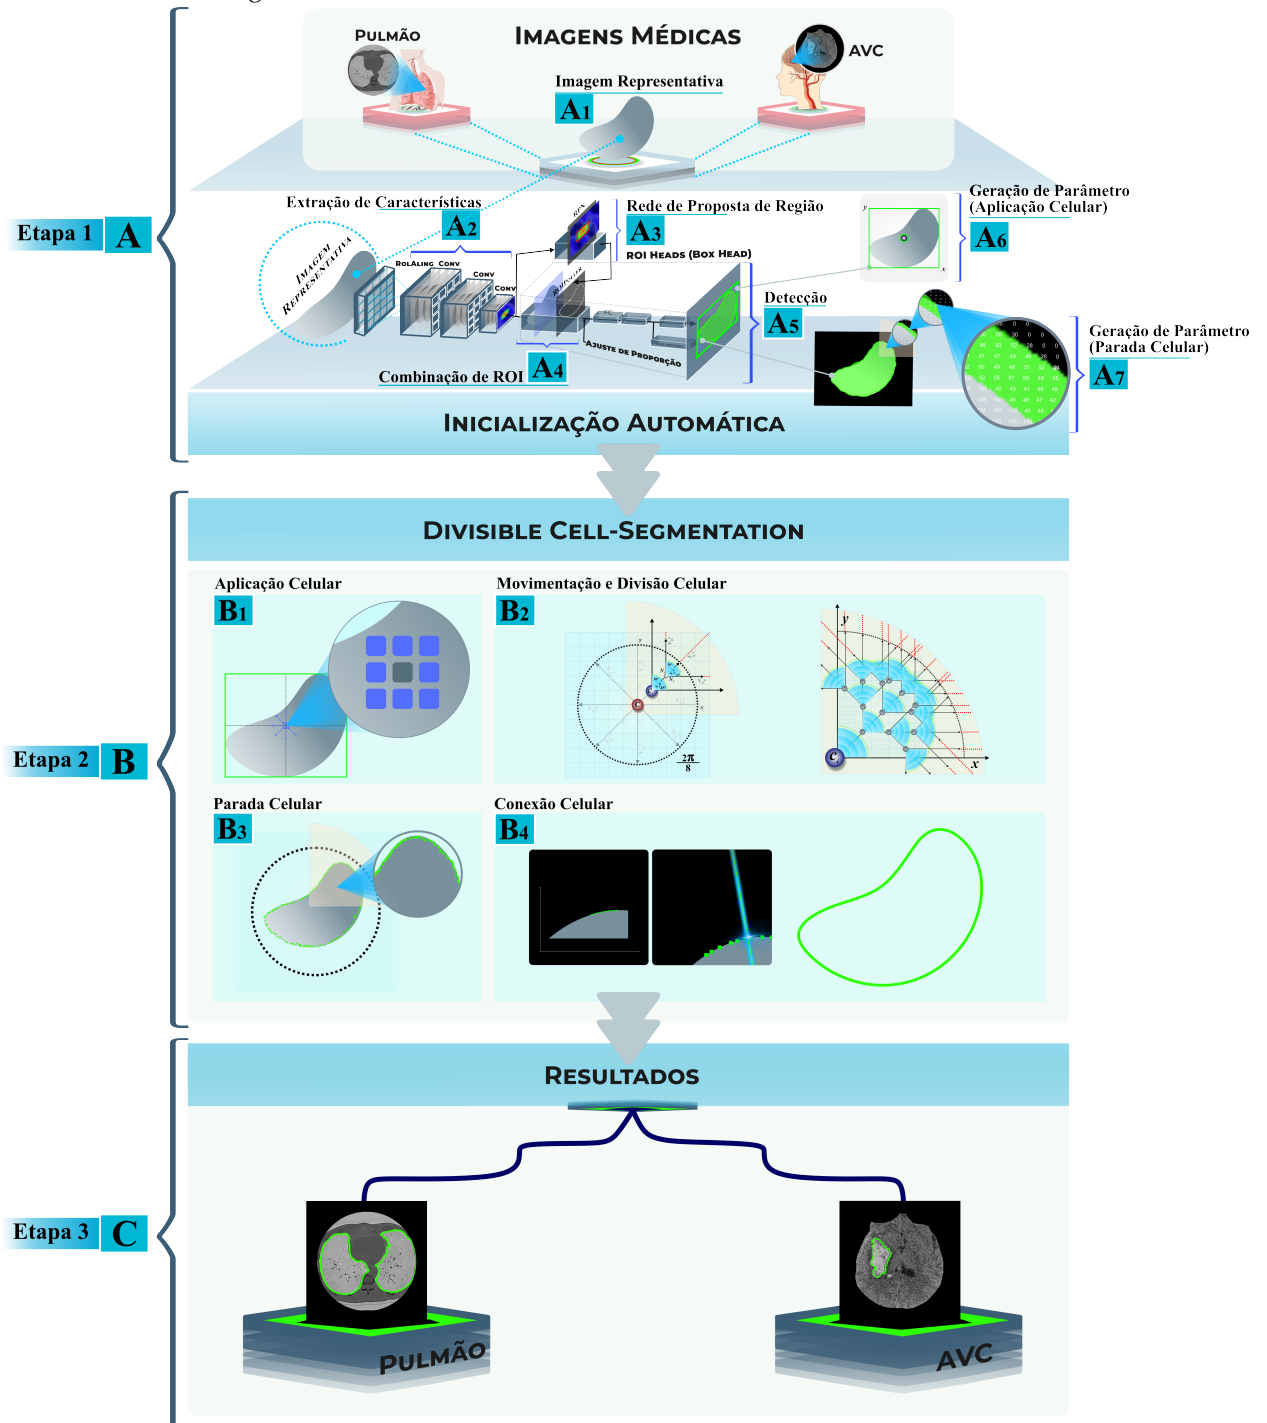
3.1 Etapa 1 (A): Inicialização Automática adaptativa: Abordagem em Imagens Médicas

A Etapa 1 (A) desta Metodologia, traz uma nova abordagem adaptativa para inicialização automática inteligente, baseada em *deep learning* para detecção em imagens médicas de TC. A abordagem utiliza a inicialização inteligente para detecção por meio de *bounding Box* e máscara, para geração de parâmetros adaptativos da célula computacional sintética.

3.1.1 Etapa 1 (AI): Uso de Imagens Médicas de TC e AVC

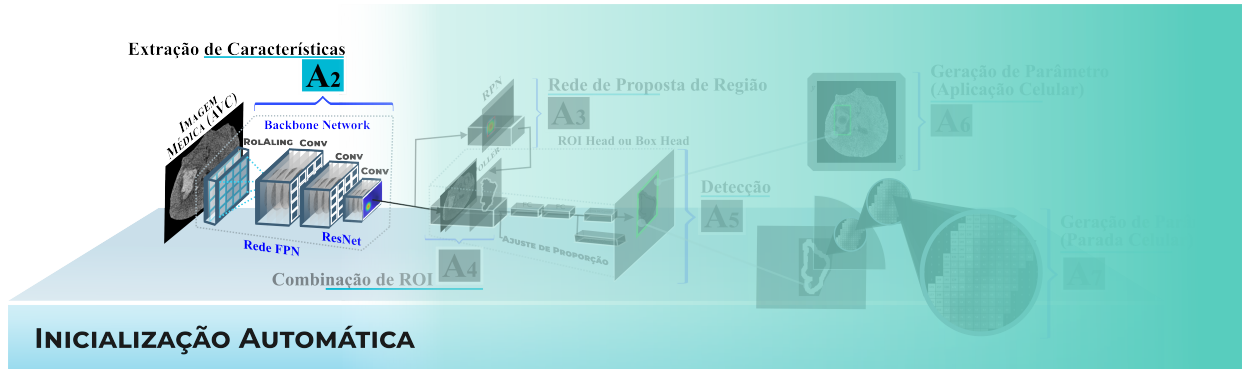
Nesta etapa, o processo de treinamento da base de dados será apresentado. Nesse sentido, para os exames de TC do Pulmão, 1.265 imagens foram utilizadas. Embora o total de imagens seja aproximadamente 13 mil, apenas a quantia usada neste trabalho possuía a marcação do especialista. Já as imagens de TC do cérebro, apenas as lesões de AVC hemorrágico foram utilizadas, totalizando 100 imagens de regiões lesionadas, bem como as marcações do especialista (*ground truth*). Além disso, as imagens foram utilizadas sem nenhum pré-processamento aplicado no modelo proposto, tornando-o totalmente automático. O padrão de divisão dos *datasets* é 80% da base para testes e 20% para treino.

Figura 12 – Ilustração do método proposto. Em (A) abordagem do treinamento para detecção da região de interesse, pela abordagem da inicialização automática inteligente. Etapa 2(B), Inicialização Automática, que tem como finalidade detectar a região a ser segmentada, Etapa 3 (C) Segmentação - Método *Divisible Cell-Segmentation*. E na Etapa 4 (D), ilustra o resultado final da segmentação pelo Método *Divisible Cell-Segmentation*.



Fonte: Elaborada pelo autor.

Figura 13 – Etapa de escolha do extrator de características (*ResNet*) bem como aplicação do processo FPN, que gera em conjunto com o extrator, um mapa de características extraídas de cada imagem médica.



Fonte: Elaborada pelo autor.

3.1.2 Etapa 1 (A2): e FPN

Esta etapa compreende dois processos, *Backbone* e FPN. Essas etapas podem ser visualizadas na Figura 13. Como ilustrado na Etapa A2 da figura, o processo de *BackBone* é responsável pela escolha e aplicação da rede que irá extrair as características das imagens de entrada TC pulmonar e AVC hemorrágico. Nesse sentido, esse trabalho aborda a *ResNet* (descrita na Seção 2.7) como extrator de características para extração de atributos da imagem de TC pulmonar e cerebral. No contexto de imagens, a *ResNet* utiliza blocos residuais para a extração de características, onde cada bloco é representado pela Equação 3.1. Nela, x , que representa a imagem de TC, é a entrada do bloco, F é a função representada pelas camadas convolucionais e W é o conjunto de parâmetros das camadas convolucionais (pesos).

$$y = F(x, W) + x \quad (3.1)$$

A *ResNet* é composta por uma camada de convolução inicial, seguida por quatro blocos residuais e uma camada de média global. Nesse sentido, a saída final da rede é produzida por uma camada totalmente conectada. A fórmula para a *ResNet* é uma composição das fórmulas para os blocos residuais e as camadas convolucionais, como mostrado abaixo na Equação 3.2, onde $F1, F2, F3$ e $F4$ são as funções representadas pelos blocos residuais, $W1, W2, W3$ e $W4$ são os conjuntos de parâmetros das camadas convolucionais dos blocos residuais e y é a saída final da rede, que é o mapa de características extraídas (*feature map*), onde apresenta um mapa com extração de características da região do AVC e regiões do Pulmão.

$$y = F_4(F_3(F_2(F_1(x, W_1), W_2), W_3), W_4) + x \quad (3.2)$$

Em resumo, a *ResNet* utiliza blocos residuais para ajudar a rede a aprender recursos mais complexos e difíceis de serem representados, o que a torna muito eficiente na extração de características de imagens médicas.

O segundo processo que compõe esta etapa é o FPN, amplamente utilizado em pipelines de processamento de imagens médicas para extrair características de diferentes escalas da imagem e melhorar a precisão da detecção de doenças ou anomalias.

No contexto deste trabalho, o FPN recebe uma imagem médica, que é processada pela *ResNet* para produzir um conjunto de características em uma determinada resolução, como ilustrado na Figura 13 Etapa A2. Em seguida, o FPN utiliza um processo chamado "*top-down*" para construir uma pirâmide de características a partir dessas características de base. Cada nível da pirâmide tem uma resolução diferente e representa características de diferentes escalas.

A fórmula matemática para o processo de "*top-down*" é dada pela Equação 3.3, onde P_i é o mapa de características de nível i , U_{i+1} é a camada de *upsample* de nível $i + 1$ e H_i é a camada de convolução de nível i .

$$P_i = H_i(U_{i+1}P_{i+1}) \quad (3.3)$$

A partir da saída da última camada da rede de base, o FPN gera um mapa de características de nível superior das imagens de TC dos pulmões e do cérebro, com uma resolução menor, aplicando uma camada de *pooling*. Em seguida, aplica uma sequência de convoluções para gerar um mapa de características de nível inferior, com uma resolução maior. Esse processo é repetido para cada nível da pirâmide de características, gerando um conjunto de mapas de características de diferentes resoluções.

O FPN utiliza ainda uma técnica chamada "*feature fusion*" para combinar as características de diferentes níveis da pirâmide. Essa técnica permite que a rede processe características de diferentes escalas e melhore a precisão da detecção de doenças ou anomalias em imagens médicas.

A fórmula matemática para a "*feature fusion*" é dada pela Equação 3.4, onde F_i é a característica fusionada de nível i , U_{i-1} é a camada de *upsample* de nível $i - 1$ e H_i é a camada de convolução de nível i .

$$F_i = H_i(P_i + U_{i-1}F_{i-1}) \quad (3.4)$$

Em resumo, o FPN é uma técnica essencial para a análise de imagens médicas, permitindo que a rede neural processe características de diferentes escalas e melhore a precisão da detecção de regiões, doenças, anomalias ou estruturas, como no caso das imagens de TC de AVC hemorrágico e Pulmão.

3.1.3 Etapa 1 (A3): RPN

Figura 14 – Aplicação do processo de RPN no mapa de características extraídas e geradas no processo A2 para gerar possíveis regiões que podem ou não ser as áreas de interesse.



Fonte: Elaborada pelo autor.

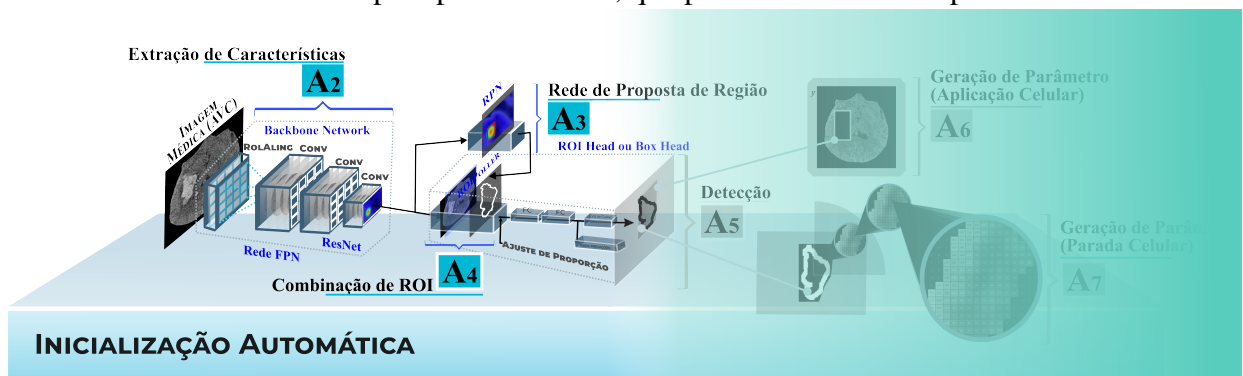
Nesta etapa o processo RPN será explanado. Esse processo pode ser visto na Figura 14 Etapa A3. Nessa etapa, a função da RPN é gerar propostas de regiões candidatas para as imagens de pulmão e AVC. Essas áreas podem conter objetos de interesse. Nesse sentido, a RPN é implementada como uma rede neural convolutiva que recebe a saída de uma camada convolutiva de uma rede base (*ResNet*) e gera propostas de regiões candidatas. Essas propostas são geradas por meio da convolução de uma janela deslizante sobre a saída da camada convolutiva. A cada posição da janela, a RPN gera várias propostas candidatas de diferentes tamanhos e aspectos, que são ajustadas para melhor se encaixar nas características da região da imagem correspondente. A saída da RPN consiste em um conjunto de propostas candidatas, cada uma com uma pontuação que indica a probabilidade de conter um objeto. A equação da RPN é dada por 3.5.

$$P_{i,j} = \text{softmax}(W \cdot \phi(x_{i,j})) \quad (3.5)$$

onde $P_{i,j}$ é a probabilidade de que a j -ésima proposta candidata na posição i na grade da janela deslizante seja uma região de objeto, $x_{i,j}$ é a entrada da RPN na posição i,j , ϕ é uma função de extração de características e W é a matriz de pesos da RPN.

3.1.4 Etapa 1 (A4): Combinação de ROI

Figura 15 – Aplicação do processo *ROI Pooling*, que une a saída do processo da Figura 14 Etapa A3 com a imagem de entrada em cada nova dimensão. A imagem de entrada é redimensionada pelo processo FPN, que pode ser visto na Etapa A2.



Fonte: Elaborada pelo autor.

Essa etapa, conhecida como *ROI Pooling*, é responsável por extrair características de regiões de interesse ROIs, resultantes da etapa anterior RPN em imagens de pulmão e de AVC. As entradas da *ROI Pooling* são: uma imagem e uma lista de ROIs, cada uma representada por quatro coordenadas que definem a posição do *bounding box* na imagem. A saída é um tensor tridimensional que contém as características das ROIs.

O funcionamento da *ROI Pooling* envolve três etapas principais, que podem ser vistas na Figura 15 Etapa A4: (1) dividir cada ROI em uma grade regular de sub-regiões, (2) extrair a característica mais relevante de cada sub-região e (3) concatenar as características em um único tensor que representa a ROI.

Formalmente, dada uma imagem de entrada I com dimensões $H \times W \times C$ e uma ROI definida por suas coordenadas (x,y,w,h) , a *ROI Pooling* divide a ROI em uma grade $S \times S$ de sub-regiões, onde S é um parâmetro configurável. Cada sub-região tem dimensões $s \times s$, onde $s = \text{ceil}(h/S)$ e $s = \text{ceil}(w/S)$. Em seguida, a *ROI Pooling* extrai a característica mais relevante de cada sub-região da imagem I usando a Equação 3.6. Nela, R é o tensor de características resultante, i e j são as coordenadas da sub-região na grade e k é o índice da dimensão do canal.

$$R_{i,j,k} = \frac{1}{s^2} \sum_{x=i \cdot s}^{(i+1) \cdot s - 1} \sum_{y=j \cdot s}^{(j+1) \cdot s - 1} I_{x,y,k} \quad (3.6)$$

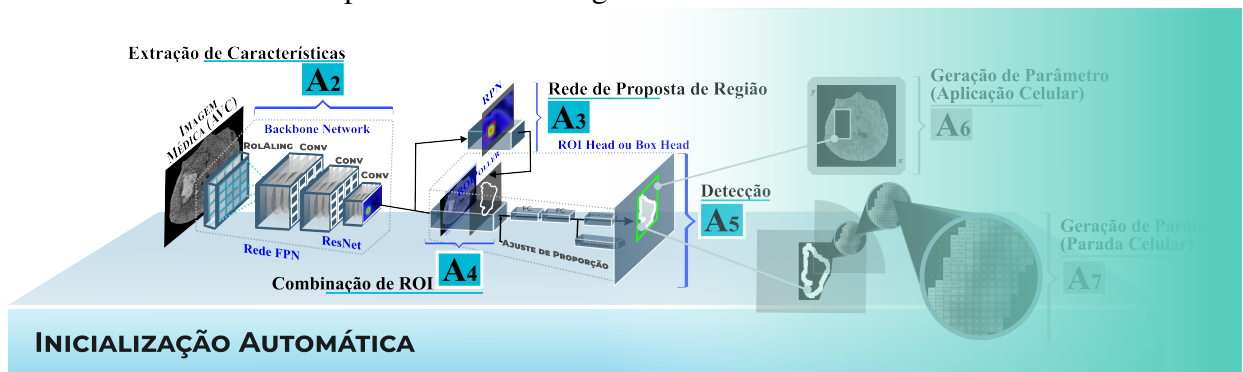
Finalmente, a *ROI Pooling* concatena os tensores de características de todas as sub-regiões em um único tensor que representa a ROI, onde F é o tensor resultante que representa a ROI r e k é o índice da dimensão do canal.

$$F_{r,k} = \text{concat}(R_{1,1,k}, R_{1,2,k}, \dots, R_{S,S,k}) \quad (3.7)$$

Dessa forma, a *ROI Pooling* extrai as características mais relevantes de cada ROI na imagem de AVC ou pulmão de entrada, que podem ser usadas como entrada para uma rede neural treinada para realizar a tarefa de detecção de objetos.

3.1.5 Etapa 1 (A5): ROI Head ou Box Head

Figura 16 – Aplicação do processo de ROI Heads que consiste em duas etapas: Aplicação de um regressor, que é responsável por reduzir a imagem de entrada para o padrão que a rede de classificação recebe. Aplicação do classificador para atribuir às marcações obtidas na Etapa A3 da referida figura.



Fonte: Elaborada pelo autor.

Essa etapa é responsável por realizar a detecção do objeto de interesse (pulmão ou AVC) em ROIs extraídas das imagens pela *ROI Pooling*. A *Box Head* é uma rede neural que recebe como entrada as características das ROIs e produz como saída as probabilidades de classe e as *bounding boxes* dos objetos de interesse presentes em cada ROI. Sua entrada é precisamente um tensor tridimensional que representa as características das ROIs, extraídas pela etapa anterior. A saída é um tensor bidimensional que contém as probabilidades de classe e as *bounding boxes* dos objetos presentes em cada ROI.

O funcionamento da *Box Head* envolve duas etapas principais, que podem ser analisadas na Figura 16 Etapa A5: (1) extrair as características das ROIs usando uma rede neural e (2) usar essas características para prever as probabilidades de classe e as *bounding boxes* dos objetos presentes em cada ROI. A segunda etapa envolve o uso das características produzidas pela *ResNet* para prever as probabilidades de classe e as *bounding boxes* dos objetos presentes em cada ROI. Essa previsão é realizada usando duas camadas de saída: uma camada de saída para as probabilidades de classe e uma camada de saída para as *bounding boxes*.

Formalmente, dado um tensor de características F para uma ROI, a *Box Head* produz as probabilidades de classe P e as *bounding boxes* B usando as Equações 3.8 e 3.9. Nas Equações, W_c , W_b , b_c e b_b são os parâmetros da *Box Head* que são aprendidos durante o treinamento. A equação (1) usa uma camada totalmente conectada com ativação *softmax* para produzir as probabilidades de classe, enquanto a equação (2) usa uma camada totalmente conectada para produzir as *bounding boxes*.

$$P = \text{softmax}(W_c \cdot F + b_c) \quad (3.8)$$

$$B = W_b \cdot F + b_b \quad (3.9)$$

Dessa forma, a *Box Head* é responsável por produzir as probabilidades de classe e as *bounding boxes* dos objetos presentes em cada ROI, que são posteriormente usadas pela etapa de pós-processamento para gerar as detecções finais.

Esta é uma etapa utilizada nesta metodologia para inicialização da segmentação das imagens médicas, e suas estruturas previamente detectadas. Com o processo de segmentação a ser realizado na Etapa 2 *Divisible Cell-Segmentation* proposto da seção 3.2 Etapa 2: Segmentação - Método *Divisible Cell-Segmentation*.

Inicialmente o processo de inicialização passa pelo para as diferentes imagens médicas (TC de AVC hemorrágico e TC Pulmonar). São treinados em paralelo, gerando pesos diferentes para cada tipo de imagem médica.

O processo de inicialização e seus resultados, que será usado como *fine-tuning* para melhor detectar as ROIs em imagens médicas a serem segmentadas, utilizou-se tais parâmetros: divisão entre treino e teste de 80%/20%, em estratégia de *cross-validation* usando *K-fold* com 3 *folders*. Além de um número máximo de iterações de 1000, 2 imagens por *batch* e o tamanho

do *batch* por imagem de 512 para TC. Utilizou-se também uma taxa de aprendizado (*learning rate*) de 0,00025 e 2 *workers*. Vale destacar que apenas uma classe era utilizada para detecção (a depender do *dataset* de imagens médicas) e que as camadas da rede que foram treinadas foram da camada *R50FPN3X* (baseado na *Mask R-CNN* como rede neural) e camadas posteriores.

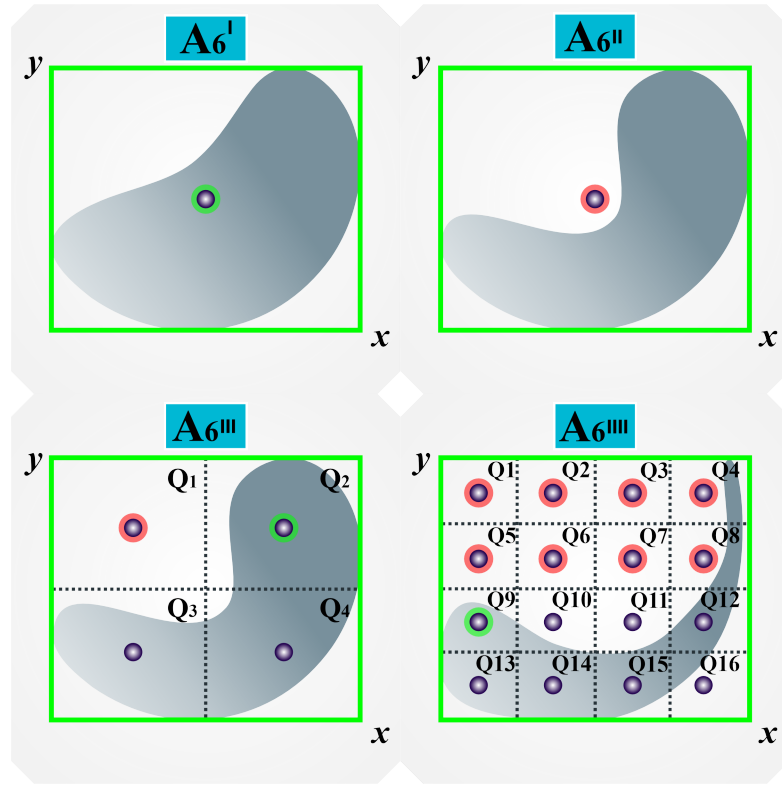
A Etapa 1 refere-se a abordagem de inicialização automática inteligente para a obtenção de parâmetros de segmentação adaptativa proposta pelo novo método *Divisible Cell-Segmentation*. A imagem (A1) representa a imagem de entrada dentro da abordagem de inicialização do método, em (A2) ilustra o processo de extração de características por meio de convoluções da imagem de entrada, em (A3) Rede de proposta de região, na qual gera uma proposta candidata de região para a imagem médica, em (A4) é ilustrado o processo de extração de características da região de interesse, em A5 é realizada a etapa da detecção da região da imagem médica. Em A6 é gerado o parâmetro de aplicação da célula computacional sintética, a ser segmentada, e por fim a em A7 é realizada a geração de parâmetro de parada celular adaptativo ótimo. Próxima seção, em Etapa 2 B, abordará o novo método de segmentação de imagens médicas, método *Divisible Cell-Segmentation*.

3.1.6 Etapa 1 (A6): Geração de Parâmetros da Aplicação Celular

Nesta etapa do processo de segmentação de imagens médicas, obtemos um ponto de inicialização da célula que será usado na Etapa 2. Deste modo, é proposta uma metodologia baseada na Inicialização do Método de Árvore de Quadrantes para encontrar um ponto ótimo de inicialização. Assim, baseado nesta abordagem, a metodologia proposta assegura que o ponto de inicialização estará posicionado dentro da região de interesse do objeto detectado. A Figura 17 ilustra o processo de varredura e seccionamento da imagem em quadrantes para a obtenção do ponto de inicialização da aplicação celular, a ser utilizado na Etapa de Aplicação Celular, Subseção 3.2.1.

O algoritmo de Inicialização do Método de Árvore é baseado no seccionamento da imagem de entrada em quadrantes. De acordo com a equação 3.10 seja pi um ponto nas coordenadas (x,y) em uma imagem de entrada I , considere k um número inteiro positivo e não nulo, a intensidade de $p(x,y)$ deve pertencer ao intervalo $[k, L-1]$, onde L é a intensidade máxima dos *pixels* na imagem, pi então poderá ser usado como coordenada de inicialização do método. Caso pi não satisfaça às condições, a imagem será seccionada em quadrantes, cada novo quadrante será então analisado em busca do ponto p de inicialização.

Figura 17 – Processo de divisão da imagem em quadrantes. Processo recursivo na qual realizada a parada quando um ponto $P_i(x,y)$ é encontrado, obedecendo aos critérios estabelecidos na Equação 3.10



Fonte: Elaborada pelo autor.

$$p_i = \begin{cases} p(x,y) & \left| \begin{array}{l} p(x,y) \in [k, L-1], \text{ onde } k \in \mathbb{Z}_+^* \end{array} \right. \end{cases} \quad (3.10)$$

Quando o ponto $p(x,y)$ não satisfazer a Equação 3.10, a imagem é dividida em quadrantes de forma recursiva, até que o ponto p_i seja encontrado. As Equações 3.13 descrevem a lógica de divisão da imagem em quadrantes. Sendo que o número de quadrantes que obedecem à Equação 3.11 e 3.13. Para uma melhor análise das equações de divisão da imagem em quadrantes, usamos a Figura 17 $A6^{III}$ para ilustrar as coordenadas x e y .

Seja I_m a imagem de entrada e Q_{search} uma função recursiva para a busca do ponto p_i de inicialização, considere Q_{search} definido como:

$$Q_{search}(I_m) = \begin{cases} p(x,y) , \text{ se } p(x,y) = p_i \\ \phi , \text{ se } \frac{1}{M \times N} \sum_{p \in I_m} p(x,y) \leq L_{min} \\ \max \begin{cases} Q_{search}(Q_1) \cup Q_{search}(Q_2) \\ \cup Q_{search}(Q_3) \cup Q_{search}(Q_4) \end{cases} \end{cases} \quad (3.11)$$

onde $p(x,y)$ é um *pixel* na imagem I_m , já, Q_1, Q_2, Q_3 e Q_4 são definidos como partições da imagem I_m . Considere I_m uma matriz de dimensões $M \times N$, podemos definir os índices de Q_1 tais como:

$$(q_{1i}, q_{1j}) \in \{0, \dots, \frac{M}{2}\} \times \{\frac{N}{2}, \dots, N\}, \quad (3.12)$$

de forma semelhante, definimos Q_2, Q_3 e Q_4 :

$$\begin{aligned} (q_{2i}, q_{2j}) &\in \{\frac{M}{2}, \dots, M\} \times \{\frac{N}{2}, \dots, N\}, \\ (q_{3i}, q_{3j}) &\in \{0, \dots, \frac{M}{2}\} \times \{0, \dots, \frac{N}{2}\}, \\ (q_{4i}, q_{4j}) &\in \{\frac{M}{2}, \dots, M\} \times \{0, \dots, \frac{N}{2}\} \end{aligned} \quad (3.13)$$

Nesse sentido, o ponto central da imagem de saída da Etapa 1 A5 é analisado. Se ele não satisfazer a condição observada na Equação 3.10, a imagem é dividida em quatro quadrantes, conforme observado na Equação de divisão de quadrantes 3.13. Entretanto, a partir da primeira divisão da imagem em quadrantes, uma operação de média é aplicada em toda a região. Isso é realizado para reduzir o custo computacional do método, pois, quando a média de um quadrante for igual a zero, ele pode ser descartado. Esse descarte de área não é prejudicial porque se a média da região for menor ou igual ao limiar L_{min} , não existe objeto dentro dela. Dessa forma, ao final do processo, um ponto $p(x,y)$ será encontrado e usado como inicialização do método proposto.

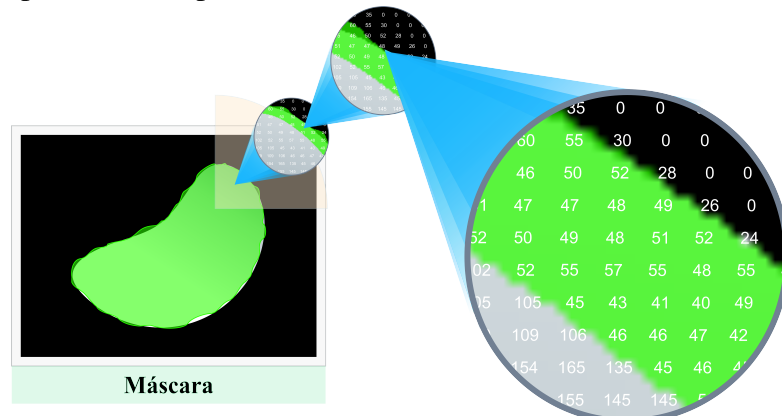
A Figura 17 ilustra a busca adaptativa por um ponto ótimo que servirá de inicialização na Etapa 3. Dessa forma, em $A6^I$, temos um exemplo de uma região que não precisa ser seccionada em quadrantes para encontrar o ponto ótimo de inicialização, pois o ponto central da imagem satisfaz a Equação 3.10. Em contrapartida, o item $A6^{II}$ ilustra um objeto em que o ponto central dele não satisfaz a Equação 3.10. Nesse caso, o item $A6^{III}$ ilustra o processo de divisão dessa mesma imagem em quadrantes. Como pode-se observar, o quadrante Q1 dessa figura não contém nenhum objeto de interesse, logo, a média dele é igual a zero. Isso acontece porque o resultado da Etapa 1 A5 retorna uma imagem onde a região de interesse sempre apresenta os valores de *pixels* maiores que zero. Dessa forma, a busca pelo ponto de inicialização passa para o quadrante Q2, onde o ponto central desse quadrante satisfaz a Equação 3.10. Por outro lado, a Figura $A6^{III}$ ilustra um objeto que não obedece às regras da equação 3.10. Nesse sentido, a imagem sofre uma nova divisão de quadrantes. Esse processo continua indefinidamente até que um ponto que satisfaça a Equação 3.10 seja encontrado.

3.1.7 Etapa 1 (A7): Geração de Parâmetros de Parada Celular Adaptativo

Após a detecção da região de interesse pela inicialização automática inteligente, é realizada a geração de parâmetro de parada adaptativo das células computacionais sintéticas, que irão dar início ao processo de segmentação após aplicação iniciada na etapa (B-1), como ilustrado na Figura 12.

O processo adaptativo de geração do parâmetro de parada celular, é baseado no limiar da região do entorno da máscara gerada pela inicialização automática sobre a imagem original de entrada. Na qual é aplicado o processo de gradiente morfológico, que corresponde o entorno da região de interesse, com elemento estruturante quadrado 5X5 para gerar uma imagem — mapa binário, que quando aplicada sobre a imagem de entrada, gera o mapa do limiar, na qual é obtido o valor do *threshold* utilizado para definir o parâmetro de parada da imagem de entrada, como ilustrado na Figura 18.

Figura 18 – Representação da área (mapa de limiar) a ser calculada pelo gerando o *threshold* para parâmetro de parada celular.



Fonte: Elaborada pelo autor.

O gradiente morfológico pode ser interpretado pela equação 3.14, onde:

$$GM = (A \oplus B) - (A \ominus B) \quad (3.14)$$

na qual, GM representa a operação de gradiente morfológico, A representa a imagem do exame de TC, B representa o elemento estruturante. Desta forma, pode-se dizer que o gradiente morfológico é obtido pela subtração da imagem dilatada (\oplus) pela imagem erodida (\ominus). (GONZALEZ *et al.*, 2009).

A Dilatação morfológica, é representada por \oplus , descrita pela equação 3.15.

$$A \oplus B = \{Z | [(B)_z \cap A] \subseteq A\} \quad (3.15)$$

na qual a dilatação A por B é o conjunto de todos os deslocamentos Z de forma que (\hat{B}) e A se sobreponham por pelo menos um elemento (GONZALEZ *et al.*, 2009). Já a Erosão morfológica, representada pela por \ominus , é descrita na equação:

$$A \ominus B = \{Z | (B)_z \subseteq A\} \quad (3.16)$$

onde a erosão de A por B é o conjunto de todos os pontos Z da imagem do exame, de forma que B , transladado por Z , está contido em A .(GONZALEZ *et al.*, 2009)

Após a obtenção do gradiente morfológico obtido com base na Equação 3.14, é aplicada outra dilatação sobre o gradiente morfológico para, então, ser gerado o mapa do limiar, que consiste na multiplicação do gradiente morfológico com a imagem de entrada, de maneira a preservar o entorno da área a ser calculada, resultando no *threshold*, que será utilizado pela célula computacional sintética como parâmetro de para celular, cujo a finalidade é a expansão celular máxima dentro da região de interesse detectada. A equação 3.17 representa a definição do *threshold* baseado na média do limiar.

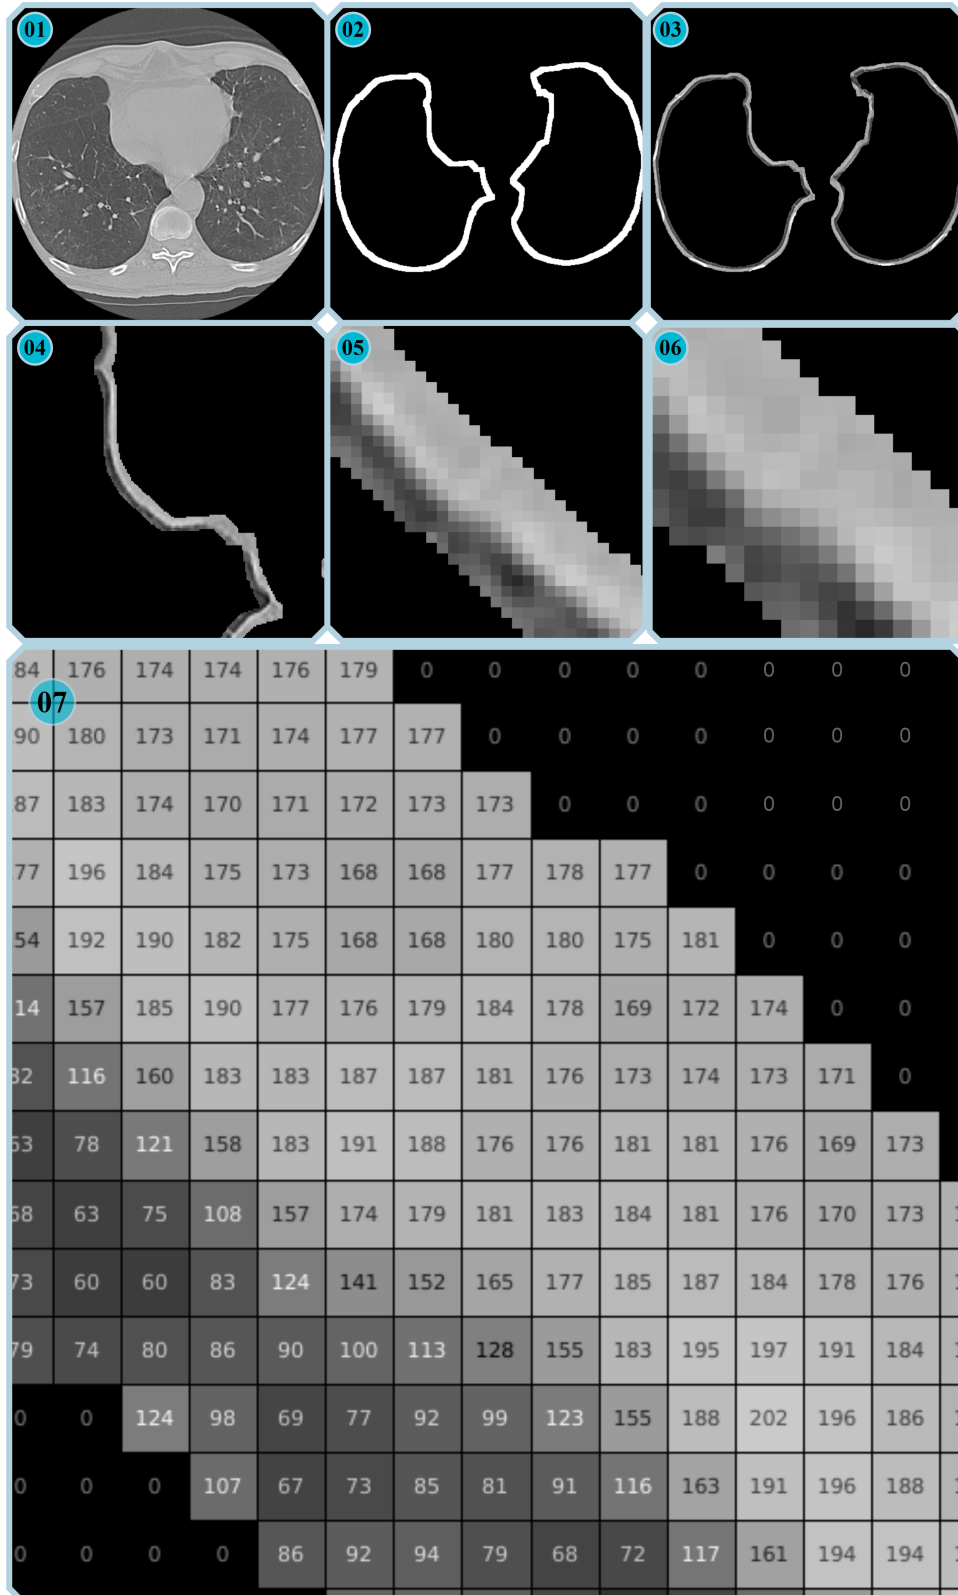
$$0 \leq f(x,y) \leq W \text{ onde,} \quad (3.17)$$

onde n é o número de *bits* presentes no mapa do limiar, na qual (x,y) é o par de coordenadas dos *pixels*; $f(x,y)$ é o nível de cinza do pixel dado em função de (x,y) ; W é o máximo valor da escala de cinza, definido por: $W = (2^n - 1)$. Desta forma, é feito o somatório dos níveis de cinza $f(x,y)$ em cada ponto do mapa do limiar para calcular a sua média.

A Figura 19 apresenta os estágios correspondentes ao processo da Etapa A (6) aplicada a TC pulmão, ilustrada na Figura 12 da Metodologia. Em 01 na Figura 19 está a imagem do exame de TC, em 02, a máscara inicial, 03 ilustra o resultado do gradiente morfológico aplicado sobre a máscara binária, 04 representa a aplicação do gradiente sobre a imagem do exame, gerando assim, o mapa do limiar, que ampliado em 05 até 07.

onde é gerado o parâmetro de parada celular adaptativo correspondente a imagem de entrada, com isso é atribuído o valor do *threshold* com base no mapa do limiar da imagem.

Figura 19 – Demonstração do processo de criação do mapa do limiar, com a aplicação do gradiente morfológico sobre a imagem do exame, onde será extraída o *threshold* sendo o valor médio do limiar, para o parâmetro de parada condicional da célula sintética.



Fonte: Elaborada pelo autor.

3.2 Etapa 2 (B): Segmentação — Método *Divisible Cell-Segmentation*

A Etapa 2 (B) da metodologia proposta por este estudo, aborda a etapa de segmentação em imagens médicas realizadas pelo novo método *Divisible Cell-Segmentation* proposto, baseado em células computacionais sintéticas capazes de se dividirem e multiplicarem até a borda do objeto de interesse, com a finalidade de segmentar a região por meio de conexões celulares.

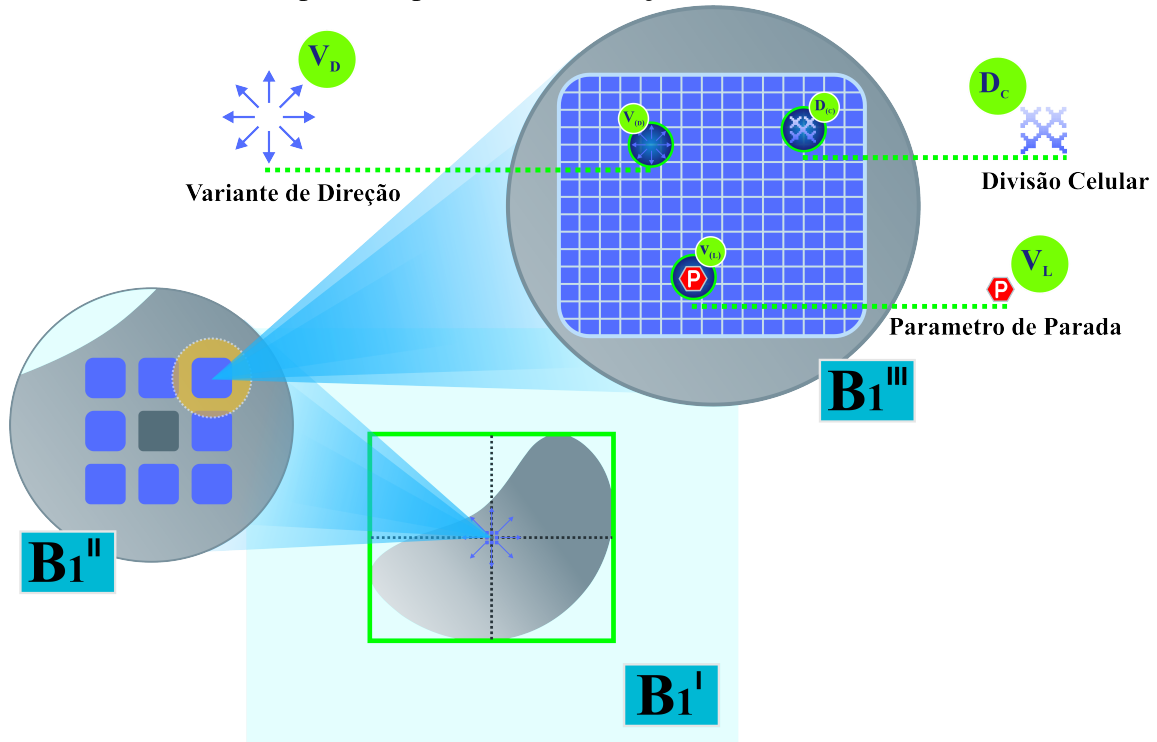
Nesta seção são apresentados os estágios da Etapa 2 (B), ilustrado pela Figura da Metodologia, Figura 12, onde traz como proposta a segmentação das imagens de TC de AVC hemorrágico e pulmão de forma, pós-inicialização automática adaptativa para segmentação da região de interesse.

3.2.1 Etapa 2 (B1) - Aplicação Celular (Célula Computacional Sintética)

Na literatura relacionada à biologia, célula é a unidade estrutural e funcional dos seres vivos, uma estrutura complexa e altamente organizada, composta de uma variedade de funções nas quais produzem seus componentes. Dentre as funções celulares, a mitose é um tipo de Divisão Celular que resulta na formação de células-filhas, apresentando o mesmo número de cromossomos que a célula-mãe. (ALBERTS *et al.*, 2015). Levando em consideração este conceito biológico, o método *Divisible Cell-Segmentation* traz uma análoga à divisão celular mitótica, onde a célula computacional sintética se divide dentro de um espaço matricial, simulando o processo de análogo à citocinese da mitose celular. O conceito inspirado neste processo, faz com que a célula computacional sintética carregue em sua estrutura, informações referente a seu comportamento, bem como sua funcionalidade. Como ilustrado na Figura 20, a célula computacional sintética carrega em si informações relacionadas ao variante de direção (Variante de Direção (VD)), representado por V_D , Divisão celular, representado por D_C e o parâmetro de Parada representado por P , onde é atribuído o valor recebido no processo de inicialização automática adaptativa, armazenado por V_L , respectivo valor do limiar.

Após a inicialização do método, é dada início à etapa de aplicação celular, representado pela equação 3.20 onde o centroide representado por C na expressão, recebe a célula c_i com variante de direção V_D e o parâmetro de parada P de acordo com seu respectivo índice dentro do espaço bidimensional. Isso corresponde aos agrupamentos de c_i , células posicionadas de acordo com o centroide a ser percorrido na matriz no ponto I , que corresponde ao ponto inicial da célula

Figura 20 – Representação em escala de uma célula computacional sintética, representando seus parâmetros internos. Em $B1_I$ é possível notar a região de interesse com as células computacionais sintéticas iniciais, em $B1_{II}$, as células computacionais sintéticas iniciais tem sua escala ampliada para ilustrar os parâmetros de função, e Em $B1_{III}$, tem-se a ilustração da ampliação de uma única célula computacional sintética inicial, com seus respectivos parâmetros de função, isto é V_D , D_C e V_L .



Fonte: Elaborada pelo autor.

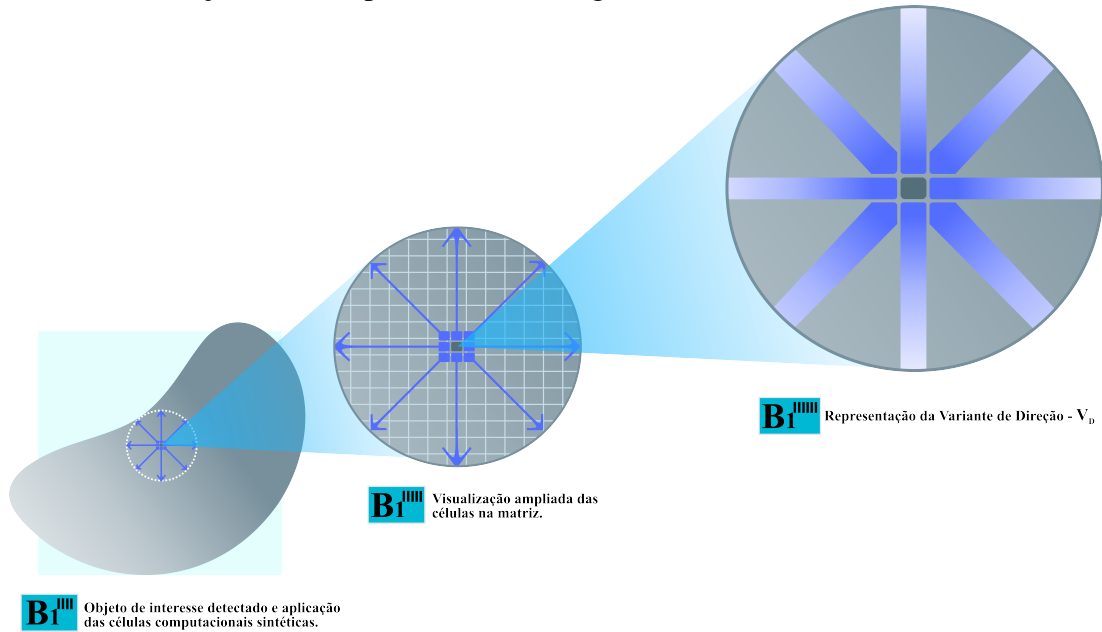
na inicialização do método. Onde cada célula tem sua posição inicial estabelecida de acordo com o índice dentro do plano inicial da matriz, que carrega os parâmetros de parada referente à região do limiar, realizada na Etapa 1 (A) de inicialização automática inteligente. O vetor variante de direção, que direciona os passos de movimentação da célula, é definido a partir de uma distância de um passo, nas coordenadas x e y , $step\ x$ e $step\ y$, respectivamente. Neste caso, considere a função de coordenadas que serão analisadas pela célula c_i

Seja Bbx e Bby a largura e a altura do *bounding box* respectivamente, o vetor V_D é definido como:

$$V_D \leftarrow \{f_{div}(c_{ix}, c_{iy}); *\} \quad (3.18)$$

tal que f_{div} é uma função recursiva, c_{ix} e c_{iy} são as coordenadas do ponto inicial c_i e $*$ é o ângulo que define a direção do movimento da célula. A função f_{div} é definida como:

Figura 21 – Processo de região de movimentação das células computacionais sintéticas, na qual cada célula tem sua direção e sentido indicado pelo variante de direção de acordo com o seu respectivo índice. Em $B1^{IIII}$ é possível visualizar o objeto de interesse definido e a aplicação das células computacionais sintéticas iniciais. Em $B1^{IIIII}$ está destacada a visualização ampliada das células computacionais sintéticas na matriz, composta por 8 células iniciais. Em $B1^{IIIIII}$ está a representação da região variante de direção V_D a ser percorrido na imagem.



Fonte: Elaborada pelo autor.

$$f_{div}(x_k, y_k) = \begin{cases} \emptyset, se & x_k + step_x > B_{bx} \text{ e} \\ & y_k + step_y > B_{by} \\ (x_k, y_k) \cup f_{div}(x_k + step_x, y_k + step_y) & \end{cases} \quad (3.19)$$

$$C \leftarrow G_c(V_D, P(V_L)) \quad (3.20)$$


onde $C = pi$

onde a variante de direção V_D é dada pela equação 3.18, na qual a função de divisão f_{div} é dada pela equação 3.19, dessa forma, a região de inicialização C , recebe o grupo de células sintéticas computacionais G_c com os parâmetros da aplicação celular. Vale ressaltar que região de inicialização é equivalente ao ponto pi , obtido na Etapa 1 (A6), seção 3.1.7. A variante de direção pode ser abordada na Figura 21, na qual as variantes individuais de direção das células computacionais V_D^* pode ser demonstrada na forma de vetor.

A Figura 21 ilustra a região de movimentação das células computacionais sintéticas a serem percorridas dentro da imagem, cada célula tem sua direção indicado pelo variante de

direção de acordo com o seu respectivo índice. Em $B1^I$ é possível visualizar a região de interesse a ser inicializada com as células computacionais sintéticas iniciais, aplicadas no centroide da região detectada pela inicialização automática inteligente, na qual os vetores da figura são os respectivos parâmetros de direção, representado por V_D . Em $B1^{II}$ com fator de ampliação, é possível observar em maior escala a ilustração dos parâmetros de movimentação dados pelo variante de direção, para cada célula individual no plano matricial ao qual a imagem está inserida. Por fim, em $B1^{III}$ está a representação do variante de direção V_D na forma de índice de direção mostrando o caminho a seguir da célula inicial ao longo do processo de aplicação do método.

Figura 22 – Imagem da aplicação do método *Divisible Cell-Segmentation*, onde as células sintéticas computacionais são inseridas nas respectivas imagens de TC de pulmão e AVC com base no parâmetro, gerado na etapa 3.1.7 (A6) pela inicialização automática adaptativa.



Fonte: Elaborada pelo autor.

A Figura 22 apresenta o processo de aplicação do método proposto adaptativo *Divisible Cell-Segmentation* aplicado a imagens de TC de AVC hemorrágico, com base na detecção da região de interesse pela inicialização automática sintética. Na imagem é possível visualizar as células computacionais sintéticas posicionadas no centro da região de interesse.

3.2.2 Etapa 2 (B2) — *Movimentação e Divisão Celular* — (Célula Computacional Sintética)

A divisão da célula computacional sintética pode ser ajustada por meio de um parâmetro, este processo de divisão celular é representado pela seguinte equação 3.21 expressa abaixo, onde:

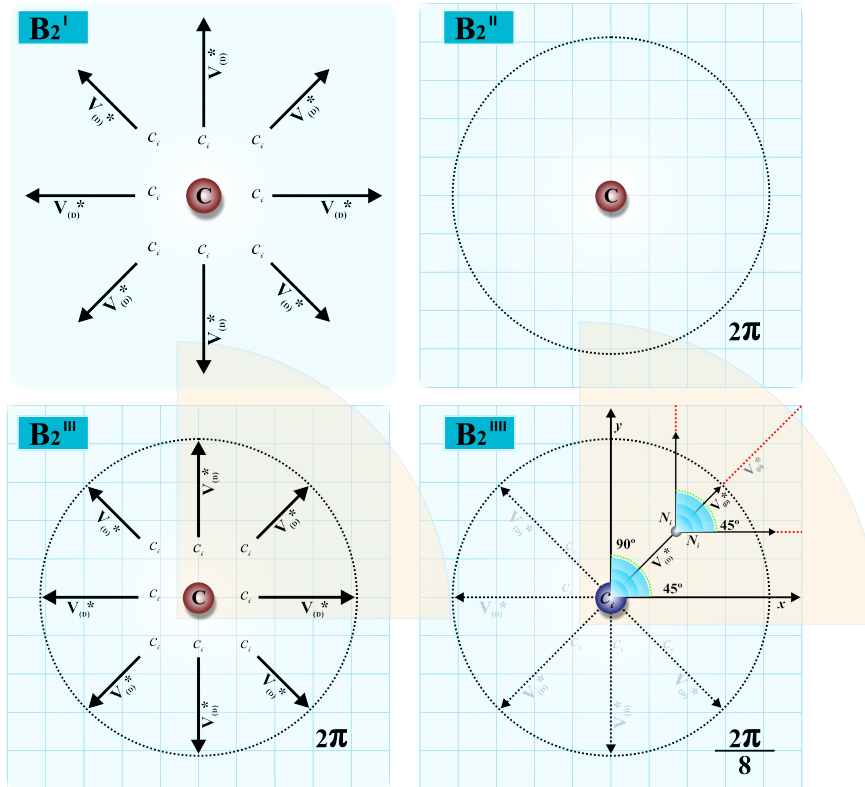
$$\begin{aligned}
D_C &= f_{div} \leftarrow (c_i + V_D^*) \\
\text{onde } N_i &\leftarrow (N_1 V_D^* + c) + (N_2 V_D^* + c) \\
\text{logo } N_i &= (N_1 c_i + N_2 c_i) \subset \text{ em } M \\
&\text{correspondente } c_i \text{ de inicialização} \\
\text{então, } \forall N_i \text{ em } M \mid D_c \text{ ocorre } \forall c \subset M
\end{aligned} \tag{3.21}$$

onde D_C corresponde à divisão da célula computacional, que recebe a célula computacional mãe no seu índice mais variante de direção, ilustrado na Figura 23, etapa B2¹. Nesta expressão, entende-se que a função de divisão está atrelada à célula inicial e o variante de direção com o parâmetro *, etapa B2¹¹, que corresponde ao parâmetro individual de direção de cada célula inicial dentro da imagem bidimensional. A expressão N_i corresponde ao novo índice onde receberá dentro da matriz os novos índices (N_1 e N_2) e suas respectivas variantes de direção mais a nova célula representada por c entendida pela expressão $N_i \leftarrow (N_1 V_D^* + c) + (N_2 V_D^* + c)$ contida na matriz M , etapa B2¹¹¹ na Figura 23. Essas duas novas células computacionais sintéticas são geradas com base na célula mãe inicial, onde carregam seus respectivos parâmetros ilustrados na imagem B2¹¹¹¹ da Figura 23. Logo, o índice N_i que representa um espaço dentro da matriz onde é inicializada a divisão celular, onde $N_1 c_i + N_2 c_i$ correspondem aos novos índices das novas células geradas a partir da célula mãe. Desta forma, representada pela última linha da expressão 3.21, para todo novo índice (N_i) na matriz (M), tal que a divisão celular ocorre para toda célula contida na respectiva matriz. A Figura 24 ilustra o processo de divisão Celular Computacional para uma única célula ao longo do seu trajeto cursado, dado com base na variante de direção, cujo ângulo é abordado na equação 3.22.

$$\begin{aligned}
\forall V_D \mid V_D \subset M, \text{ onde } V_D &= \frac{2\pi}{Q} \\
\forall c \subset G_c ; c &= (P)
\end{aligned} \tag{3.22}$$


onde para todo variante de direção, tal que o variante de direção está contido na matriz M , onde V_D é igual á $\frac{2\pi}{Q}$, onde Q corresponde á 8, fração de $\frac{360}{8}$, logo para toda célula contida no grupo de células, está sujeita ao parâmetro de parada P .

Figura 23 – Representação da aplicação e multiplicação do método proposto *Divisible Cell-Segmentation*, na qual a imagem em $B2^I$ ilustra o centroide da *Bounding Box*, cujas células sintéticas computacionais c_i com seus respectivos V_D^* . A imagem $B2^{II}$ ilustra o perímetro total, com uma angulação simétrica entre as mesmas de $\frac{2\pi}{8}$. Na imagem $B2^{III}$ está a combinação de ambas. Já Na imagem $B2^{IIII}$, é representado o processo de divisão celular computacional.




Fonte: Elaborada pelo autor.

Figura 24 – Representação da Divisão celular de uma célula sintética computacional inicial, na qual o processo de divisão gera duas novas células, cujos ângulos das respectivas variantes de direção se dão $\pm \frac{2\pi}{8}$ em relação à célula mãe. (Fonte: Autor)




Fonte: Elaborada pelo autor.

Figura 25 – Imagem da aplicação do método, *Divisible Cell-Segmentation* onde as células sintéticas computacionais iniciaram o processo de movimentação de acordo com o respectivo v_D^* .



Fonte: Elaborada pelo autor.

Figura 26 – Imagem da aplicação do método, *Divisible Cell-Segmentation* onde as células sintéticas computacionais iniciaram o processo de divisão de acordo com os parâmetros de divisão adaptativos pela inicialização automática adaptativa.



Fonte: Elaborada pelo autor.

Por fim, as Figuras 25 e 26 ilustram a aplicação do método proposto para imagens de TC de pulmão e AVC com um fator de ampliação sobre a região de aplicação do método, de maneira a evidenciar o processo de movimentação das células sintéticas computacionais na região de interesse do exame. Na Figura 25, as células, que já foram aplicadas anteriormente, ilustrado na Figura 22, iniciam o processo de movimentação de acordo com a variante de direção, já na Figura 26, é possível ver o resultado da primeira divisão celular do método, na qual cada célula sintética computacional inicial gera duas novas células filha.

3.2.3 Etapa 2 (B3) — Segmentação (Parâmetro de Parada)

Nesta etapa correspondente é criado o parâmetro de parada. Ou seja, após a divisão celular dentro da imagem, representada na Figura 27 (B4¹), a célula detecta as bordas do objeto de interesse, identificando diferentes pontos da borda do objeto (B4¹¹). A expressão pode ser

interpretada pela equação 3.23.

$$\begin{aligned}
 P &= G_c + \lambda \\
 V_L &= \phi \\
 \lambda &= \begin{cases} 0 & \text{se } V_L > \phi \\ 1 & \text{se } V_L \leq \phi \end{cases} \quad (3.23)
 \end{aligned}$$

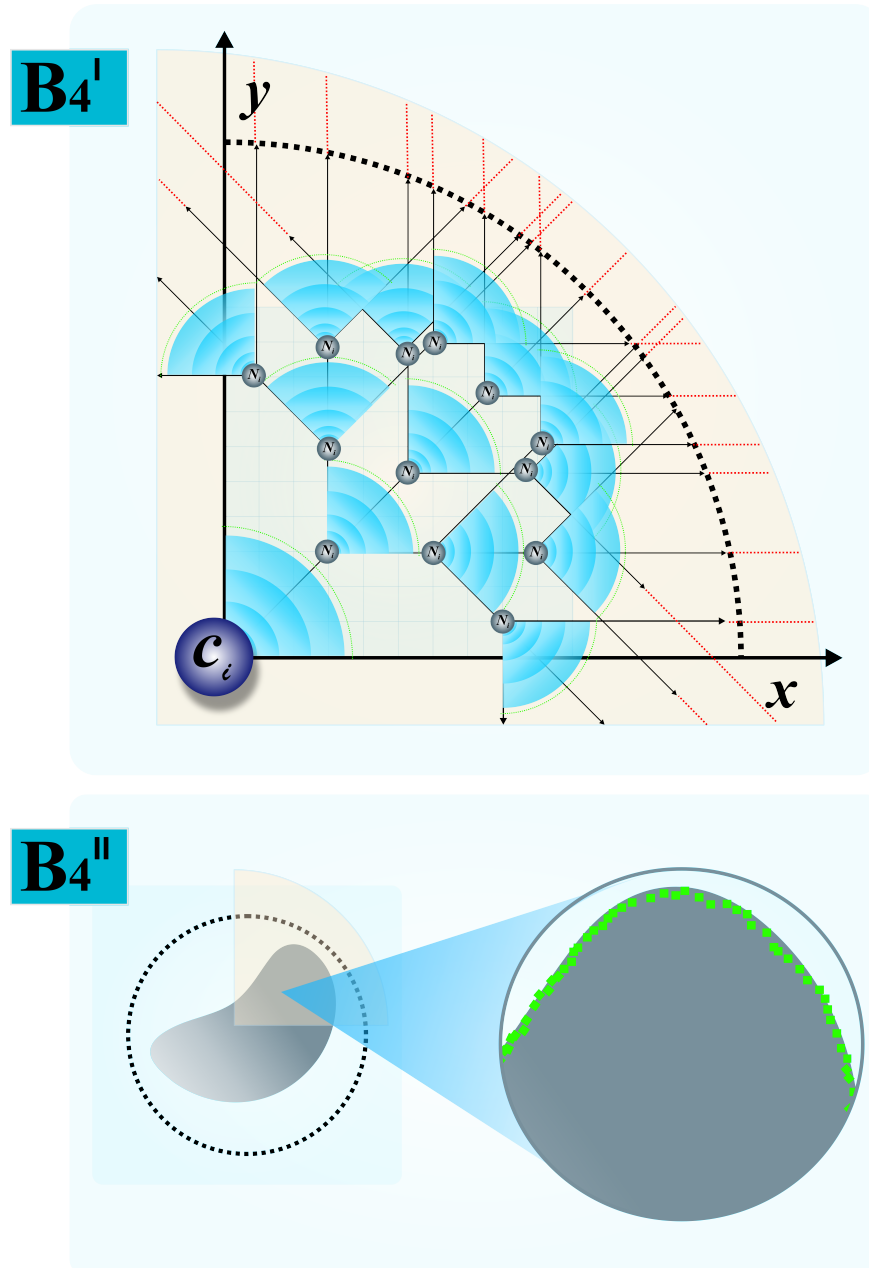
onde P representa o parâmetro de parada, que é correspondente ao grupo de células computacionais, mais λ , que representa a condição de parada ao encontrar o limiar da borda a ser detectada, representada pela expressão 3.23 delimitando o valor do limiar representado pela expressão V_L . A expressão descrita na equação para λ indica o seu valor condicional, que será 0 caso o valor do limiar assumido seja maior que ϕ , o que significa que a célula computacional sintética irá parar seu avanço, significando o encontro da borda do objeto. Caso o valor do limiar assumido seja menor ou igual a ϕ , λ assume o valor de 1, indicando que a célula computacional sintética continuará seguindo conforme seu índice no variante de direção. É importante destacar que o valor atribuído a ϕ , é dado de acordo com cada problemática com o objetivo de encontrar as bordas do objeto de interesse, levando em consideração sua intensidade de *pixels* e suas variações de limiar da região na imagem digital. Ou seja, o valor de ϕ muda de acordo com cada problema de identificação computacional e seus níveis em cinza.

As configurações do método *Divisible Cell-Segmentation* foram divididas pelo tipo de imagens médicas e tipo exame TC de AVC hemorrágico e TC Pulmonar, onde cada problema obteve o seu parâmetro referente a; Divisão celular D_c e Parâmetro de parada da célula computacional sintética representada por P .

O P , se dá pelo valor do limiar na qual corresponde a *pixels* pertencentes próximo à borda do objeto. Desta forma, pode-se calcular o *pixel* médio para P , que é carregado pela célula computacional sintética para cada imagem. Logo, o valor atribuído é *threshold* do somatório dos *pixels* capturado pela demarcação da região limiar da máscara na saída da detecção, processo de inicialização da abordagem.

O parâmetro de parada P é definido pela máscara já detectada no processo de inicialização da abordagem automática, onde é calculado os *pixels* das bordas da região de interesse, na qual é aplicado a função de m-vetorial(x,y) sobre a localização da demarcação da


Figura 27 – Processo de divisão realizado pelas células sintéticas computacionais. Na imagem $B4^I$ representa o processo de divisão celular que vai acontecendo à medida que a célula avança no plano da imagem, as setas indicam a direção a ser seguida pelas células até que as mesmas alcancem as bordas da região de interesse. Note que o ângulo entre as células é constante, de $\frac{2\pi}{8}$. Já em $B4^{II}$ está ilustrado o processo de parada das células sintéticas computacionais, na qual ao detectarem a região de interesse, começam a se aglomerar de maneira a demarcar toda a borda fechada da região de interesse.



Fonte: Elaborada pelo autor.

delineação da borda da máscara na imagem de entrada, como mostrada na subseção 3.1.7 e na Figura 28 de aplicação do método.

Figura 28 – Imagem da aplicação do método, *Divisible Cell-Segmentation* para imagem de TC de pulmão e AVC, onde as células sintéticas computacionais localizadas no limite da borda da região de interesse encontraram o parâmetro de paradas de divisão adaptativos.




Fonte: Elaborada pelo autor.

3.2.4 Etapa 2 (B4) - Segmentação (Conexões via células Computacionais Sintéticas)

Ao final do processo de movimentação das células sintéticas computacionais sobre a região de interesse, dá-se início ao processo de segmentação com a técnica de conexão via células computacionais sintéticas, na qual é criada a imagem binária do processo, uma imagem de mesmas dimensões de largura e altura da imagem do exame, formada pelos *pixels* centrais de cada célula sintética computacional localizada na borda da região de interesse, na qual cada centro da célula computacional sintética recebe nível de cinza 255, enquanto o restante recebe nível de cinza 0. A referida imagem binária é exemplificada pela Figura 29.


Figura 29 – Processo de criação de uma nova imagem com base no centroide das células computacionais sintéticas localizadas nas bordas da região de interesse. A imagem resultante consiste na binarização das células computacionais de maneira a demarcar, com um conjunto de células, as bordas da região de interesse.



Fonte: Elaborada pelo autor.

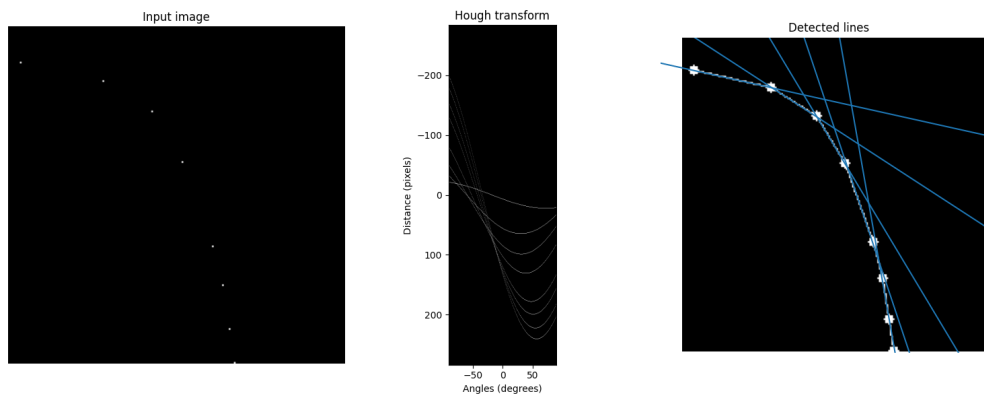
A imagem binária é então utilizada para a aplicação da última fase do método, a conexão dos centros celulares, sendo iniciado o processo de construção do plano de parâmetros da mesma, inspirado na secção 2.8 de Métodos, com auxílio da equação 3.24.

Figura 30 – Processo de conexão entre as regiões centrais das células computacionais localizadas na borda da região de interesse. Na imagem ilustrada em (A), é realizada a convolução da imagem binária na busca de *pixels* com nível de cinza diferente de zero. Quando encontrado o centro da célula computacional sintética, é iniciado o processo descrito pelas imagens B até (G), cujo ângulo da reta θ oscila de 0-360 para cada *pixel* encontrado na imagem binária. Desta forma, o plano de parâmetros da imagem é criado, e as retas que conectam os centros celulares são definidas.



Fonte: Elaborada pelo autor.

Figura 31 – Demonstração do processo realizado pelo acumulador na qual demarca os pontos representados pelas células computacionais em um plano, demarcando retas sobre cada célula computacional sintética.



Fonte: Elaborada pelo autor.

$$\forall c \subset B|P \rightarrow H(\rho, \theta)$$

$$H(\rho, \theta) = \sum_{k=1}^n w(k) \delta(\rho - x_i \cos(\theta) - y_i \sin(\theta))$$

onde

$$k = c$$

$$w(k) = \exp\left(\frac{-d^2(k,i,j)}{2\sigma^2}\right) \quad (3.24)$$

onde

$$d(k, i, j) = \min(d(i_k, j), d(j_k, i))$$

tal que

$$k \neq i \text{ e } k \neq j$$

onde, B representa borda da região de interesse, cujas células c encontram-se condicionadas pelo parâmetro de parada P e representada por K . $H(\rho, \theta)$ representa o espaço de

parâmetros da transformada, onde ρ é a distância perpendicular da linha em relação à origem e θ é o ângulo que a linha forma com o eixo x . $\sum_{k=1}^n$ representa a soma sobre todos os pontos centrais celulares na imagem que são candidatos a formar uma linha. O peso $w(k)$ é associado a cada ponto k , que representam os pontos centrais celulares, representa a confiança de que o ponto central celular pertence a uma linha. Ele é calculado com base na distância $d^2(k, i, j)$ entre o ponto celular k e os pontos celulares i e j mais próximos a ele. Quanto menor a distância, maior o peso. A função delta $\delta(\rho - x_i \cos(\theta) - y_i \sin(\theta))$ indica se um ponto (x_i, y_i) na imagem contribui para a linha representada pelos parâmetros ρ e θ . A distância $d(k, i, j)$ é a distância entre o ponto central celular k e a reta definida pelos pontos i e j . As restrições $k \neq i, k \neq j$ garantem que i e j sejam diferentes de k (ILLINGWORTH; KITTLER, 1987).

O processo de construção do plano de parâmetros pode ser ilustrado pela primeira linha de imagens da Figura 30, na qual, em (A), é realizada a convolução da imagem binária na busca dos centros celulares cujo nível de cinza seja igual a 255. Quando encontrado tal centro da região celular computacional sintética, inicia-se o processo de implementação do plano de parâmetros, oscilando o ângulo θ de 0-360 com a finalidade de encontrar todos os valores de ρ para cada ponto encontrado, conforme ilustrado nas imagens (B) até (G) na Figura 30, e apresentado na Figura 31. Por fim, construído um plano de parâmetros, inicia-se o processo de definição das retas que conectam os centros mais próximos de cada célula computacional sintética da imagem binária, através do mapeamento das retas pelo plano de parâmetros construído para a respectiva imagem.

Deste modo, o método proposto de conexões via pontos celulares onde conectam os pontos de diferentes curvaturas por meio de retas, gerando assim um contorno baseado nas células computacionais sintéticas dentro do seu ponto de parada dentro da matriz.

3.3 Métricas de Avaliação

A fim de avaliar os resultados obtidos pelo método proposto, foram utilizadas métricas: Acurácia (ACC), *Negative Predictive Value* (NPV), PPV, Coeficiente de DICE, Sensitividade (SEN), ESP, FPR e índice Jaccard (JAC).

ACC, ou acurácia é uma métrica comum para avaliar o desempenho de um modelo de segmentação de imagem. A acurácia mede a proporção de *pixels* classificados corretamente em relação ao número total de *pixels* na imagem. Em outras palavras, a acurácia mede a capacidade do modelo de identificar corretamente os *pixels* que pertencem a uma determinada classe ou

categoria. A acurácia pode ser obtida através da equação 3.25

$$ACC = \frac{VP + VN}{VP + VN + FP + FN}. \quad (3.25)$$

PPV e NPV, ou precisão, é a probabilidade de um indivíduo avaliado e com resultado positivo ser realmente positivo. Essa métrica avalia a quantidade de verdadeiros positivos sobre a soma de todos os valores positivos. O NPV é a probabilidade de um indivíduo avaliado e com resultado negativo ser realmente negativo. O PPV e NPV podem ser calculados pelas fórmulas apresentadas nas Equações 3.26 e 3.27 respectivamente:

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

$$NPV = \frac{VN}{VN + FN}. \quad (3.27)$$

As métricas PPV e NPV contêm informações sobre o poder do teste (sensibilidade e especificidade) e da população a ser examinada (prevalência da doença), sendo uma medida de grande utilidade (KOHL, 2012).

DICE, ou coeficiente de DICE é definido como o dobro da interseção entre duas regiões (a região segmentada pelo algoritmo e a região de referência) dividido pela soma do número de *pixels* em ambas as regiões. Em outras palavras, o coeficiente de DICE mede a proporção de *pixels* que as duas regiões têm em comum, em relação ao número total de *pixels* nas duas regiões (MILLETARI *et al.*, 2016). O coeficiente DICE é dado pela equação 3.28.

$$DICE = \frac{2VP}{2VP + FP + FN} \quad (3.28)$$

SEN, ou Sensitividade, Em uma segmentação, mede a proporção de *pixels* verdadeiramente positivos (pertencentes à classe de interesse) que são identificados corretamente pelo modelo em relação ao número total de *pixels* positivos na imagem. Em outras palavras, a sensibilidade mede a capacidade do modelo em encontrar corretamente todos os *pixels* pertencentes a uma determinada classe (BHADAURIA; DEWAL, 2014). A sensibilidade é dada pela fórmula 3.29.

$$SEN = \frac{VP}{VP + FN} \quad (3.29)$$

ESP, ou especificidade, em uma segmentação, mede a proporção de *pixels* verdadeiramente negativos (não pertencentes à classe de interesse) que são identificados corretamente pelo modelo em relação ao número total de *pixels* negativos na imagem. Em outras palavras, a especificidade mede a capacidade do modelo em distinguir corretamente os *pixels* que não pertencem à classe de interesse (BHADAURIA; DEWAL, 2014). a especificidade é dada pela equação 3.30

$$SPE = \frac{VN}{VN + FP} \quad (3.30)$$

FPR, ou *false positive rate* é a proporção de previsões negativas que foram determinadas como positivas para o número total de previsões negativas. Ou, quando o valor real é negativo, com que frequência a previsão é incorreta.

$$FPR = \frac{\text{No. de Previsões Incorretas}}{\text{Total No. Total de Previsões Negativas}} \quad (3.31)$$

O coeficiente de ϕ é definido como a razão entre o número de *pixels* que as duas regiões têm em comum e o número total de *pixels* em ambas as regiões, conforme a equação 3.32:

$$JAC = \frac{VP}{VP + FP + FN} \quad (3.32)$$

Todas métricas utilizadas para avaliação têm suas especificidades que foram levadas em consideração na escolha de como os métodos seriam avaliados. Não se deve pensar em uma como melhor ou pior que a outra de maneira geral, e sim deve-se analisar o problema e escolher a/as que melhor se adapta(m).

Teste Estatístico de Kolmogorov-Smirnov é um método não-paramétrico utilizado para avaliar a igualdade de distribuições de probabilidade de duas amostras. Esse teste compara a distribuição empírica das amostras com a distribuição teórica, geralmente uma distribuição normal. A hipótese nula é que as duas distribuições são idênticas, enquanto a hipótese alternativa é que as duas distribuições são diferentes. O resultado do teste é uma estatística de teste que representa a diferença máxima entre as duas distribuições, chamada de estatística D. A partir da estatística D e do tamanho da amostra, pode-se calcular um valor-p que indica a probabilidade de observar uma diferença tão grande ou maior do que a diferença observada, assumindo que

a hipótese nula é verdadeira (PRÆSTGAARD, 1995). Se o valor p for menor do que um nível de significância escolhido, geralmente 5% ou 1% para testes com a necessidade e uma maior confiabilidade, a hipótese nula é rejeitada e conclui-se que as duas distribuições são estatisticamente diferentes, como mostra a Expressão 3.33.

$$K \quad \text{Teste} \quad \begin{cases} P > \alpha & = & H_0 & - & \text{Equivalência Estatística} \\ P < \alpha & = & H_1 & - & \text{Diferença Estatística} \end{cases} \quad (3.33)$$

na qual o P representa o valor-p expresso pela estatística D , α representa o nível de significância adotado para o teste, neste caso o nível adotado foi de 1%, o que indica que o teste possui alto nível de confiabilidade. As hipóteses do teste, isto é, de igualdade estatística entre as amostras ou equivalência estatísticas entre as amostras são representados por H_0 e H_1 respectivamente. Pode-se perceber que, de acordo com a comparação entre o valor-p obtido e a significância adotada, a hipótese de equivalência estatística entre as amostras comparados, será confirmada ou negada, de maneira a reforçar as comparações métricas ou apenas demonstrar que embora possuam médias e desvios padrões diferentes, no ponto de vista estatístico tal diferença é mínima.

3.4 Considerações Finais

Esta seção apresentou a Etapa 1 (A): Inicialização Automática adaptativa: Abordagem em Imagens Médicas — abordagem para detecção das regiões de interesse (AVC hemorrágico e pulmões). Na Etapa 2 deste capítulo: Segmentação - Método *Divisible Cell-Segmentation*, foi descrito e ilustrado o novo método proposto (contribuição principal desta tese) capaz de segmentar imagens digitais bidimensionais médicas. O novo método proposto, trouxe uma abordagem análoga ao processo de divisão celular denominado citocinese, onde uma célula biológica se divide formando outra célula. O novo método aplica células computacionais sintéticas aos centros das imagens digitais, ocorrendo dentro do processo de movimentação das células computacionais sintéticas a etapa de divisão (multiplicação) com o objetivo de detectar as bordas do objeto de interesse, segmentando-o por meio de conexão celular. Por fim, foram apresentadas as diferentes métricas que serão utilizadas nos experimentos desta tese. Seguida das considerações deste capítulo.

4 EXPERIMENTOS, RESULTADOS E DISCUSSÃO

Esta seção apresenta os resultados obtidos pelos estudos desta tese. A seção é dividida em subseções nas quais abordam as seguintes etapas: Ensaios Experimentais, apresentado subseção 4.1, Etapa de Configurações e Parâmetros apresentados na subseção 4.2, Etapa de Resultados - Detecção e Segmentação em Imagens Médicas, onde são apresentados os resultados obtidos em TC de AVC hemorrágico apresentados na subseção 4.3.1 e TC em Imagens Pulmonares apresentados na subseção 4.3.2. Ao Final desta seção de resultados, é apresentando na subseção 4.4 uma Análise Geral dos Resultados desta tese.


4.1 Ensaios Experimentais — Método *Divisible Cell-Segmentation*

Esta subseção da Fase 2 de Metodologia, tem como objetivo apresentar os ensaios iniciais por meio de ilustração dos resultados dos experimentos deste estudo, por meio do novo método para segmentação *Divisible Cell-Segmentation*. Os testes realizados demonstram os resultados do novo método aplicado em imagens bidimensionais de figuras geométricas, a fim de proporcionar uma visão do comportamento das células computacionais sintéticas em imagens digitais.

A Figura 32 ilustra o processo do método *Divisible Cell-Segmentation*, método proposto por este estudo em uma imagem digital bidimensional com diferentes formas. Na imagem é possível identificar as etapas de inicialização com a aplicação das células computacionais sintéticas no centro da imagem de teste. Ao final do processo, é possível visualizar as múltiplas células computacionais sintéticas na imagem final com o resultado da segmentação.

O método *Divisible Cell-Segmentation* foi aplicado às imagens geométricas, que corresponde a segmentação das bordas do objeto de interesse em diferentes formas geométricas. Como ilustra a Figura 33, o teste foi realizado para diferentes imagens geométricas. Na primeira coluna em (A) são apresentados as Figuras geométricas originais, seguida os resultados de finalizações para a parada celular, na coluna (B) e (C), mostra a evolução de diferentes processos finalizados, simulando a parada celular diminuindo interações do processo de divisão, os valores, os resultados de (C) vão se tornando mais eficazes do que a coluna (B) para as diferentes imagens geométricas. As imagens da coluna (D), apresentam um melhor parâmetro para o ensaio de geração dos resultados de teste. Para o ensaio, foi possível concluir que o número de interações para as divisões celulares impactam nos resultados de segmentação otimizada. Isso se deve

Figura 32 – Método proposto, *Divisible Cell-Segmentation* sobre a Figura geométrica. Cada imagem na figura ocorre o avanço e divisão das células computacionais sintéticas, que se movem até detectar as regiões de borda do objeto, e assim, com a conexão celular onde delimita a máscara binária do objeto em questão na imagem, segmentada. A imagem tem dimensões de 1421 *pixels* de largura por 981 *pixels* de altura.



Fonte: Elaborada pelo autor.

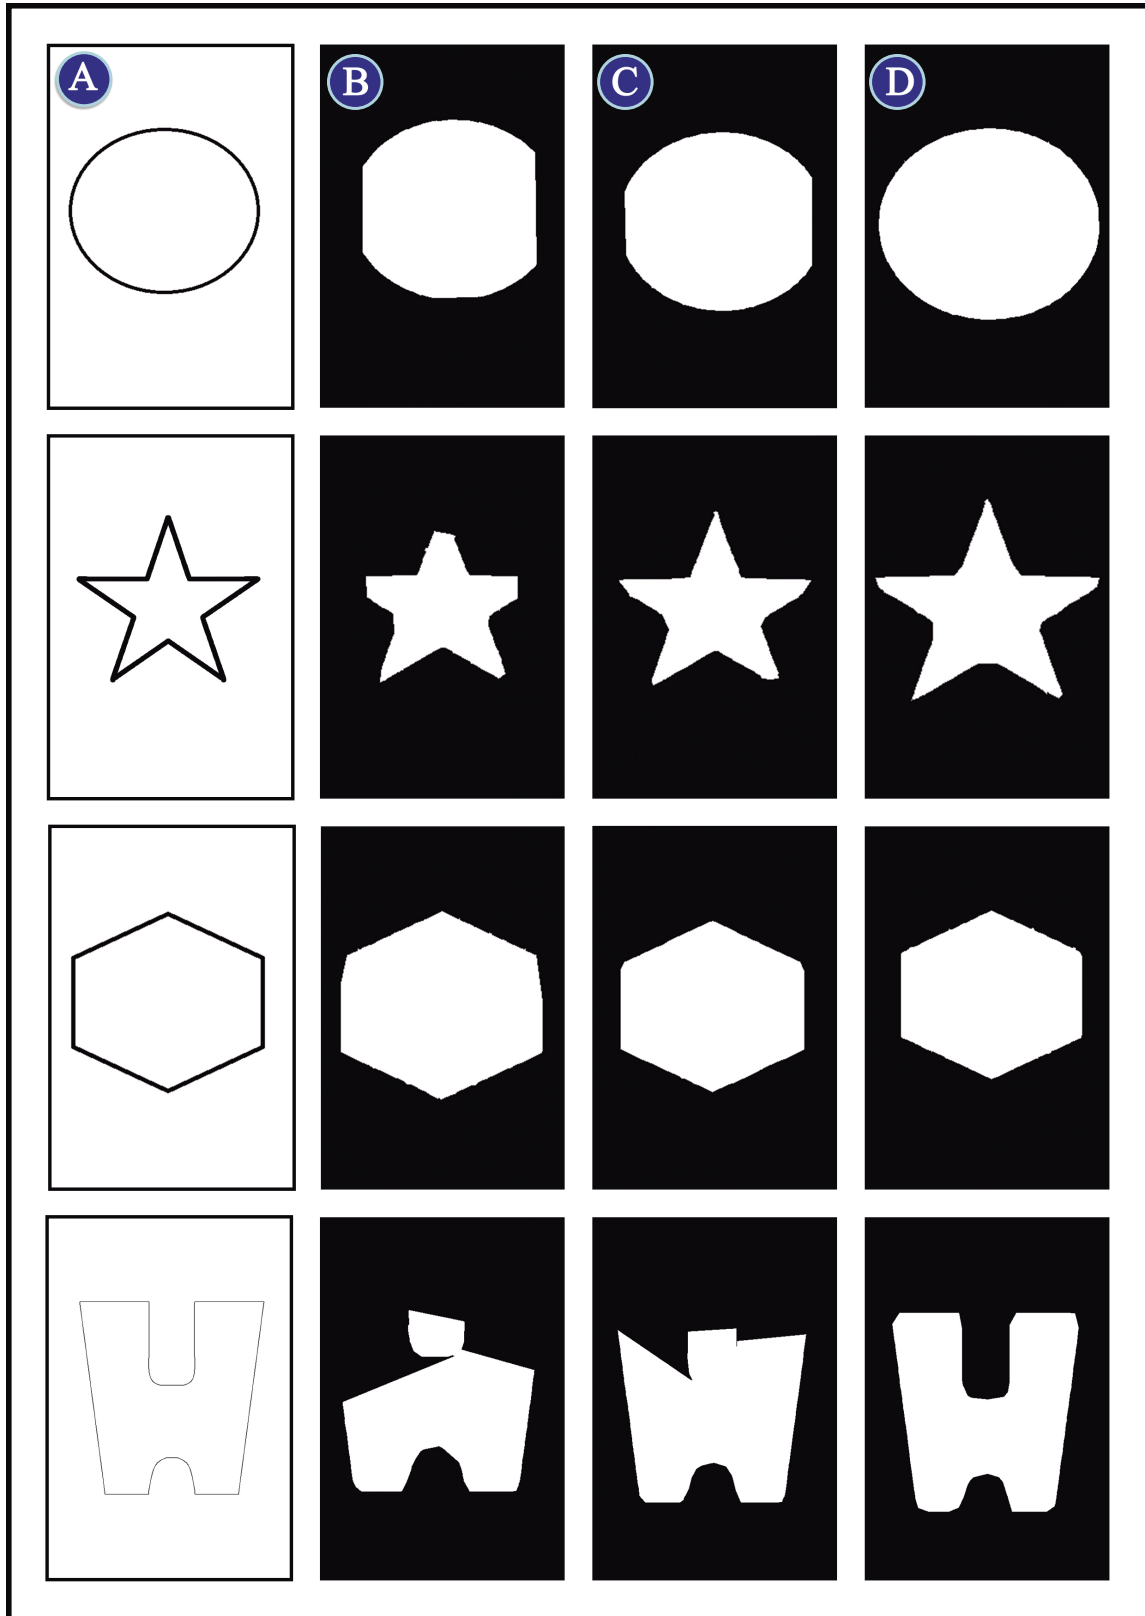
as grandes distâncias entre as células e suas conexões no momento de conexão celular. Vale ressaltar que, os parâmetros utilizados correspondem ao problema nestas específicas imagens de teste que compõem um plano de fundo totalmente branca, com bordas do objeto em cor predominantemente preto, sem tonalidades de cinza.

A figura 33, representa os testes aplicados do método proposto, *Divisible Cell-Segmentation* com diferentes parâmetros de divisão D_c denotado na equação 3.21. No ensaio é possível constatar a capacidade do método proposto na segmentação das bordas de diferentes imagens, o resultado é ajustado de acordo com o parâmetro de delimitação, de forma a se adaptar na imagem para realizar a divisão celular. Note que o processo de divisão nas etapas B e C foram limitados ocorrendo, obtendo perda de informação da borda real dos objetos.

4.2 Configurações e Parâmetros

As simulações do experimento de *deep learning* foi utilizando o sistema operacional Linux, distribuição Ubuntu 22.04, usando 16 GB de RAM, Processador Intel® Core™ i7-7700K CPU @ 4.20GHz e Placa de Vídeo NVIDIA GeForce GTX 1050 Ti (com 4 GB de memória). A implementação da detecção foi feita através da linguagem Python, versão 3.11.1, com uso das

Figura 33 – Resultado visual gerado pelos ensaios experimentais do método *Divisible Cell-Segmentation*.



Fonte: Elaborada pelo autor.

bibliotecas OpenCV v4.1.0, scikit-learn v0.20.2, v.1.14.0, Keras v.2.2.4.

Para o *fine-tuning* da inicialização automática inteligente para melhor detectar as ROI's em imagens médicas, utilizou-se tais parâmetros: divisão entre treino e teste de 80%/20%, em estratégia de *cross-validation* usando *K-fold* com 3 *folders.*, além de um número máximo de iterações de 1000, 2 imagens por *batch* e o tamanho do *batch* por imagem de 512 para TC. Utilizou-se também uma taxa de aprendizado (*learning rate*) de 0,00025 e 2 *workers*. Vale destacar que apenas uma classe era utilizada para detecção (a depender do *dataset* de imagens médicas) e que as camadas da rede que foram treinadas foram da camada *R50FPN3X* (usando a Mask R-CNN como rede neural) e camadas posteriores.

As configurações do método *Divisible Cell-Segmentation* foram divididas pelo tipo de imagens médicas e tipo exame TC de AVC hemorrágico e TC Pulmonar, onde cada problema obteve o seu parâmetro referente ao; Divisão celular D_c e Parâmetro de parada da célula computacional sintética representada por P .

O P , se dá pelo valor do limiar na qual corresponde a *pixels* pertencentes próximo à borda do objeto. Desta forma, é calculado o *pixel* médio para P , que é carregado pela célula computacional sintética para cada imagem. Logo, o valor atribuído é *threshold* do somatório dos *pixels* capturado pela demarcação da região limiar da máscara na saída da detecção, processo de inicialização da abordagem adaptativa.

4.3 Resultados — Segmentação em Imagens Médicas

Esta seção apresenta os resultados baseados na segmentação de diferentes imagens médicas de TCs. Os resultados dos experimentos são divididos por diferentes problemas em imagens médicas: Acidente Vascular Cerebral-AVC hemorrágico e Imagens Pulmonares. A inicialização do método automático inteligente para segmentação em regiões em imagens médicas está descrita na Seção 3 de metodologia, onde é apresentado o método (*Divisible Cell-Segmentation*) baseado em inicialização automática inteligente adaptativa.

4.3.1 Resultados — Acidente Vascular Cerebral Hemorrágico.

Nesta subseção são apresentados resultados da inicialização automática inteligente para detecção da região do AVC hemorrágico em imagens de TCs a ser segmentada, abordagem da Etapa 1 desta metodologia. Nestes experimentos são apresentados diferentes resultados para

a segmentação do AVC hemorrágico, bem como comparados com o estado da arte, apresentados na Subsecção 4.3.1.3.

4.3.1.1 Inicialização da abordagem - AVC Hemorrágico

São apresentados nesta seção, os resultados referente a inicialização da nova abordagem para detecção do AVC hemorrágico a ser segmentado, tal abordagem tem como objetivo identificação da região de interesse na imagem de TC dentro do processo de inicialização automática inteligente que tem como objetivo a detecção da região lesionada no cérebro.

O processo de avaliação se deu pela utilização das métricas; ACC, SEN, ESP e Coeficiente de *Dice*. Os resultados deste experimento em hemorrágicos apresentaram grande desempenho para identificação da área lesionada (região do AVC). As métricas de avaliação apresentaram altos valores desempenho para detecção com precisão da região do AVC hemorrágico, bem como delimitação da área pertencente a hemorragia por meio das caixas delimitadoras.

Tabela 1 – Resultados obtidos pela inicialização automática inteligente, realizadas pela nova abordagem do método proposto para segmentação do AVC Hemorrágico em imagens de TC - Método *Divisible Cell-Segmentation*.

<i>Abordagem</i>	Acc	Sen	Spe	Dice
<i>Inicialização automática</i>	99.37 ± 0.42	91.14 ± 5.03	99.41 ± 0.34	92.99 ± 2.53
Fold 1	99.75 ± 1.17	91.80 ± 3.51	98.75 ± 1.20	90.70 ± 1.88
Fold 2	98.99 ± 0.88	92.55 ± 6.27	98.81 ± 0.50	91.69 ± 1.07
Fold 3	99.21 ± 0.54	91.39 ± 3.10	99.33 ± 0.17	93.07 ± 2.04


Fonte: Elaborada pelo autor.

A Tabela 1 apresenta o resultado da inicialização automática inteligente, Etapa 1 inicial do processo de segmentação do novo método *Divisible Cell-Segmentation*. Em uma análise precisa dos valores obtidos, é possível identificar diferentes valores obtidos para detecção gerada pelo processo de inicialização automático inteligente com 99.37% de ACC e desvio padrão em 0.42%. Isso permite concluir em uma análise mais concreta neste processo de inicialização automática, a detecção da região de interesse, demonstrou excelente desempenho em identificar os *pixels* pertencentes a região da fronteira da hemorragia cerebral. Isso pode ser validado e consolidado mediante as métricas de SEN, ESP e DICE; com 91.14%, 99.41% e 92.99%, demonstrando a eficácia na delimitação por meio de *bounding box* e máscara da região de interesse.

Desta forma pode-se chegar a conclusão, que os parâmetros da região de interesse,

ambos geradas pela Etapa 1 de inicialização automática, obteve um papel fundamental onde são obtidos os parâmetros para celular computacional sintética.

Figura 34 – Resultado da inicialização automática inteligente que tem como abordagem a detecção da região do AVC hemorrágico para segmentação em diferentes imagens de TCs cerebrais. Na coluna (A) são apresentados as TCs, na coluna (B) são apresentados resultados da detecção da região das bordas da lesão do AVC hemorrágico.



Fonte: Elaborada pelo autor.

A Figura 34 apresenta diferentes imagens de TC de AVC Hemorrágico, com os respectivos resultados gerados pela inicialização da abordagem proposta totalmente automática. Na imagem é possível identificar diferentes AVC hemorrágico por meio da detecção inteligente demarcada com *boundig box* de cor verde, apresentando os valores precisos. Na coluna (A) são apresentadas imagens de TC do crânio, e na coluna (B) são apresentados os resultados da detecção pela inicialização da abordagem proposta. Assim, pode-se concluir que o método com abordagem automática inteligente, detectou com eficácia a região do AVC Hemorrágico em TCs, detectando com precisão o AVC nas imagens. E assim. A partir deste processo, é iniciado a Fase 2 de segmentação precisa da região do AVC hemorrágico.

4.3.1.2 Segmentação - AVC Hemorrágico (*Divisible Cell-Segmentation*)

Nesta seção são apresentados os resultados do método proposto por este estudo, denominado *Divisible Cell-Segmentation*, o método tem a finalidade de segmentar as bordas do AVC hemorrágico. Ou seja, após a detecção do AVC hemorrágico na inicialização da abordagem, é aplicado a etapa de segmentação por meio de células computacionais sintéticas dentro da matriz bidimensional (também contribuição deste estudo), como é apresentado na Seção de Metodologia 3. Neste processo, o método aplicado no centro da região detectada, onde o método entra no processo de divisão celular na qual as células computacionais sintéticas se dividem (multiplicam-se), até encontrar as bordas do AVC hemorrágico cerebral.

Tabela 2 – Resultados obtidos pelo método proposto (*Divisible Cell-Segmentation*) para a segmentação de imagens de AVC Hemorrágico em imagens de TC

Método Proposto	<i>Divisible Cell-Segmentation</i>
<i>SEN</i>	99.82 ± 1.06
<i>ESP</i>	99.81 ± 0.09
<i>ACC</i>	99.80 ± 0.09
<i>DICE</i>	93.25 ± 3.89

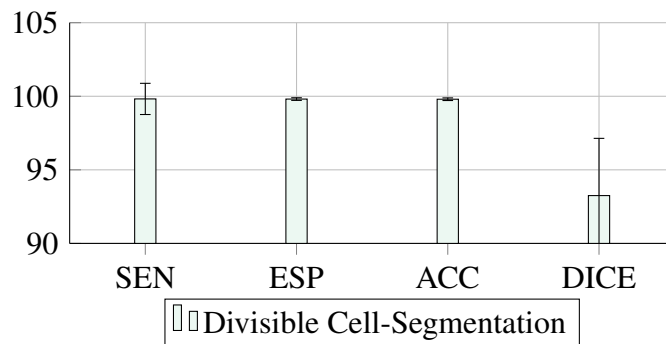
Fonte: Elaborada pelo autor.

A Tabela 2 apresenta os valores das métricas obtidas no experimento realizado com a base de dados *dataset* de AVC, apresentados na Subseção 2.9.1. O novo método *Divisible Cell-Segmentation* obteve 99.80% de ACC, o que resultou em um excelente desempenho para encontrar a borda do objeto de interesse. Neste processo é possível notar o desempenho da métrica de SEN com 98.82%, trazendo resultados de comparação para segmentação em métodos automáticos.

Este processo pode ser confirmado também no momento em que a métrica de ESP obtém excelente resultado com 99.81%, pois neste processo o método atingiu excelência em identificar *pixels* não pertencentes à região delimitada do AVC Hemorrágico. É importante ressaltar os valores obtidos também no desvio padrão, com menos de 1% na métrica ACC e ESP demonstra o método estável. A métrica SEN obteve 1.06% no desvio padrão, relativamente próximo dos demais resultados de desvio padrão nas outras métricas. A métrica de DICE apresentou 93.25%, o que demonstra o bom desempenho do método com base nos contornos em identificar diferentes regiões complexas, como identificação de regiões com contornos estreitos, e de difícil delimitação, e sua relação com a similaridade com o real contorno do AVC.

A Figura 39 ilustra, por meio do gráfico, os resultados da tabela 1 onde podem ser analisados visualmente pelas barras verticais do gráfico apresentado. Na ilustração é possível identificar que a abordagem proposta foi precisa em detectar a região do AVC, obtendo altos valores métricos de comparados em todas as métricas (*ACC, SEN, ESP e DICE*).

Figura 35 – Ilustração dos resultados obtidos com a segmentação automática de AVC Hemorrágico - Método *Divisible Cell-Segmentation*.



Fonte: Elaborada pelo autor.


Na Figura 34, pode-se observar que, em diferentes imagens de AVC hemorrágico com variadas apresentações, as lesões foram segmentadas com eficácia utilizando o método *Divisible Cell-Segmentation*. Na imagem em análise, os resultados evidenciam a efetividade do avanço das células, que foram subdivididas (multiplicadas) até alcançar as margens do objeto de interesse. O método em questão demonstrou robustez ao utilizar células computacionais sintéticas que tem como objetivo encontrar as bordas da lesão cerebral (AVC Hemorrágico). A segmentação das áreas internas das lesões, que representam um desafio devido à variedade de apresentações do AVC hemorrágico, foi segmentada através da divisão das células específicas da borda do AVC, tais pontos representados pela coloração verde, representam as células computacionais sintéticas. Com o auxílio das subdivisões celulares, tornou-se possível alcançar regiões específicas dentro

da imagem do AVC por meio de múltiplas células, o processo de segmentação obteve eficiência em identificar regiões precisas do contorno do sangramento cerebral.

Na Figura 36 é apresentado imagens de TCs, seguida pelo processo de inicialização do método *Divisible Cell-Segmentation* para segmentação de AVC hemorrágico, por meio células artificiais capazes de se dividirem até encontrar a borda da hemorragia cerebral. Neste processo, é possível visualizar a precisão da identificação da região do AVC Hemorrágico, o método inicializa a partir da detecção do centroide com base na detecção da região de interesse realizado na fase de inicialização da abordagem. O processo síncrono evolui por meio da subdivisão celular computacional sintética da região, que é aplicado dentro do AVC com os parâmetros apresentados na subseção 4.2: Configurações e Parâmetros na Seção de Metodologia, com objetivo final de identificar as bordas da hemorragia cerebral, segmentando-a todo o contorno do AVC. Na Figura 36, é possível visualizar a inicialização com base na aplicação das células por meio de localização do centroide dentro do objeto de interesse, previamente detectado na fase anterior. Ainda na Figura 36 na imagem, é possível visualizar a divisão celular computacional sintética, tendo como resultado a multiplicação celular. Nas últimas imagens, é possível identificar os contornos do objeto por meio de ajustes células na borda do AVC como processo final de segmentação por meio das conexões celulares, onde são fechados, na forma de polígono, os pontos centrais das células computacionais sintéticas posicionadas na borda da região.


Na Figura 37 é possível analisar, visualmente, as diferentes imagens com as variações de lesões de AVC Hemorrágico nas fatias da imagem tomográfica. A segmentação do AVC na imagem foi realizada de forma eficaz e detalhada, os resultados visuais, bem como os resultados obtidos pelas métricas, demonstram a eficiência do avanço das células, que se subdividiram até os limites da região de interesse. O método se utiliza de uma inovadora abordagem de divisão (multiplicação) celular computacional sintética, na qual é possível alcançar, com precisão, regiões limites do sangramento na massa cinzenta cerebral, na qual processos menos sofisticados de segmentação encontram barreiras para alcançar tais resultados. Desta forma, pode-se concluir que o método *Divisible Cell-Segmentation* é uma eficaz abordagem para segmentação de AVC Hemorrágico Cerebral, podendo ser utilizado como ferramenta para auxílio ao diagnóstico médico, baseado em modelos computacionais de visão computacional com alto desempenho.

Figura 36 – Resultado da segmentação do AVC hemorrágico em diferentes momentos, de forma gradual, usando o novo método *Divisible Cell-Segmentation* baseado em células computacionais sintéticas. Na imagem é ilustrado o resultado de método de segmentação, onde é iniciado o processo de inserção das células no centroide da região de interesse, processo de divisão celular e encontro bordas do AVC.



Fonte: Elaborada pelo autor.

Figura 37 – Resultado da segmentação com uso do método *Divisible Cell-Segmentation* em diferentes imagens pulmonares em TCs. A imagem apresentada resultados da segmentação da região das bordas dos AVCs hemorrágicos uso do método proposto.



4.3.1.3 Validação dos Resultados (AVC Hemorrágico) - Comparação com Trabalhos da Literatura

A fim de validar os resultados obtidos no estudo desta tese, esta subseção apresenta diferentes comparações com trabalhos encontrados no estado da arte. Ambos os trabalhos tiveram como premissa, segmentação de AVC hemorrágico por meio de diferentes métodos. Inicialmente são apresentados trabalhos com abordagens manuais, e métodos automáticos, posteriormente são comparados métodos com uso de *deep learning*, *Fine-tuning* e *transfer learning* encontrados na literatura e apresentados no estado da arte.

A Tabela 3 apresenta diferentes trabalhos encontrados na literatura com diferentes abordagens baseadas em métodos manuais, automáticos e uso de *deep learning* para segmentação em imagens de AVC hemorrágico em TCs.

Após a aplicação do método, os resultados obtidos foram comparados com as imagens segmentadas denominadas “padrão ouro”, para que dessa comparação fossem calculadas as métricas adotadas. Os resultados da segmentação estão na Tabela 3. Na qual são comparados os métodos manuais, *Watershed*, *LSCPM* e *FCM*, onde obtiveram valores de ESP de 87.32%, 83.03% e 90.53%, contra 99.81% obtidos pelo método proposto *Divisible Cell-Segmentation*, demonstrando assim a eficácia em identificar as bordas da hemorragia cerebral. Com os dados da referida tabela, é possível concluir que os métodos manuais obtiveram valores similares e significativos de ACC, 99.69%, 99.72% e 99.19% contra 99.80% obtido pelo método proposto. Porém, os valores de similaridades obtidos na métrica de DICE, obtiveram aproximadamente 6% de diferença com o método *FCM*, comparado ao método proposto e diferença de pouco mais de 5% com o método evolução do level set baseado no algoritmo Fuzzy C-means (*LSFCM evol*). Vale ressaltar que o método proposto realiza a detecção da região a ser segmentada, processo este totalmente automático, na qual os modelos em comparação mencionados, necessitam de intervenção humana para operar a segmentação da região do AVC.

Os métodos com abordagem automática, Level set utilizando Fuzzy C-means combinado com a Janela de Parzen (*LSFCM parzen*), evolução do level set baseado nas densidades radiológicas do crânio (*LSDRC evol*), *LSFCM evol* e *CR* apresentaram resultados similares entre si em ACC, com 99.39%, 99.79%, 99.19% e 98.67%, ambos demonstraram resultados semelhantes com acessão do *CR*, não chegando a 90% em ACC e 79.26% na métrica de DICE, demonstrando inferioridade em relação aos demais métodos se tratando de similaridade. O método proposto obteve resultados superiores referentes a métrica de similaridade DICE, com

Tabela 3 – Comparação entre o método proposto (*Divisible Cell-Segmentation*) e métodos com diferentes abordagens para segmentação de AVC hemorrágico.

Métricas de Avaliação				
Abordagem	Métodos	Referências	ESP(%)	ACC(%)
Automática	<i>Divisible Cell-Segmentation</i>	Método Proposto	99.81 ± 0.09	99.80 ± 0.09
	LSFCM Parzen	(FILHO <i>et al.</i> , 2019b)	93.59 ± 17.10	99.39 ± 02.48
	LSDRC evol	(FILHO <i>et al.</i> , 2019b)	97.42 ± 02.23	99.79 ± 00.13
	LSFCM evol	(BHADAURIA <i>et al.</i> , 2013)	90.60 ± 21.10	99.19 ± 02.97
	CR	(PHAM <i>et al.</i> , 2000)	92.84 ± 21.88	98.67 ± 04.28
Manual	Watershed	(KORBES ANDRÉ, 2010)	87.32 ± 13.38	99.69 ± 00.22
	LSCPM	(WANG; BU, 2010)	83.03 ± 11.13	99.72 ± 00.23
	FCM	(NADA, a)	90.53 ± 21.31	99.19 ± 02.97
Automática	FPLS	(REBOUÇAS <i>et al.</i> , 2021)	99.94 ± 00.09	99.11 ± 00.09
	MLS	(BRAGA <i>et al.</i> , 2021)	99.92 ± 00.03	97.64 ± 16.14
	MLS	(BRAGA <i>et al.</i> , 2017)	98.50 ± 00.94	50.01 ± 27.76
	LSBRD	(REBOUÇAS <i>et al.</i> , 2017)	83.03 ± 11.13	99.75 ± 00.25
	Algoritmo Genético	(ROUHI <i>et al.</i> , 2015)	92.84 ± 21.88	99.00 ± 04.36
	Watershed	(KORBES ANDRÉ, 2010)	87.32 ± 13.38	99.84 ± 00.19
Automática <i>Deep Learning</i>	Detectron-f λ	(HAN <i>et al.</i> , 2020)	99.99 ± 0.02	99.83 ± 0.06
	Detectron-f δ	(HAN <i>et al.</i> , 2020)	99.97 ± 0.03	99.88 ± 0.05
	Detectron-f μ	(HAN <i>et al.</i> , 2020)	99.98 ± 0.03	99.88 ± 0.05
Abordagem	Métodos	Referências	DICE(%)	SEN(%)
Automática	<i>Divisible Cell-Segmentation</i>	Método Proposto	93.25 ± 3.89	98.82 ± 1.06
	LSFCM Parzen	(FILHO <i>et al.</i> , 2019b)	90.18 ± 15.74	99.86 ± 00.09
	LSDRC evol	(FILHO <i>et al.</i> , 2019b)	87.31 ± 14.10	99.81 ± 00.13
	LSFCM evol	(BHADAURIA <i>et al.</i> , 2013)	87.14 ± 18.47	99.86 ± 00.10
	CR	(PHAM <i>et al.</i> , 2000)	79.26 ± 18.30	99.66 ± 00.23
Manual	Watershed	(KORBES ANDRÉ, 2010)	86.63 ± 07.84	99.85 ± 00.11
	LSCPM	(WANG; BU, 2010)	88.85 ± 06.51	99.96 ± 00.05
	FCM	(NADA, a)	87.41 ± 18.50	99.86 ± 00.10
Automática	FPLS	(REBOUÇAS <i>et al.</i> , 2021)	88.42 ± 06.68	83.34 ± 08,72
	MLS	(BRAGA <i>et al.</i> , 2021)	86,74 ± 06,29	78,70 ± 09,40
	MLS	(BRAGA <i>et al.</i> , 2017)	61.90 ± 24.53	99.34 ± 01.23
	LSBRD	(REBOUÇAS <i>et al.</i> , 2017)	88,85 ± 06,51	99,96 ± 00,05
	Algoritmo Genético	(ROUHI <i>et al.</i> , 2015)	79.26 ± 18.30	99.66 ± 00.23
	Watershed	(KORBES ANDRÉ, 2010)	86.63 ± 07.84	99.85 ± 00.11
Automática <i>Deep Learning</i>	Detectron-f λ	(HAN <i>et al.</i> , 2020)	91.37 ± 3.70	85.21 ± 6.29
	Detectron-f δ	(HAN <i>et al.</i> , 2020)	94.09 ± 2.40	90.89 ± 4.57
	Detectron-f μ	(HAN <i>et al.</i> , 2020)	94.04 ± 2.42	90.61 ± 4.54

Fonte: Elaborada pelo autor.

93.25% contra 90.18%, 87.31%, 87.14% dos métodos LSFCM parzen, LSDRC evol e LSFCM evol, apresentando assim um desempenho maior em identificar regiões de contorno com mais precisão, que assemelham-se a borda do AVC. Isso pode ser provado pela comparação da identificação da não região do AVC pela métrica ESP, onde o método proposto foi superior aos métodos automáticos aqui citados, com 99.81% contra 93.59% obtidos pelo método LSFCM parzen, que

obteve a melhor métrica de SEN com 98.86%. Porém, o desvio padrão da métrica DICE chega a 15%, demonstrando o desempenho não equilibrado para a similaridade dos resultados em comparação. O método proposto, *Divisible Cell-Segmentation*, manteve um maior desempenho e equilíbrio entre as métricas obtidas, o que resultou nos resultados satisfatórios em segmentação apresentados nesta tese.

As abordagens diversas apresentaram diferentes resultados de ACC, com métodos com 50.01% de precisão, resultados não satisfatórios, já que o processo não obteve exatidão nas mais diferentes imagens do AVC. Korbes ANDRÉ (2010) obtiveram resultados de ACC acima dos 99%, porém se tratando de ESP e DICE, obteve 87.32% e 86.63%, demonstrando menos robustez do método em identificar regiões que não sejam bordas do AVC, ou regiões relacionadas a similaridade. Rebouças *et al.* (2021) apresentou resultados semelhantes ao de (KORBES ANDRÉ, 2010), porém com melhores resultados, mas inferiores aos obtidos pelo método *Divisible Cell-Segmentation*, principalmente nas métricas de DICE e SEN. Os métodos *Detectron-f λ* , *Detectron-f δ* e *Detectron-f μ* abordam uso de *deep learning* combinados a métodos com uso de *fine-tuning*, ambos os métodos apresentaram resultados equivalentes nas métricas, mas foi nas métricas DICE com 91.37%, 94.09% e 94.04% e SEN com 85.21%, 90.89% e 90.61%, que apresentaram maior discrepância em relação ao método proposto, com DICE em 93.25% SEN em 98.82%, demonstrando que as combinações dos métodos baseados em *deep learning* foram superados para o problema de segmentação de AVC hemorrágico.

A Tabela 4 apresenta diferentes métodos computacionais com uso de *deep learning* e *transfer learning* para segmentação de imagem de TC do AVC hemorrágico. Assim como os outros métodos aqui comparados, a tabela apresenta a comparação de entre o método proposto *Divisible Cell-Segmentation* e métodos de aprendizagem profunda, combinado a classificadores. Mesmo com o grande poder computacional (grande capacidade de processamento), os resultados de ACC e NPV apresentaram melhores resultados adquiridos pelo método proposto, com 99.80% de ACC e 99.98% de NPV. Os resultados apresentaram desempenho relativamente similares com desempenho acima de 99% para as referidas métricas, exceto os métodos Mask-EM e Mask-Bayes, onde apresentaram em média 98% para ACC. Essa média se aplicou para o desempenho avaliado pela métrica, ESP onde ambos apresentaram em média 98%. O método proposto obteve valores equiparados aos demais métodos Mask-KNN, Mask-RF, Mask-MLP, Mask-SVM, Mask-Dtrees e Mask-ADAB, ambos acima de 99% em ESP e relativamente semelhantes para métrica de FPR. Vale ressaltar, que o autor não realizou teste de validação cruzada nos treinamentos dos

métodos, podendo levar a discussão da precisão dos dados e a superficialidade dos resultados referente ao processo de treino e teste. Pode-se concluir assim, que para a segmentação com precisão em imagens de AVC, técnicas com uso de *fine-tuning* sem uso de *transfer learning* podem ser mais vantajosos, pois a relação de uso de grande capacidade de processamento pode ser fator decisivo para aplicações que necessitem baixo custo computacional, reduzindo assim a necessidade de processamento.

Na tabela 5, o método proposto é comparado com diferentes métodos baseados em *fine-tuning* apresentados na literatura. Os métodos são baseados em combinações *deep learning* a técnicas clássicas. O método *Divisible Cell-Segmentation* apresenta a obtenção de melhor desempenho nas métricas de PPV, NPV e ACC, com 98.55%, 99.98% e 99.80%, validando os excelentes desempenhos nos resultados de segmentação do AVC. Entre os métodos da tabela, os modelos propostos mais uma vez apresentou constância com menos inalterabilidade nos índices métricos, fazendo o método *Divisible Cell-Segmentation* mais estável para segmentação do AVC. Esta estabilidade em resultados de segmentação se dá pela definição real com altos índices de acerto, tanto da região do AVC na imagem de TC, quando da não região do AVC, nivelando os verdadeiros positivos com verdadeiros negativos. Desta forma, para uma análise mais profunda e precisa, é fundamental o processo de validação cruzada, que o autor também não menciona em sua abordagem.

Assim, o método proposto por este estudo, comparado a trabalhos do estado da arte, trouxe resultados bastante satisfatórios com o novo método automático para o problema de segmentação de AVC hemorrágico. Apresentando assim uma eficácia com menos custo computacional relacionados a métodos com uso de *deep learning*, trazendo robustez por meio de uma nova abordagem. A Figura 40 traz um gráfico interessante, é possível identificar os diferentes métodos de Marques *et al.* (2022), com seus resultados em diferentes níveis de obtenção de valores métricos. As diferentes cores denotam as diferentes métricas para uma melhor análise visual, mostrando assim os métodos e seus resultados. o método proposto *Divisible Cell-Segmentation* apresenta melhores resultados, analisando o gráfico, o Método (A), (B), (C), (D) e (E) desenvolvidos de Marques *et al.* (2022).

Os resultados de comparação de tempo podem ser analisados na Tabela 6, nos experimentos são apresentados diferentes resultados comparados ao método proposto para segmentação de AVC hemorrágico, método (*Divisible Cell-Segmentation*). Na tabela, o resultado de tempo de segmentação dos resultados baseados nos modelos da inicialização automática inteligente

de (HAN *et al.*, 2020) obtiveram 2.1 segundos para segmentação de AVCs hemorrágicos, onde foi superado com 1.8 segundos obtidos pelo método proposto, superando também diferentes trabalhos conceituados da literatura, sendo até equiparados ao tempo dos métodos FPLS e LSCPM, onde também obtiveram excelentes resultados.

Tabela 4 – Comparação dos resultados obtidos na segmentação do AVC Hemorrágico nas imagens de TC propostas por este estudo *Divisible Cell-Segmentation*, em comparação com os resultados de Xu *et al.* (2020) com a rede *Mask R-CNN*.

Métricas de Avaliação				
Abordagem	Métodos	Referências	ESP	FPR
Automática <i>Transfer Learning</i>	Divisible Cell-Segmentation	Método Proposto	99.81 ± 0.09	0.19 ± 0.09
	Mask-KNN	(XU <i>et al.</i> , 2020)	99.93 ± 0.08	0.07 ± 0.08
	Mask-RF	(XU <i>et al.</i> , 2020)	99.93 ± 0.08	0.07 ± 0.08
	Mask-MLP	(XU <i>et al.</i> , 2020)	99.93 ± 0.08	0.07 ± 0.08
	Mask-SVM	(XU <i>et al.</i> , 2020)	99.93 ± 0.09	0.07 ± 0.09
	Mask-EM	(XU <i>et al.</i> , 2020)	98.86 ± 3.39	1.14 ± 3.39
	Mask-DTrees	(XU <i>et al.</i> , 2020)	99.90 ± 0.10	0.10 ± 0.10
	Mask-Bayes	(XU <i>et al.</i> , 2020)	98.14 ± 7.61	1.86 ± 7.61
	Mask-ADAB	(XU <i>et al.</i> , 2020)	99.92 ± 0.13	0.08 ± 0.13
Abordagem	Métodos	Referências	ACC	NPV
Automática <i>Transfer Learning</i>	Divisible Cell-Segmentation	Método Proposto	99.80 ± 0.09	99.98 ± 0.02
	Mask-KNN	(XU <i>et al.</i> , 2020)	99.73 ± 0.33	99.80 ± 0.35
	Mask-RF	(XU <i>et al.</i> , 2020)	99.72 ± 0.36	99.79 ± 0.38
	Mask-MLP	(XU <i>et al.</i> , 2020)	99.72 ± 0.36	99.79 ± 0.38
	Mask-SVM	(XU <i>et al.</i> , 2020)	99.70 ± 0.37	99.77 ± 0.40
	Mask-EM	(XU <i>et al.</i> , 2020)	98.76 ± 3.36	99.89 ± 0.24
	Mask-DTrees	(XU <i>et al.</i> , 2020)	99.73 ± 0.31	99.83 ± 0.33
	Mask-Bayes	(XU <i>et al.</i> , 2020)	98.06 ± 7.63	99.88 ± 0.28
	Mask-ADAB	(XU <i>et al.</i> , 2020)	99.72 ± 0.34	99.80 ± 0.35

Fonte: Elaborada pelo autor.

Assim, pode-se concluir que o método *Divisible Cell-Segmentation* obteve melhor tempo de processamento, atingindo assim a eficácia comparado a trabalhos com uso de *deep learning* e outros trabalhos do estado da arte em e segmentação de AVC hemorrágico.

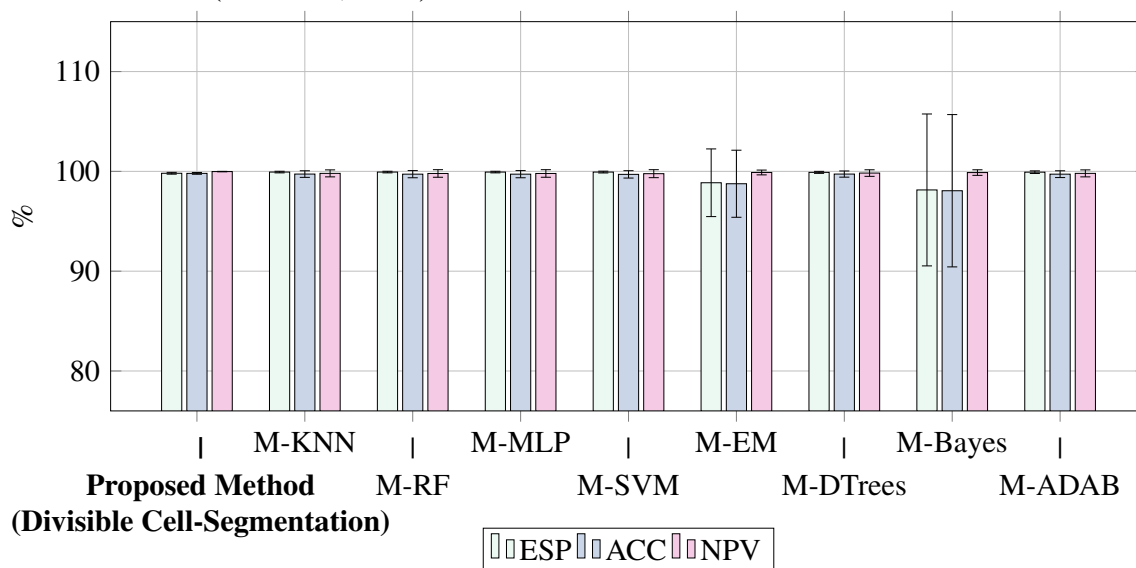
4.3.1.4 Considerações Finais — (Segmentação de AVC Hemorrágico)

O trabalho proposto por este estudo (*Divisible Cell-Segmentation*) é baseado em uma nova abordagem para inicialização automática de AVC hemorrágico e TCs do cérebro. O método inovador apresentou abordagem baseada em inicialização automática inteligente para detecção de AVC Hemorrágico, obtendo ótimos resultados comparados ao estado da arte. A segmentação baseado em divisão de celular computacionais sintéticas foi capaz de identificar a

borda do objeto de interesse (AVC hemorrágico) com precisão, o experimento obteve excelentes resultados, superando diferentes trabalhos da literatura, com 99.80% de acurácia.


O método inovador *Divisible Cell-Segmentation* trouxe um melhor desempenho comparado a trabalhos com uso de *deep learning* e diferentes métodos do estado da arte, tanto em tempo de segmentação, quanto em desempenho por custo computacional, com tempo de 1.898. Assim, o novo método para detecção e segmentação AVC hemorrágico em TCs demonstrou sua robustez e eficácia, bem como inovação na abordagem por meio de um novo método.

Figura 38 – Métricas de desempenho obtidas com o método proposto *Divisible Cell-Segmentation* e outros métodos encontrados e analisados na literatura com os métodos de (XU *et al.*, 2020).



Fonte: Elaborada pelo autor.

Figura 39 – Métricas de FPR obtidas com o método proposto *Divisible Cell-Segmentation* e outros métodos encontrados e analisados na literatura com os métodos de (XU *et al.*, 2020).



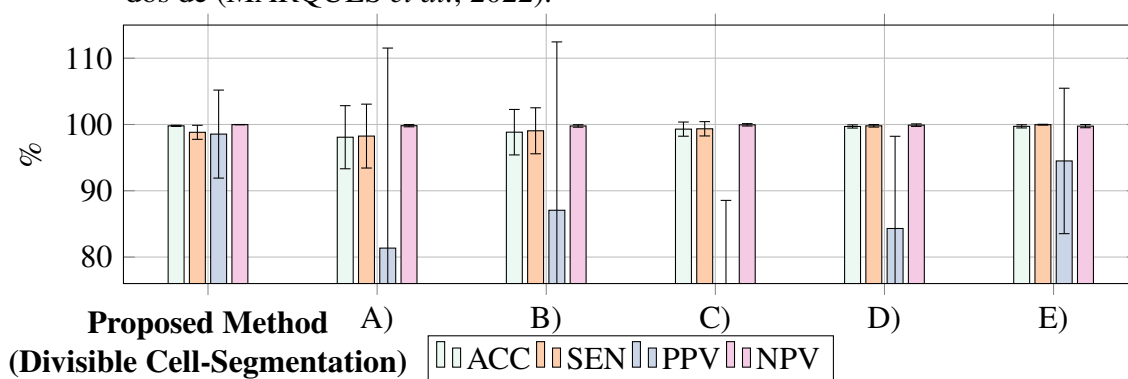
Fonte: Elaborada pelo autor.

Tabela 5 – Comparação dos resultados obtidos na segmentação do AVC Hemorrágico nas imagens de TC propostas por este estudo, em comparação com os resultados de (MARQUES *et al.*, 2022) com a rede *Mask R-CNN* e *fine-tuning*

Métricas de Avaliação				
Abordagem	Métodos	Referências	ACC	SEN
Automática <i>Fine-tuning</i>	<i>Divisible Cell-Segmentation</i>	Método Proposto	99.80 ± 0.09	98.82 ± 1.06
	A) <i>ft_{mask}Parzen</i>	(MARQUES <i>et al.</i> , 2022)	98.08 ± 4.76	98.25 ± 4.82
	B) <i>ft_{mask}Clustering_{parzen}</i>	(MARQUES <i>et al.</i> , 2022)	98.84 ± 3.43	99.05 ± 3.47
	C) <i>ft_{mask}GrowingRegion</i>	(MARQUES <i>et al.</i> , 2022)	99.30 ± 1.07	99.35 ± 1.08
	D) <i>ft_{mask}Clustering_{GrowingRegion}</i>	(MARQUES <i>et al.</i> , 2022)	99.70 ± 0.24	99.80 ± 0.19
	E) <i>ft_{mask}Parzen_{GrowingRegion}</i>	(MARQUES <i>et al.</i> , 2022)	99.72 ± 0.24	99.97 ± 0.06
Abordagem	Métodos	Referências	PPV	NPV
Automática <i>Fine-tuning</i>	<i>Divisible Cell-Segmentation</i>	Método Proposto	98.55 ± 6.64	99.98 ± 0.02
	A) <i>ft_{mask}Parzen</i>	(MARQUES <i>et al.</i> , 2022)	81.35 ± 30.18	99.82 ± 0.17
	B) <i>ft_{mask}Clustering_{parzen}</i>	(MARQUES <i>et al.</i> , 2022)	87.06 ± 25.40	99.78 ± 0.19
	C) <i>ft_{mask}GrowingRegion</i>	(MARQUES <i>et al.</i> , 2022)	69.12 ± 19.43	99.95 ± 0.18
	D) <i>ft_{mask}Clustering_{GrowingRegion}</i>	(MARQUES <i>et al.</i> , 2022)	84.31 ± 13.91	99.90 ± 0.19
	E) <i>ft_{mask}Parzen_{GrowingRegion}</i>	(MARQUES <i>et al.</i> , 2022)	94.50 ± 10.97	99.75 ± 0.24

Fonte: Elaborada pelo autor.

Figura 40 – Métricas de desempenho obtidas com o método proposto *Divisible Cell-Segmentation* e outros métodos encontrados e analisados na literatura com os métodos de (MARQUES *et al.*, 2022).



Fonte: Elaborada pelo autor.

Tabela 6 – Comparação do tempo de segmentação entre o método proposto e os métodos comparados nesta seção.

Técnica	<i>Tempo(s)</i>
Método proposto	1.898 ± 0.032
LSDRC parzen	2.29 ± 1.81
LSFCM Parzen	11.83 ± 6.72
LSDRC evol	25.42 ± 0.98
LSFCM evol	34.01 ± 3.39
CR	3.10 ± 1.70
Watershed	4.80 ± 0.62
LSCPM	1.76 ± 0.29
FCM	8.69 ± 3.16
FPLS	1.76 ± 0.29
MLS	3.74
LSBRD	4.81 ± 1.18
Detectron- $f\lambda$	2.231 ± 1.730
Detectron- $f\delta$	2.186 ± 1.890
Detectron- $f\mu$	2.295 ± 2.004
Mask-KNN	4.00 ± 0.02
Mask-RF	3.98 ± 0.01
Mask-MLP	4.50 ± 0.32
Mask-SVM	3.98 ± 0.01
Mask-EM	4.04 ± 0.10
Mask-DTrees	3.98 ± 0.01
Mask-Bayes	4.00 ± 0.05
Mask-ADAB	3.99 ± 0.02
A) $ft_{mask}Parzen$	6.49 ± 0.80
B) $ft_{mask}Clustering_{parzen}$	7.54 ± 0.80
C) $ft_{mask}GrowingRegion$	3.99 ± 0.05
D) $ft_{mask}Clustering_{GrowingRegion}$	4.61 ± 0.08
E) $ft_{mask}Parzen_{GrowingRegion}$	6.49 ± 0.50

Fonte: Elaborada pelo autor.

Em relação aos tempos de segmentação obtidos, os valores métricos apresentaram resultados semelhantes com pequenas variações em milésimos de segundos, superando outros trabalhos da literatura.

Para próximos estudos, serão explorados diferentes problemas nas próximas subseções, tais como aplicações nos diferentes problemas em imagens médicas; imagens pulmonares. A proposta traz como experimentos para solução em diferentes problemas de imagens médicas, como TCs e RMs.

4.3.2 Resultados — Abordagem Pulmonar

Os resultados gerados nesta seção são baseados no conjunto de dados apresentado na Subseção 2.9.2 de *dataset*, utilizados em diferentes trabalhos, discutidos na seção 4.3.2.2

Validação dos resultados (Imagens Pulmonares) — Comparação com Trabalhos da Literatura. A Etapa 1, de inicialização da abordagem com objetivo de detectar a região pulmonar. A abordagem vem demonstrando, com base nos testes em imagens médicas de AVC hemorrágico, um eficaz desempenho.

A Tabela 7 apresenta os resultados gerados por este estudo para detecção de pulmões em TCs, seguida dos resultados do teste de validação cruzada. Os resultados apresentados mostram a eficácia do modelo em detectar com precisão a região dos pulmões na imagem, detectando (em paralelo) ambos os pulmões em uma só imagens. O experimento serve de base para identificar a real região do pulmão e inicialização do processo de segmentação pelo método *Divisible Cell-Segmentation*, que usa o processo de detecção por meio de *bounding box* e máscara gerada, como parâmetro da célula para segmentação dos pulmões encontrados previamente na imagem de TC.

Tabela 7 – Resultados gerados pela abordagem com inicialização inteligente para detecção da região pulmonar em imagens de TCs.

Abordagem	<i>ACC</i>	<i>DICE</i>	<i>SEN</i>	<i>ESP</i>
Inicialização inteligente	99.00 ± 0.60	96.98 ± 1.21	96.74 ± 2.69	99.41 ± 0.50
Validação Cruzada				
Fold 1	99.01 ± 0.30	96.71 ± 0.80	95.34 ± 1.39	99.41 ± 1.38
Fold 2	99.00 ± 0.37	95.71 ± 1.29	96.88 ± 0.26	99.38 ± 1.70
Fold 3	99.00 ± 0.54	97.02 ± 0.21	96.51 ± 0.30	99.41 ± 1.08

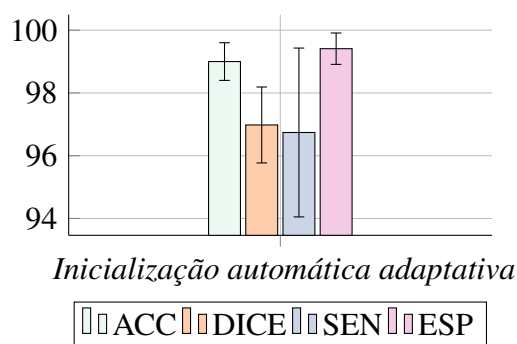
Fonte: Elaborada pelo autor.

As métricas apresentaram ótimos valores de desempenho, mostrando que o modelo treinado obteve êxito em identificar regiões pulmonares nas imagens de tomografias, assim como nas imagens de AVC hemorrágico. Pode-se concluir com estes resultados, que em ambos os experimentos tiveram acurácia com média de 99%, demonstrando a capacidade da abordagem de inicialização do método em aprender com eficácia regiões de interesse baseados em diferentes aquisições de imagens.

A Tabela 7 apresenta não só a métrica de *ACC* como um fator considerado bom resultado em detecção da região a ser segmentada, mas também por meio dos valores obtidos na métrica *ESP* (especificidade) que representa a identificação de regiões não pertencentes às regiões pulmonares, isso de fato torna o processo mais robusto tendo em vista a diversidade de patologias encontradas nas imagens de testes usadas neste experimento. Isso justifica o bom desempenho das métricas *DICE* e *SEN*, que em ambas obtiveram valores similares com 96%,

isso pode ser levado em conta devido as diferentes imagens pulmonares que tem como um grau de dificuldade o processo de inflar os pulmões e desinflar os pulmões, processo este, natural de respiração capturado nos exames e registrados nas imagens TCs. Tanto o processo de diferentes tamanhos de pulmões capturados nas imagens de TCs apresentados na Seção Descrição dos Problemas, Subseção 1.3.2 Pulmões — TCs, quanto ao processo de diferentes patologias dentro dos pulmões tornam os modelos de detecção desafiadores dentro do campo da segmentação pulmonar, assim como as patologias em diferentes imagens pulmonares.

Figura 41 – Ilustração dos valores métricos obtidos referente a inicialização inteligente para detecção da região pulmonar baseado na inicialização automática para detecção da região pulmonar.



Fonte: Elaborada pelo autor.

Ao analisar o gráfico da Figura 41 é possível identificar os diferentes valores correspondentes as barras verticais, onde representam cada barra, ACC. Na Tabela 7 a métrica de coeficiente de *Dice*, SEN, e ESP, é possível analisar o quão a abordagem foi eficiente em detectar a região pulmonar. Foi realizada a validação cruzada separando o conjunto de dados em três *folds*, cada uma com 412 *slices*, totalizando 39 exames de diferentes pacientes. Então, foram realizados três seções de treinamento/teste, cada uma com dois *folds* para treinamento e um *fold* para teste, como apresentados na Tabela 7. Analisando os resultados alcançados em cada uma das seções de treinamento/teste com diferentes *folds*, é possível identificar a similaridade entre os *folds* testados na realização do treinamento com 66% e testes, em 33% das imagens apresentados no *dataset*.

A Figura 42 apresenta o resultado na detecção de diferentes imagens pulmonares em TCs, desta forma é possível analisar de forma visual a eficácia a abordagem de inicialização automática inteligente em detectar por meio de *bounding box* os pulmões nas imagens, com os seus respectivos desafios, gerando os parâmetros da célula computacional sintética. Nas imagens da Figura 42 é possível identificar a precisão da detecção em ambas as regiões dos

pulmões. Na coluna (A) são apresentados as TCs, que servem de comparação visual da região, onde apresentam diferentes tamanhos e formas para as regiões pulmonares no exame. Vale ressaltar que para cada forma capturada na tomografia, existe um devido grau de problemática de identificação, bem como a detecção das diferentes formas e a proximidade de um pulmão com outro, como mostram as imagens 2 e 4 da coluna (A), tais problemas são frequentemente encontrados na literatura, gerando diferentes discussões para soluções eficientes.


Nesta abordagem, na coluna (B) da figura 42, é possível visualizar a otimização e eficácia do modelo em separar as regiões pulmonares, delimitando corretamente, por meio de *bounding box* com caixas delimitadoras de cor verde, no início de um pulmão, e no fim do outro. Isto certamente traz grandes benefícios para o processo de segmentação, que temos como base a região limite do pulmão. Logo este processo sendo o limite de um processo de segmentação, na qual os parâmetros celulares da célula computacional sintética desenvolvida por este estudo, carregam seus valores de parâmetros para definição adaptativa do processo de divisão celular, bem como os parâmetros de delimitação geradas pela inicialização inteligente que gera máscara “bordas” da região pulmonar, ou seja, máscara gerada pelo processo de inicialização da abordagem proposta, serem usadas como parâmetro de parada das células computacionais sintéticas por meio do limiar médio da região da máscara gerada pelo processo de detecção. Neste sentido, a máscara pulmonar é calculada com base na região da imagem de entrada, onde *threshold* limiar calculado de acordo com *pixels* da borda pulmonar em tons de cinza, gerando assim o valor de limiar médio de parada da célula computacional sobre a imagem pulmonar.

Na próxima seção é apresentado o processo de segmentação com base dos parâmetros de saída da inicialização automática inteligente.

4.3.2.1 Segmentação Pulmonar

Nesta subseção é apresentado os resultados da segmentação pulmonar em imagens de TCs, com o uso do método proposto *Divisible Cell-Segmentation*. Assim, utilizado para segmentação de regiões de AVC hemorrágico em imagens médicas, o método proposto apresenta a aplicação em imagens pulmonares com diferentes estruturas pulmonares e desafios patológicos. Este contexto traz como base a primeira fase da metodologia, processo de inicialização automático inteligente. Uma vez treinando o modelo para detecção de pulmões em imagens de TCs, o método é iniciado assim como para as outras imagens médicas já testadas (Imagens de TC de AVC hemorrágico) nestes estudos apresentados nesta tese. Ao detectar a região pulmonar, segue

Figura 42 – Resultado da inicialização inteligente para detecção da região pulmonar em imagens de TCs. As regiões detectadas apresentam a sobreposição por meio de *bounding box*, uma espécie de caixa delimitadora demarcando a área limite dos Pulmões.



Fonte: Elaborada pelo autor.

para o processo de segmentação pulmonar em duas regiões da mesma imagem, pois agora se trata de duas regiões de pulmões. Ambos são calculados os centroides de cada pulmão na imagem de TC, e em paralelo é aplicado o processo de segmentação por meio de células computacionais sintéticas que se dividem até encontra a borda pulmonar, processo já descrito na subseção de Metodologia. Subseção 3.2 Fase 2: Segmentação — Método *Divisible Cell-Segmentation*.

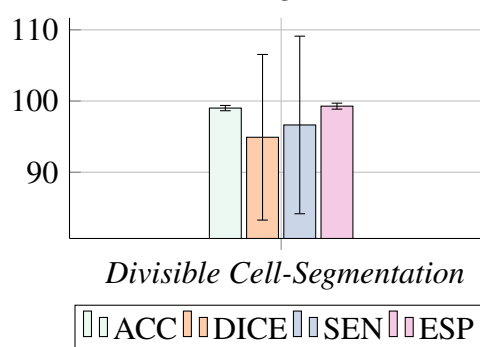
Tabela 8 – Resultados gerados pelo Método *Divisible Cell-Segmentation* para segmentação de pulmões em imagens de TCs.

Segmentação Pulmonar	ACC	DICE	SEN	ESP
<i>Divisible Cell-Segmentation</i>	99.01 ± 0.37	94.91 ± 11.63	96.64 ± 12.47	99.28 ± 0.42

Fonte: Elaborada pelo autor.

A segmentação dos pulmões com uso do método proposto *Divisible Cell-Segmentation* apresentaram resultados satisfatórios, como mostra na Tabela 8, foi possível obter uma precisão de 99.01% de Acurácia, demonstrando total eficácia do processo de segmentação da região de ambos os pulmões nas imagens de TCs. A métrica de coeficiente de DICE apresentou valores relevantes para segmentação, obtendo 94.91%, mostrando a eficiência em encontrar as fronteiras das diferentes formas pulmonares. Mesmo com grandes desafios em segmentar as regiões pulmonar, o método obteve eficácia em delinear as bordas do objeto de interesse. Note que o processo final de detecção trouxeram ganhos similares nas métricas de SEN com 96.64% e ESP com 99.28%, onde obtiveram valores aproximados.

Figura 43 – Ilustração dos valores métricos obtidos referente a segmentação da região pulmonar com uso do método *Divisible Cell-Segmentation* referente a Tabela 8.



Fonte: Elaborada pelo autor.

A figura 43 traz o gráfico comparativo em forma de barras verticais, onde é possível analisar os diferentes valores obtidos no processo de segmentação relacionados as diferentes métricas de avaliação, Apontando assim, as métricas de ACC e ESP como métricas de maiores valores dentre as demais métricas, onde ambas as métricas foram escolhidas com base em

métricas utilizadas para comparações de trabalhos já realizados no estado da arte.

A Figura 44 apresenta o resultado do processo de segmentação realizado pelo método *Divisible Cell-Segmentation*. Na figura é possível visualizar o processo de segmentação iniciada pela Fase de Inicialização, onde o centroide é calculado com base da detecção e parâmetros do *bounding box* realizado na Fase 1 de detecção da região pulmonar. A sequência de imagens, iniciadas da esquerda para a direita na Figura 44, apresenta o processo de aplicação das células, bem como suas subdivisões com o objetivo de encontrar a borda pulmonar. A imagem final apresenta o resultado final da segmentação com base do método *Divisible Cell-Segmentation*. Ao final deste processo, é apresentado na figura 44 a imagem segmentada, ligando todos os pontos centrais celulares, de maneira a compor a máscara binária da região do pulmão.

Na Figura 45 é possível analisar visualmente que, em diferentes imagens com diferentes patologias pulmonares, bem como diferentes formas, os pulmões foram segmentados com eficácia. Na imagem, os resultados demonstram eficiência do avanço das células subdividindo-as até a borda do objeto de interesse. O método trouxe robustez por se tratar de células artificiais computacionais que tem como objetivo alcançar as bordas dos pulmões. As regiões de dentro dos pulmões (Diferentes patologias) sempre foram desafios para segmentação do pulmão, porém o método por se tratar de divisão de certos pontos de avanço (regiões denominada de célula artificial) é possível com suas subdivisões alcançar regiões especificar onde o processo de segmentação poderia esbarrar em regiões de patologias dificultando o processo de segmentação, para melhorar este processo, nas imagens de pulmão foi realizado um pré-processo de limiarização na imagem de entrada.


Tabela 9 – Tempo de segmentação médio do método proposto *Divisible Cell-Segmentation* para a segmentação de pulmonar em imagens de TC.

Segmentação Pulmonar	Tempo(s)
Divisible Cell-Segmentation	2.031 ± 0.99

Fonte: Elaborada pelo autor.

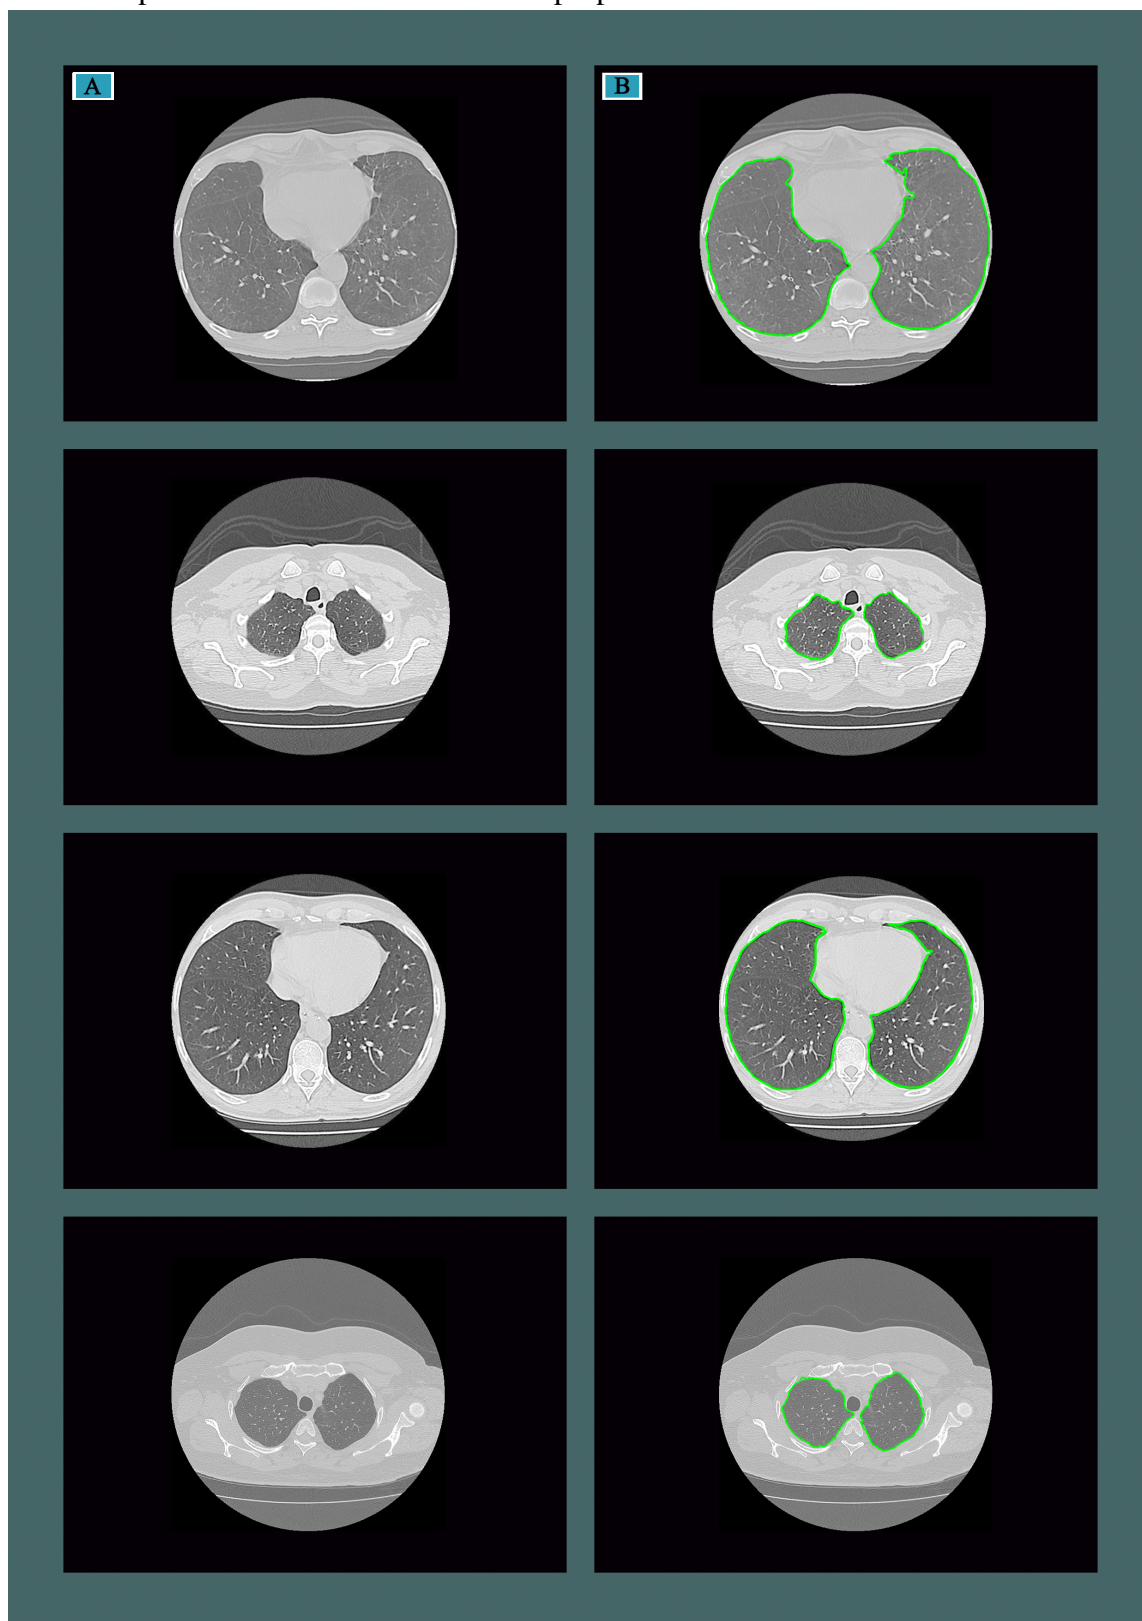
A tabela 9 ilustra a média e desvio padrão do tempo de segmentação do método proposto, *Divisible Cell-Segmentation* para a segmentação do pulmão em imagens de TC. Nota-se que mesmo para a problemática do pulmão, na qual o modelo deve segmentar ambos os pulmões na imagem, o modelo obteve resultados satisfatórios, com média pouco maior que um segundo, de 2.03 segundos, e baixo desvio padrão, de 0.99 segundos. Dessa forma evidencia-se a velocidade do método e sua otimização em tempo de segmentação.

Figura 44 – Segmentação pulmonar em imagem de TC realizada pelo método *Divisible Cell-Segmentation*. Ao longo das imagens, é possível observar a evolução da movimentação das células computacionais sintéticas, além da sua divisão, de forma a detectar as bordas dos pulmões. Na última imagem, encontra-se o resultado da segmentação dos pulmões com uso do método após a etapa de conexão entre os pontos centrais de cada célula na borda do pulmão.



Fonte: Elaborada pelo autor.

Figura 45 – Resultado da segmentação com uso do método *Divisible Cell-Segmentation* em diferentes imagens pulmonares em TCs. Na coluna (a) são apresentadas as TCs, e na coluna (B) são apresentados os resultados da segmentação da região das bordas pulmonares com uso do método proposto.



Fonte: Elaborada pelo autor.

4.3.2.2 Validação dos Resultados (Imagens Pulmonares) - Comparação com Trabalhos da Literatura

Esta subseção tem como finalidade, apresentar uma discussão entre os diferentes trabalhos no estado da arte em comparação ao método proposto *Divisible Cell-Segmentation*, a fim de validar o experimento realizado para segmentação de pulmões em imagens de TCs. Em meio a literatura é possível comparar com diferentes trabalhos, desde trabalhos com clássicos com uso de PDI, a trabalhos relacionados ao uso de *deep learning* e *Fine-tuning*.

A Tabela 10 apresenta a comparação do método proposto *Divisible Cell-Segmentation*, a diferentes trabalhos do estado da arte. O método proposto apresentou excelentes resultados na segmentação da região do pulmão, obtendo 99.01% de ACC contra 98.01% de FLog Parzen Level Set (FLPS), 97.88% de vector field convolution (VFC), 96.79% gradient vector flow (GFV), 97.56% THR mod e 95.77% de THR multi, ambos modelos com abordagem manual. Superando assim modelos da literatura baseados em inicialização manual. Isso pode ser analisado no índice de JAC que apresenta os resultados de similaridade entre a região de segmentação real da borda do pulmão, onde o método proposto obteve 92.13% contra 78,82 no pior caso, pelo método THR multi, e 91.45 do método FPLS com melhor abordagem comparada. Neste sentido, pode se concluir o novo método obteve valores relevantes nas métricas de SEN e coeficiente de Dice, onde apresentaram resultados métricos próximos. Vale ressaltar que o método proposto *Divisible Cell-Segmentation* é um método que inicializa de forma automática, fazendo a detecção prévia sem intervenção humana em sua inicialização, detecção da região pulmonar, bem como a segmentação das bordas com alta precisão.

A eficácia do modelo proposto pode ser comparada, também, a métodos da literatura, cujo abordam a inicialização automática para segmentação. A tabela 10 apresenta diferentes métodos automáticos do estado da arte, a comparação entre eles e o método *Divisible Cell-Segmentation* proporciona uma visão do método proposto, do quão eficaz foi sua abordagem em encontrar diferentes regiões do pulmão, cujo processo é extremamente difícil devido a diferentes formas do contorno de um pulmão, capturado pelo processo de respiração na aquisição dos exames TC. O método proposto superou em ACC todos os métodos apresentados na Tabela 10, com 99.01% contra 97.17%, 98.84%, 98.86%, 98.93%, 98.89%, 98.04%, e 09.99% referente aos métodos (NBLS, MLS, FGAC, OPS-Euclidean, SISDEP, CRISP e CRAD, ambos métodos conceituados na literatura. Concluindo assim, que o método *Divisible Cell-Segmentation* obteve eficácia em segmentar com precisão imagens de TC pulmonar, com as mais variadas estruturas e

formas do pulmão.

A Tabela 11 apresenta o tempo de segmentação do modelo *Divisible Cell-Segmentation*, bem com a eficácia comparada aos métodos apresentados, com diferentes abordagens manuais e automáticas. Obtendo 2.03 segundos, superando diferentes e poderosos métodos de segmentação pulmonar.

Tabela 10 – Comparação da segmentação pulmonar entre os métodos FPLS, VFC, GVF, THR mod, THR multi, NBLs, MLS, FGAC, OPS-Euclidean, SISDEP, CRISP e CRAD.

Métricas de Avaliação				
Abordagem	Métodos	Referências	ACC	SEN
Manual	Divisible Cell-Segmentation	Método Proposto	99.01 ± 0.37	96.64 ± 12.47
	FPLS	(REBOUÇAS <i>et al.</i> , 2021)	98.97±00.65	98.57±01.78
	VFC	(XU; PRINCE, 1998)	97.88±01.29	98.26±01.31
	GVF	(LI; ACTON, 2006)	96.79±03.61	96.75±05.10
	THR mod	(ALEXANDRIA <i>et al.</i> , 2010)	97.56±01.63	98.22±01.28
	THR multi	(ALEXANDRIA <i>et al.</i> , 2010)	95.77±3.96	97.68±03.45
Automático	NBLs	(BRAGA <i>et al.</i> , 2021)	97.17 ± 1.09	82.48 ± 6.16
	MLS	(BRAGA <i>et al.</i> , 2017)	98.84 ± 0.46	97.39 ± 2.87
	FGAC	(MEDEIROS <i>et al.</i> , 2019)	98.86±00.46	99.21±00.66
	OPS-Euclidean	(FILHO <i>et al.</i> , 2019a)	98.93±0.53	99.00±0.79
	SISDEP	(FELIX <i>et al.</i> , 2009)	98.89±0.52	98.99±0.65
	CRISP	(FILHO <i>et al.</i> , 2011)	98.04±0.89	98.01±1.23
	CRAD	(FILHO <i>et al.</i> , 2014)	98.99±0.57	99.45±0.43
Abordagem	Métodos	Referências	JAC	DICE
Manual	Divisible Cell-Segmentation	Método Proposto	92.13 ± 2.18	94.91 ± 11.63
	FPLS	(REBOUÇAS <i>et al.</i> , 2021)	91.45 ± 2.62	95.51 ± 1.42
	VFC	(XU; PRINCE, 1998)	87.62 ± 4.81	93.33 ± 2.82
	GVF	(LI; ACTON, 2006)	85.11 ± 7.71	91.76 ± 4.84
	THR mod	(ALEXANDRIA <i>et al.</i> , 2010)	86.65 ± 3.79	92.81 ± 2.21
	THR multi	(ALEXANDRIA <i>et al.</i> , 2010)	78.82 ± 14.43	87.29 ± 11.18
Automático	NBLs	(BRAGA <i>et al.</i> , 2021)	81.57 ± 6.18	89.71 ± 4.01
	MLS	(BRAGA <i>et al.</i> , 2017)	92.76 ± 2.45	96.23 ± 1.34
	FGAC	(MEDEIROS <i>et al.</i> , 2019)	92.73 ± 3.43	96.19 ± 1.93
	OPS-Euclidean	(FILHO <i>et al.</i> , 2019a)	93.75 ± 2.09	96.76 ± 1.12
	SISDEP	(FELIX <i>et al.</i> , 2009)	93.30 ± 1.87	96.52 ± 1.01
	CRISP	(FILHO <i>et al.</i> , 2011)	88.31 ± 4.56	93.73 ± 2.70
CRAD	(FILHO <i>et al.</i> , 2014)	93.72 ± 3.15	96.73 ± 1.73	

Fonte: Elaborada pelo autor.

Tabela 11 – Tempo médio de segmentação do *Divisible Cell-Segmentation* em relação a outros métodos.

Métodos	Tempo(s)
Método Proposto (<i>Divisible Cell-Segmentation</i>)	002.03 ± 0.99
FPLS	001.32 ± 0.09
NBLS	000.13 ± 0.02
MLS	002.01 ± 0.46
GVF	240.00 ± 3.05
VFC	030.00 ± 2.67
OPS Euclidean	005.86 ± 1.96
SISDEP	004.90 ± 2.02
CRAD	002.00 ± 0.16
FGAC	001.85 ± 0.50
Fonte: Elaborada pelo autor.	

A Tabela 12 apresenta diferentes métodos computacionais baseados em *deep learning* e métodos com uso de *fine-tuning*. O estudo de (HU *et al.*, 2020) apresentou diferentes modelos com uso da rede *Mask R-CNN* para a segmentação da mesma base de dados de pulmão, assim como o estudo de 12 apresentou métodos baseados em *fine-tuning*. na tabela é possível analisar o desempenho do método desta tese, que apresentou resultados excelentes comparados ao estado da arte, superando métodos computacionais de alto desempenho com uso de *transfer learning*, com alto custo computacional. Os métodos Mask+Bayes, Mask+SVM, Mask+K-means e Mask+EM, obtiveram resultados de ACC em 86.42%, 95.78%, 97.68% e 97.28%. Demonstrando assim a eficácia do método *Divisible Cell-Segmentation* para segmentação pulmonar. Vale salientar que todos os métodos utilizaram a mesma base de dados para treinamento dos modelos *deep learning*. Neste contexto, o modelo superou com grandes diferenças o modelo Mask+Bayes como a pior abordagem entre os métodos do autor, com diferença de 13% na métrica de ACC, e quase 3% em seu melhor método convolucional Mask+K-means. O que comprova, que mesmo com abordagens com maior capacidade de processamento, o modelo *Divisible Cell-Segmentation* superou, conforma os resultados apresentados nas métricas de SEN obtendo 96.64, e em ESP com 99.28 assemelhando-se qualitativamente nos resultados. A métrica de DICE apresenta valores de similaridade próximas ao modelo Mask+K-means obtendo pouco mais de 2% de diferença, mesmo com o alto desempenho por parte da clusterização do modelo *transfer learning*.

Os métodos de (HAN *et al.*, 2020) baseados em *fine-tuning* obtiveram resultados interessantes. Os métodos baseados no *framework Detectron2-fλ* é baseado em *fine-tuning* usando o *framework Detectron2* combinado com a técnica de janelamento de *Parzen*. O método

Detectron-f δ é baseado em *fine-tuning* usando a rede *Detectron2* combinado com a Janela *Parzen* e *Clusterização*. Já o método *Detectron-f μ* é baseado no uso de *fine-tuning* usando a *Detectron2* combinado com a Janela de *Parzen*, Crescimento de Região e *Clusterização*.

O método obteve uma acurácia de 99.01%, equiparando-se e superando o estado da arte para problemas similares com uso de detecção e segmentação por meio de uso de *deep learning*. A similaridade entre os valores obtidos nas métricas de coeficiente de DICE, SEN e ESP tornaram o novo método *Divisible Cell-Segmentation*, alternativas não só para problemas em imagens de pulmões, mas para diferentes problemas em imagens médicas, como são apresentados nos experimentos desta tese.

Tabela 12 – Comparação do método proposto, a métodos com abordagem *deep learning* e *fine-tuning* para segmentação pulmonar.

Métricas de Avaliação				
Abordagem	Métodos	Referências	ACC	DICE
Automatica <i>Deep Learning</i>	Divisible Cell-Segmentation	Método Proposto	99.01 ± 0.37	94.91 ± 11.63
	Mask + Bayes	(HU <i>et al.</i> , 2020)	86.42 ± 11.11	86.42 ± 11.11
	Mask + SVM	(HU <i>et al.</i> , 2020)	95.78 ± 2.62	95.78 ± 2.62
	Mask + K-means	(HU <i>et al.</i> , 2020)	97.68 ± 3.42	97.33 ± 3.24
	Mask + EM	(HU <i>et al.</i> , 2020)	97.28 ± 3.85	87.63 ± 9.39
Automática <i>Fine-Tuning</i>	Divisible Cell-Segmentation	Método proposto	99.01 ± 0.37	94.91 ± 11.63
	Detectron-f λ	(HAN <i>et al.</i> , 2020)	98.95 ± 0.61	96.74 ± 1.44
	Detectron-f δ	(HAN <i>et al.</i> , 2020)	99.02 ± 0.59	97.03 ± 1.24
	Detectron-f μ	(HAN <i>et al.</i> , 2020)	99.02 ± 0.60	97.01 ± 1.25
Abordagem	Métodos	Referências	SEN	ESP
Automática <i>Deep Learning</i>	Divisible Cell-Segmentation	Método Proposto	96.64 ± 12.47	99.28 ± 0.42
	Mask + Bayes	(HU <i>et al.</i> , 2020)	91.06 ± 14.66	78.05 ± 17.25
	Mask + SVM	(HU <i>et al.</i> , 2020)	96.69 ± 10.24	92.18 ± 4.87
	Mask + K-means	(HU <i>et al.</i> , 2020)	96.58 ± 8.58	97.11 ± 3.65
	Mask + EM	(HU <i>et al.</i> , 2020)	95.86 ± 8.67	96.42 ± 4.49
Automática <i>Fine-Tuning</i>	Divisible Cell-Segmentation	Método proposto	96.64 ± 12.47	99.28 ± 0.42
	Detectron-f λ	(HAN <i>et al.</i> , 2020)	96.52 ± 3.16	99.29 ± 0.76
	Detectron-f δ	(HAN <i>et al.</i> , 2020)	96.54 ± 2.73	99.45 ± 0.47
	Detectron-f μ	(HAN <i>et al.</i> , 2020)	96.74 ± 2.78	99.45 ± 0.49

Fonte: Elaborada pelo autor.

Tabela 13 – Tempo médio de segmentação do *Divisible Cell-Segmentation* em relação aos métodos baseados em *deep learning* e *fine-tuning* para segmentação pulmonar


Métodos	Tempo(s)
Método proposto	02.03 ± 0.99
Mask + Bayes	13.41 ± 5.19
Mask + SVM	11.59 ± 2.57
Mask + K-means	11.24 ± 3.05
Mask + EM	12.30 ± 2.17
Detectron-f λ	2.231 ± 1.730
Detectron-f δ	2.186 ± 1.890
Detectron-f μ	2.295 ± 2.004

Fonte: Elaborada pelo autor.

O coeficiente Dice (DICE) mostrou diferenças positivas em comparação ao *Divisible Cell-Segmentation*, exceto para o método *Detectron-f λ* , que apresentou valores inferiores. O método *Detectron-f λ* não conseguiu superar *Divisible Cell-Segmentation*, considerando que apenas a Janela *Parzen* como um uso *fine-tuning* teve dificuldade em encontrar as bordas dos ângulos mais fechados. Os modelos *Detectron-f δ* e *Detectron-f μ* , tinham ligeiramente melhor resultados comparados aos modelos do autor, mas comportou-se de forma semelhante se tratando dos valores de desvio padrão. Com a avaliação de DICE que analisa o desempenho calculado da sobreposição, os resultados foram relativamente semelhantes, ambos com 97%, contra 96 e 94% do método proposto. Tais resultados mostram a eficiência dos diferentes modelos em fazer pequenos ajustes para a segmentação relacionada à borda do pulmão. A Tabela 13 Apresenta diferentes tempos de segmentação pulmonar com uso de *deep learning*, na qual o método proposto apresentou melhor eficácia na estimativa de tempo de segmentação pulmonar.

A Figura 46 apresenta o gráfico os diferentes métodos baseados em segmentação pulmonar, onde ilustra a representação por meio de barras verticais relacionadas a métrica de ACC. Apresentando os desempenhos entre os mais diferentes métodos.

Figura 46 – Ilustração dos valores métricos obtidos referente a segmentação da região pulmonar com uso do método *Divisible Cell-Segmentation* referente a Tabela 8.



■ Divisible Cell-Segmentation ■ Detectron-f λ ■ Detectron-f δ ■ Detectron-f μ

Fonte: Elaborada pelo autor.

A figura permite a análise visual da acurácia dos diversos modelos apresentados no gráfico, isso corrobora para uma análise mais profunda com uso de CNNs onde apresentam um cenário na literatura com diversas aplicações com enfoque na área de estudo de imagens médicas, visão computacional e modelos inteligentes. A similaridade entre a métricas representa a diversidade de métodos, e a eficácia do método proposto.

Com o objetivo de validar a equivalência estatística entre os resultados obtidos pelo método proposto *Divisible Cell-Segmentation* e os trabalhos encontrados na literatura, presentes na tabela 12, foi-se realizado o teste de Kolmogorov-Smirnov sobre o conjunto de amostras, comparando os vetores métricos que compõe a média e desvio padrão do método de Hu *et al.* (2020), e o método proposto, com um coeficiente de confiabilidade de 99%. Dessa forma, na tabela 12 pode-se constatar o resultado do teste, sendo a Figura 4.1, a legenda da tabela.

$$K \quad teste \quad \left\{ \begin{array}{l} \square = \text{Igualdade Estatística} \\ \boxtimes = \text{Diferença Estatística} \end{array} \right. \quad (4.1)$$

Tabela 14 – Tabela de teste estatístico de Kolmogorov-Smirnov realizada nos resultados métricos dos métodos utilizados na segmentação de imagens de pulmão de TC, sendo essas técnicas, o método proposto *Divisible Cell-Segmentation* e os métodos desenvolvidos por Hu *et al.* (2020): Detectron- $f\lambda$, Detectron- $f\delta$ e Detectron- $f\mu$.

Métodos		Acc	Dice	Sen	Spe
Método Proposto <i>(Divisible Cell-Segmentation)</i>	-Detectron- $f\lambda$	□	□	□	□
Método Proposto <i>(Divisible Cell-Segmentation)</i>	-Detectron- $f\delta$	□	□	□	□
Método Proposto <i>(Divisible Cell-Segmentation)</i>	-Detectron- $f\mu$	□	□	□	□

Fonte: Elaborada pelo autor.

O resultado do teste estatístico de Kolmogorov-Smirnov presente na tabela 14 indica igualdade estatística entre os resultados métricos do método proposto e os resultados métricos dos modelos desenvolvidos por Hu *et al.* (2020), ilustrados na tabela 12, para a mesma base de dados utilizada. Dessa forma, pode-se afirmar que, embora os resultados sejam visualmente diferentes, possuindo médias e desvios padrões distintos, são estatisticamente equivalentes ao se analisar todo o conjunto de dados utilizados para exprimir essa média e desvio padrão se analisados com o método estatístico de Kolmogorov-Smirnov.

4.3.2.3 Considerações Finais — (Segmentação Pulmonar)

Ao final desta seção, pode se concluir que o método *Divisible Cell-Segmentation* obteve excelentes resultados, com super eficácia em segmentar as bordas da estrutura pulmonar. A comparação entre os mais diferentes métodos conceituados no estado da arte com abordagem manual, automática, uso de *deep learning* e *fine-tuning* proporcionou uma visão geral da eficácia dos resultados gerado pelo método proposto. Em uma análise geral dos resultados com base da segmentação de TC pulmonar, pode-se afirmar a eficácia e eficiência na detecção da região pulmonar e na segmentação das bordas do pulmão, com 99.01% de acurácia e 2.03 segundos, atingindo um robusto tempo de segmentação.

4.4 Análise Geral dos Resultados do Método Proposto.

A fim de trazer uma análise geral dos resultados obtidos pelo método proposto, bem como uma contextualização relacionada as Fases 1 e 2 da metodologia desta tese, a referida seção analisa os resultados baseados nas diferentes problemáticas em detecção e segmentação em imagens de TCs de AVC Hemorrágico e Pulmão.

O estudo levou em consideração inicialmente os experimentos dos ensaios apresentado na seção 4.1 Ensaios Experimentais, onde traz inicialmente uma visão para uma nova abordagem e contribuição em processamento de imagens médicas, no eixo de pesquisa de Visão Computacional e segmentação em imagens digitais. Os resultados apresentados na seção de ensaio proporcionaram uma nova abordagem para segmentação de imagens a partir da detecção do centroide em uma imagem digital. Visualmente foi possível identificar pontos de bordas em um determinado objeto de interesse em uma imagem digital bidimensional, este processo capaz de percorrer a imagem por meio de células computacionais sintéticas com o objetivo de se dividirem e multiplicarem, proporcionou uma nova abordagem para segmentação em imagens digitais.

A partir dos ensaios experimentais onde possibilitou uma análise visual, foi possível aplicar em um problema real para segmentação de AVC Hemorrágico, processo este bastante discutido na literatura. Este processo de teste em imagens de TCs trouxe resultados animadores, pois em posse da segmentação real realizadas por médicos especialistas, foi possível gerar métricas de avaliação para comparar com outros modelos computacionais que usaram a mesma base de dados com os dados chamado "padrão ouro"(imagens segmentadas por especialistas).

Em posse dos resultados compatíveis com o estado da arte gerados pelo novo método de ensaio, outros problemas do estado da arte foram agregados ao objeto de pesquisa, como as imagens de TCs de Pulmões, *datasets* contendo o "padrão ouro" de cada exame de diagnóstico por imagem.

Na metodologia proposta por esta tese, foi proposta uma abordagem de inicialização inteligente para em detecção das regiões a serem segmentadas, então o método proposto foi abordado para problemas de imagem médica (AVC hemorrágico e imagens Pulmonares). A primeira fase de resultado do estudo obteve resultados satisfatórios, já que a inicialização para detecção das regiões previamente treinadas, obtiveram acima de 99% de ACC na região de interesse, tornando o processo de inicialização eficaz para detectar regiões em imagens médicas de TC. Os primeiros resultados gerados e comparados com o estado da arte (AVC hemorrágico) obtiveram 99.37% de acurácia, obtendo uma precisão eficaz na inicialização inteligente para detecção do AVC. Para a fase segmentação das bordas de AVC hemorrágico, o novo método proposto por este estudo *Divisible Cell-Segmentation* obteve uma acurácia de 99.80, superando trabalhos renomados encontrados no estado da arte.

Tabela 15 – Comparação entre os resultados do método proposto *Divisible Cell-Segmentation* para as bases de TC de cérebro e TC de pulmão. Na tabela, é possível analisar os resultados da abordagem de inicialização inteligente para detecção e segmentação das regiões de interesse.

Análise do Método			
Abordagem	<i>ACC</i>	<i>ESP</i>	<i>SEN</i>
AVC Hemorrágico			
Deteção	99.37 ± 00.42	99.41 ± 00.34	91.14 ± 05.03
Segmentação	99.80 ± 00.09	99.81 ± 00.09	99.82 ± 01.06
Pulmão			
Deteção	99.00 ± 00.60	99.41 ± 00.50	96.74 ± 02.69
Segmentação	99.01 ± 00.37	99.28 ± 00.42	96.64 ± 12.47

Fonte: Elaborada pelo autor.

Tais resultados podem ser analisados na Tabela 15, onde apresentam o resultado de ACC das imagens de TC de AVC Hemorrágico e TC de Pulmões. A tabela traz as principais métricas em comum de cada experimento, escolhidas de acordo com os resultados gerados nos trabalhos comparados por diferentes estudos de trabalho encontrados no estado da arte, métricas (ACC, SEN e ESP).

Na tabela 15 é possível analisar os diferentes resultados para as diferentes imagens

médicas, ao identificar os valores de acurácia, tanto para detecção, quanto para segmentação, os modelos computacionais mantiveram uma acurácia acima de 99% como mostra na Tabela 15 Análise do Método para Imagens Médicas. O melhor caso para inicialização inteligente para detecção ocorre para o AVC Hemorrágico, devido à complexidade do AVC Hemorrágico obter o limiar de *pixels* estáveis (níveis similares) dentro da região pertencente, ao analisarmos as imagens de AVC como apresentado na subseção 15 é possível identificar a região do AVC hemorrágico com variações de *pixels* tendendo a cor branca dentro da escala de cinza, contribuindo para uma identificação da barreira da região do AVC e a região da massa cerebral.

Se tratando da fase de segmentação das imagens médicas, o AVC hemorrágico obteve a ACC acima dos demais modelos, obtendo 99.80% superando também trabalhos encontrados no estado da arte, a mesma perspectiva se deu também com o valor de métrica ESP com 99.81% e SEN com 99.82%, tornando o modelo para detecção e segmentação de AVC hemorrágico com uso do novo método *Divisible Cell-Segmentation* o mais eficaz dentre os problemas abordados. Vale ressaltar que a acurácia é uma importante métrica de avaliação, que busca apontar o índice de acertos com base na quantidade total de estimações, e assim, indicar a margem de acertos do modelo.

Pode-se concluir que o método obteve acurácias satisfatórias para as bases abordadas, e por se tratar de uma métrica que aponta maiores acertos do método, pode-se deduzir que o método proposto, *Divisible Cell-Segmentation* é um método inovador, adaptativo e generalista, sendo capaz de obter resultados satisfatórios comparados do estado da arte para diferentes bases de dados de TCs.

A métrica de ESP aborda o grau de acerto de verdadeiros negativos na imagem, dessa forma, esta métrica avalia a capacidade do modelo de ignorar o que de fato não pertence à região de interesse no modelo. Ao analisar, é possível constatar que as maiores médias e desvio padrões para a métrica de ESP foram para a detecção e segmentação de AVC Hemorrágico, com um valor médio de 99.80%, indicando que, mesmo para um *dataset* constituído de diferentes formatos e escalas de cinza para a região de interesse, o modelo possui robustez ao delimitar o que não deve ser levado em consideração para segmentar a região de interesse na imagem. A comparação relativa leva a deduzir que a ESP média para a segmentação do pulmão em imagens de TC é relativamente menor que as imagens do AVC, isto novamente se deve pelo grau de dificuldade da base em questão, que é constituída não somente por diferentes fatias do exame de TC, com variados formatos para os pulmões de acordo com a fatia, mas também ao fato da

existência de diferentes patologias pulmonares intersticiais presentes nas TCs do exame, que afeta pontos da região do pulmão na imagem. Sobre o AVC, nota-se que o modelo obteve o menor desvio padrão e a segunda maior média, de 99.37%. Isto se deve pela similaridade das amostras, que facilita a demarcação automática baseada no limiar. Dessa forma, constata-se que o modelo proposto, *Divisible Cell-Segmentation* possui altos índices de ESP, e com um baixo desvio padrão para as duas bases, assim o modelo é capaz de delimitar a região de fundo, em detrimento da região de interesse na imagem, de forma robusta e eficaz tanto em tempo de segmentação como otimização, independente da divergência da base.

O que se pode observar para a métrica de especificidade em ambas as bases, é que o desvio padrão é relativamente baixo, principalmente se comparado os resultados para a detecção da região de interesse e segmentação de AVC Hemorrágico com relação aos demais trabalhos já comparados no estado da arte. Isto se deve, devido ao fato da métrica de Sensitividade avaliar a relação de verdadeiros positivos em detrimento do total de acertos na imagem, demonstrando a eficácia do método. Dessa forma, como as bases de TCs de pulmão apresentam alto grau de divergência entre exames, o resultado é refletido no desvio padrão do modelo.

Mesmo com tais fatores de dificuldade para a realização da segmentação, pode-se analisar que o método proposto, *Divisible Cell-Segmentation* obteve Sensitividades médias superiores à 90%, o que indica a qualidade da segmentação do modelo não somente para diferentes tipos de bases, mas também para bases de diferentes imagens médicas, com diferentes texturas e áreas de região de interesse.

Tabela 16 – Comparação do tempo de segmentação entre as diferentes abordagens obtidas pelo método proposto *Divisible Cell-Segmentation*.

Segmentação	Tempo(s)
AVC Hemorrágico	- 1.898 ± 0.032
Pulmão	- 2.031 ± 0.99

Fonte: Elaborada pelo autor.

A tabela 16 apresenta o tempo de segmentação do modelo proposto, *Divisible Cell-Segmentation* para as regiões de interesse das diferentes bases abordadas neste estudo. Ao analisar a Tabela 16, pode-se constatar que para todas as bases, o modelo proposto *Divisible Cell-Segmentation* foi capaz de segmentar as regiões de interesse de todas as bases com baixo tempo de segmentação, com diferenças decimais e segmentação de tempo médio pouco mais que 1 segundo, indicando assim, a robustez do processo de delimitação das bordas por parte do

método proposto. O tempo de segmentação do pulmão em imagens de TC foi relativamente maior se comparado com os demais, com cerca de 0,64 segundos a mais que o resultado mais eficaz, isto é, para a segmentação de AVC Hemorrágico em imagens de TC. E isto se deve as regiões do pulmão, são, no geral, maiores que as regiões de lesão do AVC, o que demanda um fator de tempo maior para que a segmentação ocorra.

Com tudo, pode-se considerar em uma análise geral para os três experimentos, que o método proposto *Divisible Cell-Segmentation* obteve melhor desempenho com total eficácia para segmentação em imagens de AVC hemorrágico. Para imagens de TCs pulmonares o método obteve eficácia, com tudo relativamente menor desempenho entre os três experimentos. Porém, vale ressaltar que o método superou diferentes trabalhos encontrados no estado da arte. Concluindo assim, que o novo método *Divisible Cell-Segmentation* é eficaz para diferente tipos de segmentações em imagens médicas.

4.5 Considerações Finais

Este capítulo apresentou os resultados da análise comparativa do método proposto *Divisible Cell-Segmentation*, um novo método baseado na analogia ao processo biológico de citocinese, onde a célula se divide originando outras células. O método *Divisible Cell-Segmentation* baseia-se em células computacionais sintéticas capazes de se dividirem em um plano bidimensional em uma imagem digital, cujo a finalidade do método é a segmentação das bordas de objeto de interesse, tratadas aqui como objeto de estudo imagens médicas de TCs (TCs de AVC hemorrágico, e imagens de TC pulmonares). Em sua primeira etapa foi utilizado como a inicialização automática inteligente para detecção da região a ser segmentado que obteve acima de 99% de ACC para detecção nos diferentes tipos de imagens médicas e suas respectivas regiões de interesse.

As métricas utilizadas para avaliação dos diferentes modelos foram escolhidas com base em comparação a trabalhos encontrados na literatura, a fim de validar e comparar os diferentes métodos, bem como os diferentes modelos computacionais. As métricas utilizadas foram; ACC, ESP, SEN, PPV, NPV, DICE e FPR, ambas utilizadas em diferentes trabalhos encontrados no estado da arte, aplicadas as mesmas bases de dados. A subseção 3.3 Métricas de Avaliação, apresentam estas diferentes métricas utilizadas para comparação de resultados desta tese.

Após este processo de resultados obtidos por este estudo com uso da inicialização

automática inteligente para detecção, e o novo método *Divisible Cell-Segmentation* para segmentação, separadas por subseções: Subseção AVC hemorrágico e Imagens Pulmonares, os resultados foram comparados com o estado da arte em suas respectivas subseções de resultados trazendo uma conclusão específica para cada problema em imagens médicas. Tais comparações com estudos da literatura apontaram obtenções de resultados superiores a trabalhos do estado da arte, e também semelhanças não só de valores em métricas, mas também de uso de técnicas para detecção das regiões de interesse.

O novo método *Divisible Cell-Segmentation* demonstrou ser um método eficaz para segmentação de AVC Hemorrágico em diferentes tipos de imagens TCs, tornando o método mais robusto no tempo de segmentação para detecção de diferentes TCs, e eficiente para diferentes problemas de pulmão e AVC hemorrágico. Isso pode ser comprovado na subseção 4.4 Análise Geral dos Dados, onde trouxe uma comparação com os diferentes resultados entre as imagens médicas, tanto para detecção, quanto para segmentação, atingindo acima de 99% para as duas abordagens (detecção e segmentação) nos diferentes tipos de imagens de TCs.

Desta forma, pode-se afirmar que o novo método *Divisible Cell-Segmentation* é um algoritmo eficiente para segmentação, bem como para diferentes problemas (AVC hemorrágico e imagens pulmonares). Podendo assim ser parte de um sistema CAD, diminuindo o tempo de análise médica em *slides* em exames de TCs, exames estes bastantes utilizados na teoria de avaliação clínica. O método mostrou-se bastante eficaz, podendo ser utilizado como uma ferramenta de apoio à tomada de decisão, o que aumentaria a precisão, fundamentando o processo decisório, bem como a capacidade de diagnóstico médico por imagens usados por médicos especialistas.

5 CONCLUSÕES E TRABALHOS FUTUROS

Este último capítulo apresenta as conclusões, considerações finais, um resumo das contribuições científicas, bem como uma seção de trabalhos futuros relacionados com os assuntos abordados nesta tese.

5.1 Conclusões

Esta tese apresentou uma abordagem baseada em inicialização automática inteligente adaptativa, capaz de detectar regiões de AVC hemorrágico e Pulmão em imagens de TC com o objetivo de gerar parâmetros adaptativos para o novo método de segmentação *Divisible Cell-Segmentation*, capaz de segmentar com eficácia imagens médicas por meio de células computacionais sintéticas, visando o auxílio ao diagnóstico médico. O novo método proposto utilizou células nas quais se dividem (multiplicando-se) com o objetivo de encontrar a borda do objeto, segmentando-a por meio da conexão celular.

Esta tese não apenas considerou os resultados do método proposto *Divisible Cell-Segmentation*, mas também de métodos similares na avaliação e análise dos dados e da segmentação das regiões de interesse em cada experimento realizado, visto que um dos objetivos da tese é apresentar os métodos recentes aplicados em cada uma das bases considerando métodos convencionais e recentes na literatura, de origens e funcionamentos diversos, visando realizar a mesma tarefa, bem como comparar com métodos de baseados em *deep learning* recentes nas mesmas aplicações, assim como trabalhos já consolidados na literatura. De acordo com os resultados apresentados em cada um dos experimentos detalhados na Seção de Resultados, pode-se concluir que este objetivo foi realizado de forma satisfatória, visto que as tabelas de resultados, análises e discussões foram realizadas e embasadas em cima destas revisão bibliográfica realizada considerando estas premissas.

Quanto à proposta de inicialização automática inteligente baseada em abordagem adaptativa, pode-se concluir que o método proposto obteve resultados satisfatórios em todas as imagens analisadas quanto a detecção, obtendo eficácia em seu objetivo. Vale ressaltar, que em todas as aplicações avaliadas visando o auxílio ao diagnóstico médico foram considerados não apenas imagens saudáveis, mas também imagens com regiões que apresentam doenças e anomalias que dificultam determinar onde se encontram as regiões de interesse de forma eficaz, o que foi superado com a evolução da abordagem celular em detectar a região de interesse com

eficácia em diferentes pontos da borda, possibilitando assim, a conexão celular e precisão na segmentação.

Quanto a proposta de um novo método adaptativo para segmentação otimizada baseado em *fine-tuning*, pode-se concluir que o novo método atendeu a proposta baseada nos resultados satisfatórios produzido pelo método *Divisible Cell-Segmentation.*, através das células computacionais sintéticas divisíveis, onde obtiveram acurácia acima de 99%. Então pode-se concluir que o método proposto cumpriu este objetivo com sucesso, apresentando-se como um método promissor na segmentação das regiões de interesse em imagens médicas, evidenciando a sua abordagem otimizada para uso e auxílio ao diagnóstico médico, baseado nos experimentos realizados por meio de células computacionais sintéticas.

Considerando o método proposto na segmentação de regiões de AVC em imagens de TC cerebral, o método proposto obteve índices de diferentes métricas acima de 99% superado diferentes métodos conceituados na literatura, obtendo assim desempenho satisfatórios todas as métricas de desempenho, incluindo métodos com uso de *deep learning*, demonstrando também a robustez do método proposto em segmentar o AVC em diferentes imagens médicas, com tempo de segmentação em 1.89 segundos, superando diferentes métodos clássicos e obtendo melhor tempo de segmentação entre os métodos *deep learning*. As métricas de ACC e NPV obtiverem melhores resultados, demonstrando equivalência na métrica de ESP com 99.81%, levando em consideração também que vários métodos não realizaram validação cruzada, o que demonstra ainda mais robustez do método em uma validação precisa dos resultados.

Quanto aos resultados obtido em segmentação dos pulmões em imagens médicas de TC do pulmão, pode-se concluir que o método proposto *Divisible Cell-Segmentation* obteve eficácia na inicialização automática com obtenção de 99.00% de ACC para detecção da região do pulmão, com tempo de 2.03 segundos, superando todos os trabalhos com uso de *deep learning*. Ultrapassando todos os métodos consolidados neste trabalho comparado, mostrando a equivalência por meio das métricas de DICE e JAC, mostrando-se equiparado junto a modelos de alto desempenho e otimização.

Assim, considerando a análise geral dos resultados obtidos pelo novo método *Divisible Cell-Segmentation* proposto, pode-se concluir que o método pode ser indicado para uso de segmentação de regiões de interesse, sendo promissor na análise de imagens de TC de diferentes pacientes saudáveis, bem como em imagens de TC com patologias. Desta forma, o novo método pode ser integrado em sistemas de auxílio ao diagnóstico médico, seja na etapa do diagnóstico

ou acompanhamento do paciente no tratamento de doenças, bem como no acompanhamento do quadro clínico médico em análise de AVC em imagens de TC cerebral e imagens de pulmões em TC, com alto índice de precisão.

5.2 Trabalhos Futuros

Todo o desenvolvimento do trabalho de tese, bem como os resultados obtidos, não esgota a pesquisa sobre segmentação em imagens de TC para os respectivos problemas de imagens médicas (AVC hemorrágico e Imagens pulmonares. Neste sentido, pode-se propor os seguintes trabalhos futuros:

- aplicar o novo método de segmentação para diferentes imagens médicas, tais como; melanoma, coração e nódulos mamários;
- desenvolver novas configurações para que o método possa auxiliar na segmentação de imagens de Raio-X do pulmão, para confrontar os resultados obtidos nas imagens de TCs pulmonares;
- analisar se o desempenho do método pode ser melhor otimizado com novas configurações dos parâmetros utilizados neste estudo;
- Adaptar e analisar o método para uso de classificadores, substituindo e a conexão entre as células, com o objetivo de encontrar o melhor classificador para a melhor conexão entre os pontos celulares.
- adaptar e investigar a aplicabilidade do método desenvolvido para outras estruturas do corpo humano por meio de exames de imagens médicas;
- investigar a aplicabilidade do método desenvolvidos para segmentação de diferentes tipos de imagens digitais, tais como eixo temático; biomédica, indústria e robótica, buscando investigar a capacidade da generalização do método proposto.

Espera-se que com estas melhorias, os resultados futuros sejam ainda mais precisos e rápidos, comparados com os obtidos neste trabalho.

REFERÊNCIAS

- AGGARWAL, N.; KARL, W. C. Line detection in images through regularized hough transform. **IEEE transactions on image processing**, IEEE, New York, USA, v. 15, n. 3, p. 582–591, february. 2006.
- ALBERTS, B.; BRAY, D.; HOPKIN, K.; JOHNSON, A. D.; LEWIS, J.; RAFF, M.; ROBERTS, K.; WALTER, P. **Essential cell biology**. New York: Garland Science, 2015.
- ALEXANDRIA, A.; CORTEZ, P. C.; FELIX, J.; CAVALCANTE, T.; FILHO, P. R.; JÚNIOR, J. S.; ABREU, J. Hilbertian energy: a method for external energy calculation on radial active contours. In: SYSTEMS, SIGNALS AND IMAGE PROCESSING - IWSSIP, 17., 2010, Rio de Janeiro, Brazil: **IEEE**, 2010. p. 37–45.
- AMBRÓSIO, P. E. **Redes neurais auto-organizáveis na caracterização de lesões intersticiais de pulmão em radiografia do tórax**. Tese (Doutorado) — Faculdade de Medicina de Ribeirão Preto, Universidade de São Paulo, Ribeirão Preto, SP, Brasil, 2010.
- BADRINARAYANAN, V.; KENDALL, A.; CIPOLLA, R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation. **IEEE Transactions on pattern analysis and machine intelligence**, IEEE, New York, USA, v. 39, n. 12, p. 2481–2495, january. 2017.
- BENGIO, Y.; COURVILLE, A.; VINCENT, P. Representation learning: A review and new perspectives. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, New York, USA, v. 35, n. 8, p. 1798–1828, august. 2013.
- BHADAURIA, H.; DEWAL, M. Intracranial hemorrhage detection using spatial fuzzy c-mean and region-based active contour on brain ct imaging. **Signal, Image and Video Processing**, Springer, Berlin/Heidelberg. Germany, v. 8, n. 2, p. 357–364, march. 2014.
- BHADAURIA, H.; SINGH, A.; DEWAL, M. An integrated method for hemorrhage segmentation from brain ct imaging. **Computers & Electrical Engineering**, Amsterdam, Netherlands, v. 39, n. 5, p. 1527–1536, july. 2013.
- BISHOP, C. M.; NASRABADI, N. M. **Pattern recognition and machine learning**. Nova York, USA: Springer, 2006. v. 1. 15–738 p.
- BRAGA, A. M.; MARQUES, R. C.; MEDEIROS, F. N.; NETO, J. F. R.; BIANCHI, A. G.; CARNEIRO, C. M.; USHIZIMA, D. M. Hierarchical median narrow band for level set segmentation of cervical cell nuclei. **Measurement**, Elsevier, Braunschweig, Germany, v. 176, p. 109–232, may. 2021.
- BRAGA, A. M.; MARQUES, R. C.; RODRIGUES, F. A.; MEDEIROS, F. N. A median regularized level set for hierarchical segmentation of sar images. **IEEE Geoscience and Remote Sensing Letters**, IEEE, New York, USA, v. 14, n. 7, p. 1171–1175, may. 2017.
- CAPLAN, L. R.; MOHR, J. P.; ACKERMAN, R. H. In memoriam: Charles miller fisher, md (1913-2012). **Archives of Neurology**, American Medical Association, Boston, USA, v. 69, n. 9, p. 1208–1209, september. 2012.

CHAN, H.-P.; HADJIISKI, L. M.; SAMALA, R. K. Computer-aided diagnosis in the era of deep learning. **Medical physics**, Wiley Online Library, v. 47, n. 5, p. 218–227, may. 2020.

CHATE, R. C.; FONSECA, E. K. U. N.; PASSOS, R. B. D.; TELES, G. B. S.; SHOJI, H.; SZARF, G. Apresentação tomográfica da infecção pulmonar na covid-19: experiência brasileira inicial. **Jornal Brasileiro de Pneumologia**, SciELO Brasil, Brasília, Brasil, v. 46, fevereiro. 2020.

DIPU, N. M.; SHOHAN, S. A.; SALAM, K. Deep learning based brain tumor detection and classification. In: INTERNATIONAL CONFERENCE ON INTELLIGENT TECHNOLOGIES - CONIT. 2021, Hubli, India: **IEEE**, 2021. p. 1–6.

DUDA, R. O.; HART, P. E. **Pattern classification**. 2. ed. New York, USA: John Wiley & Sons, 2006.

EL-KOUSSY, M.; SCHROTH, G.; BREKENFELD, C.; ARNOLD, M. Imaging of acute ischemic stroke. **European Neurology**, Karger Publishers, Basel, Switzerland, v. 72, n. 5-6, p. 309–316, october. 2014.

FELIX, J.; CORTEZ, P.; COSTA, R.; FORTALEZA, S.; PEREIRA, E.; HOLANDA, M. Computer-assisted evaluation of pulmonary emphysema in ct scans: comparison between a locally developed system and a freeware system. **Jornal Brasileiro De Pneumologia - J BRAS PNEUMOL**, São Paulo. Brasil, v. 35, p. 15–28, september. 2009.

FELIX, J. H. S. **Sistema de Visão Computacional para Detecção e Quantificação de Enfisema Pulmonar**. Tese (Doutorado) — Dissertação de Mestrado, Universidade Federal do Ceará, Fortaleza, CE, Fortaleza, CE, Brasil, 2007.

FILHO, P. P.; BARROS, C.; RAMALHO, G.; CLAYTON, P.; PAPA, J.; ALBUQUERQUE, V.; TAVARES, J. Automated recognition of lung diseases in ct images based on the optimum-path forest classifier. **Neural Computing and Applications**, Berlin/Heidelberg, Germany, v. 31, p. 901–914, june. 2019.

FILHO, P. P. R.; BARROS, A. C. da S.; ALMEIDA, J. S.; RODRIGUES, J.; ALBUQUERQUE, V. H. C. de. A new effective and powerful medical image segmentation algorithm based on optimum path snakes. **Applied Soft Computing**, Elsevier, v. 76, p. 649–670, 2019.

FILHO, P. P. R.; CORTEZ, P. C.; BARROS, A. C. S.; ALBUQUERQUE, V. H. C. 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**, Elsevier, Amsterdam, Netherlands, v. 41, n. 17, p. 7707–7721, december. 2014.

FILHO, P. P. R.; CORTEZ, P. C.; BARROS, A. C. S.; ALBUQUERQUE, V. H. C.; TAVARES, J. M. R. Novel and powerful 3d adaptive crisp active contour method applied in the segmentation of ct lung images. **Medical image analysis**, Elsevier, Amsterdam, Netherlands, v. 35, p. 503–516, january. 2017.

FILHO, P. P. R.; CORTEZ, P. C.; HOLANDA, M. A. Active contour modes crisp: new technique for segmentation of the lungs in ct images. **Revista Brasileira de Engenharia Biomédica**, São Paulo. Brasil, v. 27, n. 4, p. 259–272, may. 2011.

GOLDSZMIDT, A. J.; CAPLAN, L. R. **Stroke Essentials 2010**. Boston, Massachusetts: Jones & Bartlett Publishers, 2009.

GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. L. **Digital Image Processing using MATLAB**. Upper Saddle River, NJ: Pearson Prentice Hall, 2009.

GRAVES, A.; MOHAMED, A.; HINTON, G. Speech recognition with deep recurrent neural networks. In: INTERNATIONAL CONFERENCE ON ACOUSTICS, SPEECH AND SIGNALS PROCESSING, 38., 2013, Vancouver, BC, Canada: **IEEE**, 2013. p. 6645–6649.

GROTTA, J. C.; ALBERS, G. W.; BRODERICK, J. P.; KASNER, S. E.; LO, E. H.; SACCO, R. L.; WONG, L. K.; DAY, A. L. **Stroke e-book: Pathophysiology, diagnosis, and management**. New York, USA: Elsevier Health Sciences, 2021.

GUO, C.; ZHANG, Z.; LAU, A. K.; LIN, C. Q.; CHUANG, Y. C.; CHAN, J.; JIANG, W. K.; TAM, T.; YEOH, E.-K.; CHAN, T. C. Effect of long-term exposure to fine particulate matter on lung function decline and risk of chronic obstructive pulmonary disease in taiwan: a longitudinal, cohort study. **The Lancet Planetary Health**, Elsevier, Amsterdam, Netherlands, v. 2, n. 3, p. 114–125, march. 2018.

HAAN, B. D.; CLAS, P.; JUENGER, H.; WILKE, M.; KARNATH, H. O. Fast semi-automated lesion demarcation in stroke. **NeuroImage: Clinical**, Elsevier, Amsterdam, Netherlands, v. 9, p. 69–74, september. 2015.

HAAS, L. Julius wagner-jauregg (1857–1940). **Journal of Neurology, Neurosurgery & Psychiatry**, BMJ Publishing Group Ltd, v. 72, n. 1, p. 105–105, 2002.

HAN, T.; NUNES, V. X.; SOUZA, L. F. D. F.; MARQUES, A. G.; SILVA, I. C. L.; JUNIOR, M. A. A. F.; SUN, J.; FILHO, P. P. R. Internet of medical things—based on deep learning techniques for segmentation of lung and stroke regions in ct scans. **IEEE Access**, IEEE, New York. USA, v. 8, p. 71117–71135, april. 2020.

HAYKIN, S. **Neural networks: a comprehensive foundation**. Porto Alegre, RS: Prentice Hall PTR, 1998.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2. ed. Porto Alegre, RS: Bookman, 2001.

HEART AND STROKE FOUNDATION OF CANADA. **What is stroke?** 2023. Disponível em: <<https://www.heartandstroke.ca/stroke/what-is-stroke>>. Acessado em: 10 de janeiro de 2023.

HOLMES, E. J.; FORREST-HAY, A. C.; MISRA, R. R. **Interpretation of emergency head CT: a practical handbook**. 3. ed. Cambridge, UK: Cambridge University Press, 2017.

HOUNSFIELD, G. N. Computed medical imaging. **Science**, American Association for the Advancement of Science, v. 210, n. 4465, p. 22–28, 1980.

HOWARD, J.; GUGGER, S. Fastai: A layered api for deep learning. **Information**, Basel, Switzerland, v. 11, n. 2, p. 108, february. 2020.

HU, Q.; SOUZA, L. F. F.; HOLANDA, G. B.; ALVES, S. S.; SILVA, F. H. S.; HAN, T.; FILHO, P. P. R. An effective approach for ct lung segmentation using mask region-based convolutional neural networks. **Artificial intelligence in medicine**, Elsevier, Amsterdam, Netherland, v. 103, p. 101–792, March. 2020.

ILLINGWORTH, J.; KITTLER, J. The adaptive hough transform. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, IEEE, New York, USA, n. 5, p. 690–698, september. 1987.

- ILLINGWORTH, J.; KITTLER, J. A survey of the hough transform. **Computer vision, graphics, and image processing**, Elsevier, Amsterdam, Netherlands, v. 44, n. 1, p. 87–116, october. 1988.
- JAIN, A. K.; MURTY, M. N.; FLYNN, P. J. Data clustering: a review. **ACM computing surveys (CSUR)**, Acm New York, NY, USA, New York, USA, v. 31, n. 3, p. 264–323, september. 1999.
- JESAN, J. P. The neural approach to pattern recognition. **Ubiquity**, Association for Computing Machinery, New York, NY, p. 2, apr 2004.
- JIJJA, A.; RAI, D. Efficient mri segmentation and detection of brain tumor using convolutional neural network. **International Journal of Advanced Computer Science and Applications**, Science and Information (SAI) Organization Limited, v. 10, n. 4, 2019.
- KOHL, M. Performance measures in binary classification. **International Journal of Statistics in Medical Research**, NY, USA, v. 1, n. 1, p. 79–81, february. 2012.
- KORBES ANDRÉ, R. **Analysis of Algorithms of the Watershed Transform**. 2010. Tese (Doutorado) — Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, São Paulo, Brasil, 2010.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, Publishing Group UK London, UK, London, v. 521, n. 7553, p. 436–444, may. 2015.
- LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, november. 1998.
- LI, B.; ACTON, S. T. Vector field convolution for image segmentation using snakes. In: IEEE INTERNATIONAL CONFERENCE ON IMAGE PROCESSING, 10., Atlanta, Geórgia, EUA: **IEEE**, 2006. p. 1637–1640.
- LIN, T.-Y.; MAIRE, M.; BELONGIE, S.; HAYS, J.; PERONA, P.; RAMANAN, D.; DOLLÁR, P.; ZITNICK, C. L. Microsoft coco: Common objects in context. In: COMPUTER VISION–ECCV 2014, 13 ., Zurich, Switzerland: **Springer**, 2014. p. 740–755.
- LUO, P.; LI, J. Dual-source computed tomography image information under deep learning algorithm in evaluation of coronary artery lesion in children with kawasaki disease. **The Journal of Supercomputing**, Springer, Heidelberg, Germany, p. 1–18, october. 2022.
- MARQUES, A. G.; SOUZA, L. F. F.; SANTOS, M. A.; NASCIMENTO, J. J. C.; SARMENTO, R. M.; LUCENA, I. B.; SILVA, I. C. L.; FILHO, P. P. R. Automatic segmentation of hemorrhagic stroke on brain ct images using convolutional neural networks through fine-tuning. In: 2022 INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN), 34., Padua, Italy: **IEEE**, 2022. p. 01–08.
- MEDEIROS, A. G.; GUIMARÃES, M. T.; PEIXOTO, S. A.; SANTOS, L. de O.; BARROS, A. C. S.; REBOUÇAS, E. S.; ALBUQUERQUE, V. H. C.; FILHO, P. P. R. A new fast morphological geodesic active contour method for lung CT image segmentation. **Measurement**, Elsevier BV, v. 148, p. 106–687, dec 2019.
- MEDEIROS, A. G.; SANTOS, L. O.; SARMENTO, R. M.; REBOUÇAS, E. S.; FILHO, P. P. R. New adaptive morphological geodesic active contour method for segmentation of hemorrhagic stroke in computed tomography image. In: BRAZILIAN CONFERENCE ON INTELLIGENT SYSTEMS, 9., Cham: **Springer**, 2020. p. 604–618.

MEDEIROS, A. G.; SILVA, F. H.; OHATA, E. F.; PEIXOTO, S. A.; FILHO, P. P. R. An automatic left ventricle segmentation on echocardiogram exams via morphological geodesic active contour with adaptive external energy. **Journal of Artificial Intelligence and Systems**, Wollongong, Australia, v. 1, p. 77–95, october. 2019.

MEIRELLES, G. S. P. Covid-19: uma breve atualização para radiologistas. **Radiologia Brasileira**, Brasília, Brasil, v. 53, p. 320–328, Sep-Oct. 2020.

MILLETARI, F.; NAVAB, N.; AHMADI, S.-A. V-net: Fully convolutional neural networks for volumetric medical image segmentation. In: 2016 FOURTH INTERNATIONAL CONFERENCE ON 3D VISION (3DV), 4., Stanford, California, EUA: **IEEE**, 2016. p. 565–571.

MITCHELL, T. M. **Machine learning**. New York, USA: McGraw-hill, 2007. v. 1.

MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. **Foundations of machine learning**. Cambridge, Massachusetts, London, England: MIT press, 2018.

NIXON, M.; AGUADO, A. **Feature Extraction and Image Processing for Computer Vision**. 2. ed. Cambridge, MA: Academic Press, 2008.

PAO, D. C. W.; LI, H. F.; JAYAKUMAR, R. Shapes recognition using the straight line hough transform: Theory and generalization. **IEEE Transactions on Pattern Analysis & Machine Intelligence**, IEEE Computer Society, New York, USA, v. 14, n. 11, p. 1076–1089, november 1992.

PATINO, D.; ORTEGA, J. A.; BRANCH, J. W. Automatic skin lesion segmentation on dermoscopic images by the means of superpixel merging. In: 21ST INTERNATIONAL CONFERENCE, GRANADA, SPAIN, 21., 2018, Granada, Spain: **Springer**, 2018. p. 728–736.

PEHRSON, L. M.; NIELSEN, M. B.; LAURIDSEN, C. A. Automatic pulmonary nodule detection applying deep learning or machine learning algorithms to the lidc-idri database: a systematic review. **Diagnostics**, Multidisciplinary Digital Publishing Institute, Basel, Switzerland, v. 9, n. 1, p. 29–41, march. 2019.

PENNISI, A.; BLOISI, D. D.; NARDI, D.; GIAMPETRUZZI, A. R.; MONDINO, C.; FACCHIANO, A. Skin lesion image segmentation using delaunay triangulation for melanoma detection. **Computerized Medical Imaging and Graphics**, United Kingdom, v. 52, p. 89 – 103, september. 2016. ISSN 0895-6111.

PEREIRA, S.; PINTO, A.; ALVES, V.; SILVA, C. A. Brain tumor segmentation using convolutional neural networks in mri images. **IEEE transactions on medical imaging**, IEEE, New York, USA, v. 35, n. 5, p. 1240–1251, march. 2016.

PHAM, D. L.; XU, C.; PRINCE, J. L. Current methods in medical image segmentation. **Annual review of biomedical engineering**, Califórnia, USA, v. 2, n. 1, p. 315–337, august. 2000.

PRÆSTGAARD, J. T. Permutation and bootstrap kolmogorov-smirnov tests for the equality of two distributions. **Scandinavian Journal of Statistics**, JSTOR, New York, USA, p. 305–322, september. 1995.

REBOUÇAS, E. S.; BRAGA, A. M.; SARMENTO, R. M.; MARQUES, R. C. P.; FILHO, P. P. R. Level set based on brain radiological densities for stroke segmentation in ct images. In: 30th IEEE International Symposium on Computer-Based Medical Systems (CBMS), 30., Thessaloniki, Greece: **IEEE**, 2017. p. 391–396.

REBOUCAS, E. S.; MARQUES, R. C.; BRAGA, A. M.; OLIVEIRA, S. A.; ALBUQUERQUE, V. H. C. de; FILHO, P. P. R. New level set approach based on parzen estimation for stroke segmentation in skull ct images. **Soft Computing**, Springer, Heidelberg, Germany, v. 23, n. 19, p. 9265–9286, august. 2018.

REBOUÇAS, E. S.; MEDEIROS, F. N. S.; MARQUES, R. C. P.; CHAGAS, J. V. S.; GUIMARAES, 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**, Elsevier, Amsterdam, Netherlands, v. 105, p. 107–273, July. 2021.

REBOUCAS, E. S.; SARMENTO, R. M.; FILHO, P. P. R. 3d adaptive balloon active contour: method of segmentation of structures in three dimensions. **IEEE Latin America Transactions**, IEEE, New York, USA, v. 13, n. 1, p. 195–203, january. 2015.

REBOUÇAS FILHO, P. P. **Métodos de contornos ativos Crisp adaptativo 2D e 3D aplicados na segmentação dos pulmões em imagens de tomografia computadorizada do tórax**. Tese (Doutorado) — Universidade Federal do Ceará (UFC), Fortaleza, CE, Maio 2013.

REBOUÇAS FILHO, P. P.; REBOUÇAS, E. S.; MARINHO, L. B.; SARMENTO, R. M.; TAVARES, J. M. R.; ALBUQUERQUE, V. H. C. Analysis of human tissue densities: A new approach to extract features from medical images. **Pattern Recognition Letters**, Elsevier, Amsterdam, Netherlands, v. 94, p. 211–218, July. 2017.

REBOUÇAS FILHO, P. P.; SARMENTO, R. M.; HOLANDA, G. B.; LIMA, D. A. New approach to detect and classify stroke in skull ct images via analysis of brain tissue densities. **Computer methods and programs in biomedicine**, Elsevier, v. 148, p. 27–43, 2017.

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: MEDICAL IMAGE COMPUTING AND COMPUTER-ASSISTED INTERVENTION-MICCAI - INTERNATIONAL CONFERENCE, 18., 2015, Munich, Germany: **Springer**, 2015. p. 234–241.

ROUHI, R.; JAFARI, M.; KASAEI, S.; KESHAVARZIAN, P. Benign and malignant breast tumors classification based on region growing and cnn segmentation. **Expert Systems with Applications**, Elsevier, Amsterdam, Netherlands, v. 42, n. 3, p. 990–1002, february. 2015.

RUSSELL, S. J. **Artificial intelligence a modern approach**. New York: Pearson Education, Inc., 2010.

SANTAMARIA, A. F.; RAIMONDO, P.; TROPEA, M.; RANGO, F. D.; AIELLO, C. An iot surveillance system based on a decentralised architecture. **Sensors**, Multidisciplinary Digital Publishing Institute, Basel, Switzerland, v. 19, n. 6, p. 1469–1479, march. 2019.

SARMENTO, R. M.; PEREIRA, R. F.; COIMBRA, P. P. A.; MACÊDO, A. C. N.; FILHO, P. P. R. Segmentação de acidente vascular cerebral em imagens de tomografia computadorizada: Um estudo comparativo. In: SIMPÓSIO DE INSTRUMENTAÇÃO E IMAGENS MÉDICAS (SIIM), 7., 2015, Campinas, SP, Brasil: **FEEC - UNICAMP**, 2015. p. 113–114.

SARMENTO, R. M.; VASCONCELOS, F. F.; FILHO, P. P. R.; ALBUQUERQUE, V. H. C. An iot platform for the analysis of brain ct images based on parzen analysis. **Future Generation Computer Systems**, Elsevier, Amsterdam, Netherlands, v. 105, p. 135–147, april. 2020.

SARMENTO, R. M.; VASCONCELOS, F. F. X.; FILHO, P. P. R.; WU, W.; ALBUQUERQUE, V. H. C. D. Automatic neuroimage processing and analysis in stroke—a systematic review. **IEEE reviews in biomedical engineering**, IEEE, NY. USA, v. 13, p. 130–155, august. 2019.

SCLIAR, M. História do conceito de saúde. **Physis: Revista de saúde coletiva**, SciELO Brasil, may. São Paulo, Brasil, v. 17, p. 29–41, 2007.

SHIBATA, K.; HASHIMOTO, T.; MIYAZAKI, T.; MIYAZAKI, A.; NOBE, K. Thrombolytic therapy for acute ischemic stroke: past and future. **Current pharmaceutical design**, Bentham Science Publishers, Pisa, Italy, v. 25, n. 3, p. 242–250, january. 2019.

SHIN, M.; PAIK, W.; KIM, B.; HWANG, S. An iot platform with monitoring robot applying cnn-based context-aware learning. **Sensors**, Multidisciplinary Digital Publishing Institute, Manchester, Reino Unido, v. 19, n. 11, p. 2525–2537, june. 2019.

SIQUEIRA, M. L. **Reconhecimento Automático de Padrões em Imagens Ecocardiograficas**. 2010. Tese (Doutorado) — Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, RS, Brasil, 2010.

SKOURT, B. A.; HASSANI, A. E.; MAJDA, A. Lung ct image segmentation using deep neural networks. **Procedia Computer Science**, Elsevier, Amsterdam, Netherlands, v. 127, p. 109–113, june. 2018.

SOUZA, L. F. F.; HOLANDA, G. B.; ALVES, S. S.; SILVA FRANCISCO HÉRCULES DOS S REBOUÇAS FILHO, P. P. Automatic lung segmentation in ct images using mask r-cnn for mapping the feature extraction in supervised methods of machine learning. In: INTERNATIONAL CONFERENCE ON INTELLIGENT SYSTEMS DESIGN AND APPLICATIONS, 8, 2019. Veneza, Itália: **Springer**, 2019. p. 140–149.

SOUZA, L. F. F.; SILVA, I. C. L.; MARQUES, A. G.; SILVA, F. H. S.; NUNES, V. X.; HASSAN, M. M.; ALBUQUERQUE, V. H. C.; FILHO, P. P. R. Internet of medical things: an effective and fully automatic iot approach using deep learning and fine-tuning to lung ct segmentation. **Sensors**, MDPI, Basel, Switzerland, v. 20, n. 23, p. 6711, november. 2020.

THABET, A.; KOTTAPALLY, M.; III, J. C. H. Management of intracerebral hemorrhage. **Handbook of clinical neurology**, Elsevier, Amsterdam, Netherlands, v. 140, p. 177–194, 2017.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern recognition**. San Diego, CA: Academic press, 2003.

TOU, J. T.; GONZALEZ, R. C. **Pattern Recognition Principles**. 1. ed. Massachusetts, EUA: Addison-Wesley, 1974.

TRIPATHI, S.; VERMA, A.; SHARMA, N. Automatic segmentation of brain tumour in mr images using an enhanced deep learning approach. **Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization**, Taylor & Francis, Oxfordshire, United Kingdom, v. 9, n. 2, p. 121–130, September. 2021.

ULLAH, M.; BARI, M.; AHMED, A.; NAVEED, S. Lungs cancer detection using digital image processing techniques: A review. **Mehran University Research Journal of Engineering and Technology**, v. 38, n. 2, 2019.

VASCONCELOS, F. F.; SARMENTO, R. M.; FILHO, P. P. R.; ALBUQUERQUE, V. H. C. de. Artificial intelligence techniques empowered edge-cloud architecture for brain ct image analysis. **Engineering Applications of Artificial Intelligence**, Elsevier, Amsterdam, Netherlands, v. 91, p. 103–585, may. 2020.

WALLACE, B. A. **The Attention Revolution: Unlocking the Power of the Focused Mind**. Boston: Simon and Schuster, 2006.

WANG, X.-Y.; BU, J. A fast and robust image segmentation using fcm with spatial information. **Digital Signal Processing**, Elsevier, Amsterdam, Netherlands, v. 20, n. 4, p. 1173–1182, july. 2010.

WU, Y.; KIRILLOV, A.; MASSA, F.; LO, W.-Y.; GIRSHICK, R. **Detectron2**. 2023. Disponível em: <<https://github.com/facebookresearch/detectron2>>. Acessado em: 02 de fevereiro de 2023.

XU, C.; PRINCE, J. L. Snakes, shapes, and gradient vector flow. **IEEE Transactions on Image Processing**, IEEE, New York, USA, v. 7, n. 3, p. 359–369, march. 1998.

XU, Y.; HOLANDA, G.; SOUZA, L. F. F.; SILVA, H.; GOMES, A.; SILVA, I.; FERREIRA, M.; JIA, C.; HAN, T.; ALBUQUERQUE, V. H. C. Deep learning-enhanced internet of medical things to analyze brain ct scans of hemorrhagic stroke patients: a new approach. **IEEE Sensors Journal**, IEEE, New York, USA, v. 21, n. 22, p. 24941–24951, October. 2020.

XU, Y.; SOUZA, L. F.; SILVA, I. C.; MARQUES, A. G.; SILVA, F. H.; NUNES, V. X.; HAN, T.; JIA, C.; ALBUQUERQUE, V. H. C.; FILHO, P. P. R. A soft computing automatic based in deep learning with use of fine-tuning for pulmonary segmentation in computed tomography images. **Applied Soft Computing**, Elsevier, Amsterdam, Netherlands, v. 112, p. 107–810, november. 2021.