

UNIVERSIDADE FEDERAL DE SÃO CARLOS– UFSCAR  
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA– CCET  
DEPARTAMENTO DE COMPUTAÇÃO– DC  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO– PPGCC

**João Pedro Parella**

**Segmentação de vasos sanguíneos  
utilizando redes neurais convolucionais:  
Investigação da prevalência de  
descontinuidades e desenvolvimento de  
técnicas para mitigá-las**



**João Pedro Parella**

**Segmentação de vasos sanguíneos  
utilizando redes neurais convolucionais:  
Investigação da prevalência de  
descontinuidades e desenvolvimento de  
técnicas para mitigá-las**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação do Centro de Ciências Exatas e de Tecnologia da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação.

Área de concentração: Processamento de Imagens e Sinais

Orientador: Prof. Dr. Cesar Henrique Comin

São Carlos

2024



Dedico esse trabalho à minha família, por todo o incentivo e ajuda durante todo esse tempo.



---

# Agradecimentos

---

Agradeço primeiro a Deus, que me proporcionou a capacidade para chegar até aqui, segundo a todos meus familiares, meus pais e avós por todo o apoio desde minha infância, a minha esposa por todos os momentos e incentivos ao decorrer. Também quero dedicar ao meu orientador, que me incentivou e me ajudou tanto. E por fim, mas não menos importante, ao meu tio e Mestre Paulo Sergio Rosalin Moreno, que mesmo não tendo laços sanguíneos, me teve como sobrinho, me incentivou, me ajudou e também é graças a ele que posso chegar nesse momento, descanse em paz!



*“Idéias e somente idéias podem iluminar a escuridão.” (Ludwig von Mises)*



---

# Resumo

---

Com os avanços atuais de tecnologias e técnicas de medicina, a incessante busca por melhorar os métodos de diagnósticos e análises científicas traz a tona um grande desafio, a eficiência e eficácia nos processamentos de dados de exames e testes. Na área de processamento de imagens desses exames, há uma fase muito importante que pode influenciar todos os seguintes passos e até mesmo o diagnóstico final, que é a fase de segmentação. Em particular, a segmentação é importante em exames envolvendo imagens de vasos sanguíneos, pois estes possuem uma grande dificuldade de análise por serem estruturas complexas e finas. Buscar melhorias de técnicas de segmentação é algo de grande importância, levando em conta que é uma fase muito sensível da análise, e que a simples mudança de lente ou aparelho de aquisição de imagens pode comprometer a qualidade das amostras. Estudos da literatura focam em quantificar a qualidade de métodos de segmentação utilizando métricas globais de acurácia, precisão e revocação, mas muitas vezes esse foco pode acarretar problemas na geometria dos vasos, onde são perdidas informações importantes como bifurcações, continuidade e diâmetro, podendo assim causar diversos problemas no diagnóstico. Este trabalho concentra-se na análise de problemas de continuidade na segmentação de vasos, ou seja, casos nos quais partes de vasos não são detectadas corretamente. Uma métrica de acurácia é proposta para quantificar especificamente a qualidade de segmentação em regiões de vasos difíceis de serem segmentadas. A métrica consiste no cálculo da tradicional medida de revocação, mas apenas em regiões nas quais os vasos são menos salientes. É mostrado que essa métrica possibilita quantificar com maior precisão do que métricas tradicionais a qualidade de detecção de vasos de pouca saliência em imagens. Também é definida uma técnica de aumento de dados para o treinamento de redes neurais que possibilita aumentar a qualidade de segmentação de vasos de baixa saliência. A técnica consiste em criar regiões com quedas de intensidade e descontinuidades para tornar a segmentação mais desafiadora. Com base nas análises realizadas, é esperado que as técnicas desenvolvidas possam auxiliar na melhoria de diagnósticos e futuras pesquisas em biologia, criando possibilidades de análises para correção de problemas de segmentação.

**Palavras-chave:** segmentação, vasos sanguíneos, interrupções, descontinuidades, Imagens artificiais.



---

# Abstract

---

With the current advancements in technology and medical techniques, the pursuit of improving diagnostic methods and scientific analyses brings forth a significant challenge: the efficiency and effectiveness in processing clinical data. In the field of medical image processing, there is a crucial phase that can influence all subsequent steps and even the final diagnosis, which is the segmentation phase. Particularly, segmentation is vital in examinations involving images of blood vessels, as these structures pose a great difficulty in analysis due to their complex and thin nature. Seeking improvements in segmentation techniques is of paramount importance, considering it is a highly sensitive phase of analysis, and a simple change of lens or imaging acquisition device can compromise the quality of the samples. Literature studies focus on quantifying the quality of segmentation methods using global metrics such as accuracy, precision, and recall, but often this focus may lead to problems in vessel geometry, where important information such as bifurcations, continuity, and diameter are lost, thereby causing various diagnostic issues. This work focuses on the analysis of continuity problems in vessel segmentation, i.e., cases in which parts of vessels are not correctly detected. An accuracy metric is defined to specifically quantify the segmentation quality in regions of vessels that are difficult to segment. It is demonstrated that this metric enables more precise quantification of the quality of low-saliency vessel detection in images than traditional metrics. Additionally, a data augmentation technique is defined for training neural networks, enabling improved segmentation quality of low-saliency vessels. The technique involves the creation of regions with drops in intensity and vessel discontinuities. Based on the analyses conducted, it is expected that the developed techniques can assist in improving diagnoses and future research in biology, creating new possibilities for addressing segmentation problems.

**Keywords:** segmentation, blood vessels, interruptions, discontinuities, Artificial Images.



---

# Lista de ilustrações

---

Figura 1.1 – Exemplo de diferentes resultados de segmentação . . . . .	20
Figura 2.1 – Imagem de exemplo Casal . . . . .	24
Figura 2.2 – Imagem de exemplo Casal parte 2 . . . . .	25
Figura 2.3 – Rede neural Convolutacional - Exemplo LeNet-5 . . . . .	27
Figura 2.4 – Arquitetura UNet . . . . .	28
Figura 2.5 – Arquitetura DeepLab . . . . .	29
Figura 2.6 – Imagens de Exemplo Segmentação e Descontinuidade . . . . .	30
Figura 2.7 – Imagens de Exemplo Segmentação métricas de avaliação . . . . .	30
Figura 3.1 – Ilustração do método de (ZHANG et al., 2018) . . . . .	35
Figura 4.1 – Imagens Obtidas da base de dados . . . . .	42
Figura 4.2 – Principais parâmetros do modelo de vasos . . . . .	43
Figura 4.3 – Imagens do algoritmo de geração de imagem . . . . .	44
Figura 4.4 – Imagens de Exemplo de Geração . . . . .	46
Figura 4.5 – Exemplo de cálculo da saliência local de um vaso . . . . .	47
Figura 4.6 – Exemplo de expansão dos valores . . . . .	48
Figura 4.7 – Exemplo de segmentação de diferentes métodos . . . . .	50
Figura 4.8 – Exemplo de aumento de dados . . . . .	51
Figura 4.9 – Exemplo de queda de intensidade . . . . .	52
Figura 5.1 – Exemplos de vasos artificiais . . . . .	54
Figura 5.2 – Exemplos de vasos gerados em diferentes angulações. . . . .	55
Figura 5.3 – Exemplos de vasos gerados e segmentações da rede . . . . .	56
Figura 5.4 – LVS para algumas imagens de exemplo. A primeira linha de figuras mostra as imagens originais, a segunda mostra a LVS calculada para cada pixel de vaso. Na terceira linha são mostradas em vermelho as regiões com LVS abaixo de 0,2. As regiões são indicadas apenas no esqueleto para que seja possível ver com mais facilidade o restante do vaso. . . . .	58

Figura 5.5 – Resultados para diferentes limiares da LVS para uma mesma imagem. Os valores de limiar são indicados acima de cada imagem. Regiões vermelhas indicam segmentos abaixo do limiar. . . . .	59
Figura 5.6 – Arquitetura de rede neural utilizada nos experimentos. Observe que as camadas indicadas em amarelo são repetidas 7 vezes. . . . .	59
Figura 5.7 – Resultados referentes à métrica LSRecall. (a) Comparação entre a revocação ( <i>Recall</i> ) e o LSRecall obtidos para todas as amostras do conjunto de dados. Cada ponto representa uma amostra. A linha tracejada indica a função $y = x$ . (b) Média de LSRecall em função do limiar de saliência usado para calcular a métrica. . . . .	60
Figura 5.8 – Resultados do aumento de dados. (a) Comparação do LSRecall obtido quando a CNN foi treinada com e sem aumento de dados. (b) Os mesmos dados, porém com $y$ indicando a melhoria relativa entre os valores de LSRecall. Um limiar de 0,5 foi utilizado para o cálculo do LSRecall. . . . .	61
Figura 5.9 – Resultados do aumento de dados para um limiar de 0,05 no cálculo do LSRecall. (a) Comparação do LSRecall obtido com e sem aumento de dados. (b) Os mesmos dados, porém com $y$ indicando a melhoria relativa entre os valores de LSRecall. . . . .	62

---

# Sumário

---

1	INTRODUÇÃO . . . . .	17
1.1	Contextualização e problemática . . . . .	19
1.2	Objetivos e justificativa . . . . .	19
1.3	Organização do trabalho . . . . .	20
2	FUNDAMENTAÇÃO TEÓRICA . . . . .	23
2.1	Segmentação de imagens . . . . .	23
2.2	Redes neurais convolucionais . . . . .	26
2.3	Medidas de performance de segmentação . . . . .	29
3	REVISÃO BIBLIOGRÁFICA . . . . .	33
3.1	Segmentação de vasos sanguíneos . . . . .	33
3.2	Descontinuidades de segmentação . . . . .	36
4	METODOLOGIA . . . . .	41
4.1	Dados reais utilizados . . . . .	41
4.2	Método de geração de dados artificiais . . . . .	42
4.3	Análise de descontinuidades utilizando vasos artificiais . . . . .	46
4.4	Quantificação da saliência de vasos sanguíneos . . . . .	46
4.5	Métrica para avaliação da segmentação de vasos pouco salientes	49
4.6	Método de aumento de dados para geração de vasos pouco salientes . . . . .	50
5	RESULTADOS . . . . .	53
5.1	Geração de Imagens Artificiais . . . . .	53
5.2	Análise da saliência local de vasos . . . . .	57
5.3	Aumento de imagens . . . . .	61

6	CONSIDERAÇÕES FINAIS . . . . .	63
6.1	Contribuições do trabalho . . . . .	64
	REFERÊNCIAS . . . . .	65

---

# Capítulo 1

## Introdução

---

No mundo atual, vivemos rodeados de diversas doenças causadas ou que tenham relação com alterações em vasos sanguíneos (ZHANG et al., 2018). Medidas preventivas possuem grande importância para evitar ou amenizar tais doenças, mas os sistemas empregados para avaliação e preparação de exames em geral podem apresentar grande demora, muitas vezes causadas pela necessidade de análise de um especialista (MOCCIA et al., 2018). Em áreas que diariamente recebem milhares de exames para avaliação, isso pode ser um agravante na demora da avaliação e diagnóstico (HSU et al., 2017). Por exemplo, a angiografia por ressonância magnética, um exame onde é feito o acompanhamento dos vasos sanguíneos, pode auxiliar no diagnóstico de diversas doenças, más-formações e até problemas causados por cirurgias de grande porte (ZHANG et al., 2018). Portanto, a agilidade de proporcionar um diagnóstico num exame desse porte é essencial, pois pode evitar diversos problemas de saúde. Com uma área em crescente desenvolvimento de estudos relacionados a essas doenças, há uma necessidade cada vez maior para que as imagens estudadas tenham sempre um tratamento sem viés e com precisão.

Também podem ser citados exemplos de estudos relacionados a experimentos em camundongos, onde normalmente são feitos testes em um grupo de animais, e os resultados são comparados com um grupo de controle para se entender o que os experimentos causaram em diferentes áreas do corpo, como por exemplo no cérebro, onde alterações podem ser causadas por diversas doenças (FREITAS-ANDRADE et al., 2022). Investigar o que essas variações causam e porque são causadas pode ajudar a entender mais sobre a doença estudada, para isso uma análise manual minuciosa muitas vezes se torna inviável, não apenas pelo custo, mas também pela possível presença de vieses.

Buscar avanços em técnicas de segmentação e processamento de imagens de vasos sanguíneos é um passo muito importante, pois elas permitem a definição de metodologias

sistemáticas para o diagnóstico clínico. Com isso, a segmentação pode auxiliar especialistas e pesquisadores na definição de padrões clínicos de doenças e na identificação de alterações que poderiam passar despercebidas.

As melhorias na identificação de vasos podem ser definidas de diferentes formas, incluindo técnicas onde se busca melhorar o pré-processamento das imagens, a definição de filtros e outras técnicas de realce para facilitar a análise de um especialista, e até mesmo a criação de métodos totalmente automatizados. Atualmente, a segmentação através de redes neurais convolucionais (CNN, do inglês *Convolutional Neural Network*) é a abordagem mais promissora (MOCCIA et al., 2018).

Apesar de importantes avanços na interpretação de redes neurais, essa metodologia ainda é conhecida como uma *caixa-preta*, pois não é simples entender as características e procedimentos utilizados para classificar os píxeis de uma imagem. Com isso, pode ser difícil identificar causas de problemas na segmentação de vasos, pois não há uma metodologia padrão que permita prever se uma imagem será segmentada com sucesso por uma rede. Por exemplo, alterações no nível de ruído da imagem, nas características geométricas dos vasos, ou do equipamento de aquisição podem influenciar de maneira imprevisível na qualidade da análise. Portanto, um estudo orientado a entender os motivos e quais características podem influenciar a segmentação de vasos é importante. Buscar melhorias através da definição de novas arquiteturas de redes e técnicas de treinamento são relevantes, mas também é interessante identificar as características das imagens que levam a dificuldades na segmentação dos vasos. Inclusive, métodos de avaliação de erros e de identificação de problemas específicos também necessitam de grande atenção.

Neste trabalho são propostas técnicas para ajudar na avaliação de métodos de segmentação e no treinamento de redes neurais. É proposta uma nova métrica baseada na dificuldade de identificação de segmentos de vasos. Essa métrica é calculada para todos os segmentos de vasos da imagem com base na similaridade da intensidade do vaso com o fundo da imagem. A hipótese é que quanto maior for a similaridade entre o vaso e o fundo da imagem, mais difícil será a segmentação, já que alguns pontos podem ser considerados fundo de forma equivocada. Com base nisso são definidas pontuações de saliência para os segmentos de vasos, e métricas de acurácia são aplicadas apenas nos segmentos com saliência abaixo de um limiar.

Para o treinamento de redes neurais foi criado um algoritmo de aumento de dados, que consiste na modificação de segmentos de vasos, criando lacunas e quedas de intensidades, as quais tendem a ajudar no treinamento das redes, criando dificuldades para a rede segmentar corretamente os vasos.

## 1.1 Contextualização e problemática

Atualmente na literatura, o maior foco é na melhoria da acurácia de classificação, detecção e segmentação, buscando sempre melhorar as técnicas já existentes ou identificando novos métodos para que seja possível uma melhora na acurácia. No caso da segmentação, é comum o uso de métricas de acurácia como a intersecção sobre a união (IoU) ou coeficiente Dice (MOCCIA et al., 2018), que proporcionam um valor global para a qualidade de segmentação de todos os píxeis de uma imagem. O uso de tais métricas pode esconder deficiências importantes de um algoritmo dependendo do tipo de estrutura que se deseja segmentar.

Na segmentação de estruturas finas, é comum encontrar o problema da continuidade nas estruturas após técnicas de processamento, gerando assim falhas na segmentação que podem acabar causando diversos outros problemas nos passos seguintes ao processamento. A Figura 1.1 mostra um exemplo do tipo de problema que pode surgir. São ilustrados dois possíveis resultados de algoritmos de segmentação (em ciano e em vermelho). A segmentação em ciano mostra um suposto algoritmo que levou muito mais em conta a continuidade e a geometria do que a acurácia global de segmentação. Já a segmentação em vermelho ilustra uma segmentação que identificou a maioria dos píxeis pertencentes ao vaso, mas falhou em regiões importantes para a análise deles.

Falhas sistemáticas em algoritmos de segmentação podem levar a erros na estimativa de características importantes dos vasos. No caso da segmentação em vermelho ilustrada na Figura 1.1, a tortuosidade, o comprimento e o número de bifurcações dos vasos poderão ser subestimados. No caso da segmentação em ciano, essas propriedades serão mais bem estimadas, mas os diâmetros dos vasos será subestimado. Tais erros de segmentação podem criar falsos diagnósticos, principalmente levando em conta que muitas patologias causam alterações na tortuosidade, comprimento e até mesmo bifurcação dos vasos.

Nesse contexto, é interessante desenvolver técnicas para analisar possíveis falhas sistemáticas em algoritmos de segmentação. Portanto, além de buscar obter boa qualidade de segmentação geral da imagem, é importante definir procedimentos e métricas que identifiquem e aprimorem problemas em regiões relevantes de vasos sanguíneos.

## 1.2 Objetivos e justificativa

Este trabalho foca em uma característica muito desejada na segmentação de vasos sanguíneos, que é a preservação da continuidade do vaso. O principal objetivo do estudo é definir técnicas que auxiliem na preservação da continuidade dos vasos quando estes são segmentados utilizando redes neurais convolucionais. A definição dessas técnicas envolve três objetivos específicos:

- Definir um índice de saliência que possibilite quantificar a dificuldade esperada de



Figura 1.1 – Ilustração de dois possíveis resultados de um algoritmo de segmentação, mostrados em ciano e em vermelho. A segmentação em ciano representa bem a geometria do vaso, com exceção do seu diâmetro. A segmentação em vermelho falhou em pontos importantes dos vasos, como bifurcações e regiões tortuosas.

segmentação de regiões específicas de vasos sanguíneos.

- Criar uma métrica que quantifique a qualidade de algoritmos de segmentação em regiões de vasos sanguíneos difíceis de serem segmentadas.
- Propor um protocolo de geração de dados artificiais e uma técnica de aumento de dados para melhorar a robustez de redes neurais à descontinuidades de vasos.

A definição de um índice de saliência possibilita identificar a dificuldade esperada na segmentação de diferentes regiões de um tecido vascular. Grande parte dos vasos em uma imagem podem ser simples de serem identificados. Uma medida de saliência permitirá focar o ajuste de algoritmos de segmentação em regiões mais desafiadoras. Tendo definido um índice de saliência, é possível definir uma métrica de qualidade de segmentação em regiões possuindo saliência específicas. Por exemplo, é possível identificar a fração de píxeis de vasos sanguíneos identificados com sucesso em regiões de baixa saliência.

A elaboração de um modelo para a geração de vasos artificiais permitirá analisarmos de forma sistemática as situações nas quais redes neurais conseguem representar com sucesso o critério de continuidade dos vasos. Será definida também uma nova técnica de aumento de dados que permita gerar imagens realísticas de vasos sanguíneos com variações pré-definidas de intensidade, o que permitirá o treinamento de redes mais robustas à descontinuidades.

### 1.3 Organização do trabalho

Este trabalho está organizado da seguinte forma:

O capítulo 2 apresenta a fundamentação teórica do trabalho, onde são abordados os temas de segmentação de imagens, redes neurais convolucionais e as medidas de performance de segmentação.

No capítulo 3 é abordada a revisão bibliográfica utilizada nesse trabalho, onde são descritos estudos prévios sobre os temas de segmentação de vasos sanguíneos e descontinuidades de segmentação.

O capítulo 4 explicita as metodologias aplicadas nesse trabalho, incluindo o modelo de geração de vasos artificiais, a definição de um índice de saliência e de uma métrica de qualidade de segmentação, assim como a proposta de um algoritmo de aumento de dados para vasos sanguíneos.

No capítulo 5 são mostrados os resultados das metodologias propostas.

Por fim, o capítulo 6 discorre sobre as considerações aos experimentos realizados.



---

## Capítulo 2

# Fundamentação Teórica

---

*Neste capítulo descrevemos o referencial teórico utilizado. Apresentamos procedimentos comumente empregados na segmentação de vasos sanguíneos, que envolvem etapas de realce, binarização, bem como métodos de modelos deformáveis e rastreamento. Na sequência, descrevemos a tendência mais atual de realizar a segmentação de vasos utilizando técnicas de aprendizado de máquina, juntamente com algumas arquiteturas de redes neurais usualmente empregadas na literatura.*

### 2.1 Segmentação de imagens

Segmentação de imagens pode ser definida como um processamento para a identificação de regiões coerentes da imagem. Duas classes principais de segmentação são usualmente estudadas: segmentação semântica e segmentação de instâncias. Na segmentação semântica, é definida uma classe para cada pixel da imagem. Portanto, a imagem é particionada em diferentes classes. Um exemplo de segmentação semântica pode ser visto na Figura 2.1(B), onde é mostrada a classe de pessoas, a classe bicicleta e a classe fundo. Apenas classificar os objetos com uma única classe pode ser suficiente para alguns propósitos, mas algumas aplicações exigem uma segmentação mais específica, chamada de segmentação de instâncias, onde cada objeto é identificado separadamente. Na Figura 2.1(C) é mostrado um exemplo de segmentação de instâncias, onde podemos observar que os objetos foram divididos em 4 instâncias, pessoa1, pessoa2, bicicleta e fundo. Esse sistema poderia ser utilizado, por exemplo, para identificar quantas pessoas se encontram na imagem.

A segmentação é um procedimento necessário para que outros sistemas possam processar os dados segmentados para extrair informações importantes sobre as imagens, como a identificação de tumores em exames médicos (TIWARI; SRIVASTAVA; PANT, 2020). Também podem ser citados exemplos onde segmentação é utilizada para a contagem de




Figura 2.1 – Principais tipos de segmentação. Em (A) temos a imagem original, onde podemos ver um casal sentado ao lado de uma bicicleta. Em (B) temos uma imagem de exemplo de segmentação semântica, onde podemos ver as classes distintas extraídas da imagem, em vermelho a classe bicicleta, em verde a classe pessoa e em preto a classe fundo. Já em (C) temos a segmentação de instâncias, onde são definidas classes específicas para cada instância encontrada. Imagem original foi retirada de site com direitos livres <sup>1</sup>.

objetos (DIJKSTRA et al., 2021) e para diagnósticos, como por exemplo, o crescimento de vasos sanguíneos de forma anormal, também conhecido como neovascularização anormal, usualmente causado pela retinopatia da prematuridade como (ZHANG et al., 2018) mostra em seu artigo. A segmentação é algo que pode ajudar muito nos processos mais avançados que se decorrem do pós processamento das imagens, pois ter informações precisas podem diminuir o tempo gasto em análises.

Imagens também podem ser segmentadas manualmente. Mas segmentações feitas manualmente podem apresentar diversos problemas, como divergências entre operadores, causando inconsistências na segmentação, também sendo necessário um tempo muito grande e muitos operadores para a segmentação. Isso acaba gerando diversos problemas e uma lentidão acima do normal. Por outro lado, extrações feitas de forma automatizada podem agilizar muito a operação e processamento de exames, podendo diminuir o tempo para que o médico dê um diagnóstico correto e diminuir riscos de falhas, tendo assim potencial de maior precisão e menos viés. Essas são características importantes que para certas aplicações de pesquisas podem ser essenciais. Por exemplo, pesquisas envolvendo a comparação entre um grupo de controle e um grupo onde foram feitos alguns testes, precisam ter uma precisão muito grande, pois qualquer alteração mínima pode ser o fator chave pesquisado. Adicionalmente, é necessário que a segmentação não possua vieses. Portanto, uma técnica de segmentação automatizada pode ser a melhor abordagem para esse tipo de pesquisa.

Por se tratar de algo muito complexo, com diversos fatores influenciadores, a segmenta-

<sup>1</sup> <<https://pixabay.com/pt/photos/fran%c3%a7a-proven%c3%a7a-bicicleta-amantes-1049333/>>



Figura 2.2 – Imagem em que se destacam em verde e vermelho partes importantes da imagem para discussão e levantamento de possíveis problemas de segmentação. Imagem original foi retirada de site com direitos livres <sup>1</sup>.

ção pode ter diversos problemas, desde erros em que são classificados erroneamente alguns pixels, até mesmo classificações de classes ou instâncias inexistentes na imagem original. Na segmentação de imagens, o maior desafio quando utilizada uma técnica automatizada ou semiautomatizada é, em grande parte, a consistência de continuidade, pois muitas vezes as segmentações tendem a ter interrupções e artefatos. Por exemplo, é comum objetos distintos serem segmentados como uma coisa só, ou objetos inteiros serem divididos em mais de um objeto. Tudo isso é causado normalmente por problemas de ligação entre os pontos do objeto na imagem, muitas vezes esses pontos não são identificados como uma coisa só. Exemplificando, um erro que é muito comum em sistemas automatizados, pode ser observado na Figura 2.1(A), na qual parte das pernas das pessoas não tem conexão direta com o restante do corpo devido ao banco que se sobrepõe, causando assim uma desconexão, como pode ser observado pela imagem 2.2. Analisando a imagem, pode-se concluir que a perna destacada em verde é parte da pessoa à esquerda e o destaque em vermelho da pessoa à direita. Um algoritmo de segmentação que busca identificar instâncias poderia errar e acabar classificando esses objetos como parte do fundo, ou até mesmo atribuí-los a instâncias incorretas.

Para corrigir problemas de segmentação muitas vezes são aplicadas técnicas variadas, que buscam criar associações entre pixels do objeto, podendo assim aumentar a precisão da segmentação. Melhorias constantes foram propostas em trabalhos da literatura ao longo

<sup>1</sup> <<https://pixabay.com/pt/photos/fran%c3%a7a-proven%c3%a7a-bicicleta-amantes-1049333/>>

dos anos, com diversas técnicas e variadas abordagens de segmentação, nos mais diversos tipos de imagens, como de pessoas (CAO; LIU; JAIN, 2014), linguagem escrita (GATOS; STAMATOPOULOS; LOULLOUDIS, 2011), exames médicos (MOCCIA et al., 2018) e diversos outros tipos de imagens. Atualmente, a maioria das abordagens consideradas estado da arte envolvem redes neurais convolucionais.

## 2.2 Redes neurais convolucionais

Redes neurais convolucionais são uma arquitetura de rede neural que se inspira no mecanismo natural de percepção visual dos seres vivos. Em 1959 (HUBEL; WIESEL, 1968) descreveu que as células do córtex visual animal são responsáveis pela detecção de luz em campos receptivos, inspirado por tal descoberta, (FUKUSHIMA; MIYAKE, 1982) propôs o neocognitron em 1980 que pode ser considerado o antecessor da CNN. Em 1990 (LECUN et al., 1989) publicou um artigo que estabeleceu a forma básica de uma CNN, chamada de LeNet. Desde então, muitas pesquisas buscaram melhorias e mudanças para que se tornasse uma técnica mais robusta. Dentre as mais notáveis, pode-se destacar (HINTON et al., 2012) que propuseram a arquitetura AlexNet e mostraram melhorias significativas em métodos de classificação de imagens. A arquitetura proposta é semelhante à LeNet, mas com estrutura mais profunda, mais camadas de convoluções. Outras contribuições importantes incluem a ZFNet (ZEILER; FERGUS, 2014), VGGNet (SIMONYAN; ZISSERMAN, 2014), GoogleNet (SZEGEDY et al., 2015) e ResNet (HE et al., 2016). Ao longo dos anos as redes se tornaram cada vez mais profundas, como por exemplo a ResNet, que é cerca de 20 vezes mais profunda que a AlexNet e até 8 vezes mais profunda que a VGGNet. Redes mais profundas possuem maior capacidade de ajuste, porém também possuem maior complexidade, o que torna a rede mais complicada de otimizar e mais propensa a sobreajuste, que é quando uma rede se torna muito específica para o conjunto de treinamento, podendo ter problemas para prever novos resultados.

Por mais que existam diversas arquiteturas de CNN, em sua essência a arquitetura tende a seguir um padrão, formado por 3 principais tipos de camadas: convolucionais, *pooling* e totalmente conectadas. A camada convolucional tem como objetivo aprender padrões marcantes da imagem e destacá-los, mapeando-os e transformando-os em ativações. A camada de *pooling* tem como objetivo receber a saída das camadas convolucionais e transformar em uma saída com menor tamanho. Normalmente se aplica técnicas de *max pooling*, onde é utilizado sempre o maior valor dentro da janela de *pooling*. As camadas totalmente conectadas (do inglês *fully connected*) possuem cada neurônio conectado com todos os valores de ativação da camada anterior. Esta camada usualmente é uma das últimas camadas da rede e é importante em tarefas de classificação de imagens. Na Figura 2.3 temos um exemplo de arquitetura da rede LeNet-5.

Nas redes neurais convolucionais temos outros conceitos importantes que usualmente

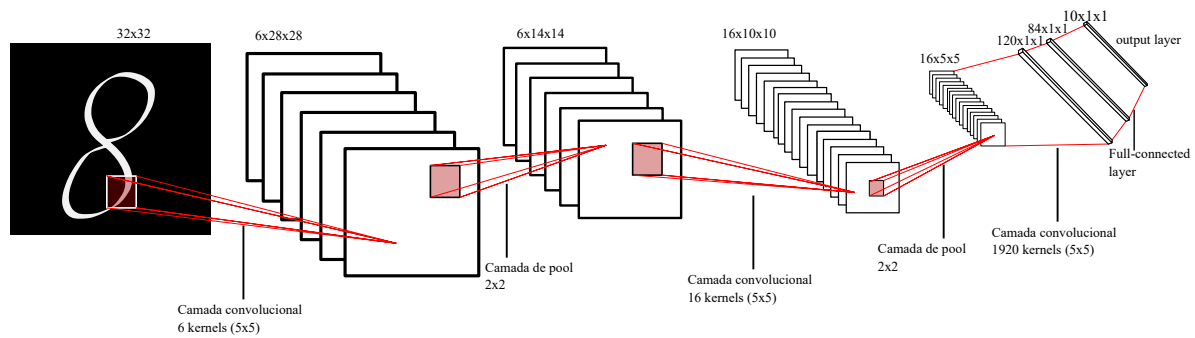


Figura 2.3 – Exemplo da arquitetura LeNet-5. FONTE: Próprio autor

aprimoram o resultado da rede. Toda rede neural precisa de uma função de ativação não-linear para evitar que se torne trivial. Atualmente a função de ativação mais popular é a ReLu, do inglês *Rectified Linear Unit*. Também podem ser descritos alguns passos adicionais que redes específicas podem utilizar, como vamos ver mais adiante, um desses passos é a convolução transposta, que pode ser entendida como a operação inversa da convolução. A convolução transposta pode ser utilizada para aumentar a resolução espacial das ativações da rede.

Atualmente é comum ser encontrada duas principais formas de serem aplicadas redes neurais convolucionais, sendo a primeira e mais comum, para classificação, onde é identificado um objeto na figura e é concedido a ele uma classe ou instância específica. Por exemplo, na Figura 2.1, caso fosse aplicada uma rede neural convolucional na região onde se encontra apenas a bicicleta, a rede daria como resultado a classe Bicicleta. A segunda forma, que é a estudada neste trabalho, é a segmentação, onde a rede neural deve retornar a localização exata dos pixels de um dado objeto, podendo assim fazer um processamento espacial das informações descritas.

Dentre diversas redes neurais estudadas, possivelmente as mais comuns e mais utilizadas para segmentação de imagens médicas são a UNet (RONNEBERGER; FISCHER; BROX, 2015) e a DeepLab (CHEN et al., 2017).

A UNet possui uma arquitetura baseada em contração e expansão, tendo esse nome por causa do desenho de sua arquitetura. A UNet foi criada principalmente para imagens biomédicas. A sua arquitetura é ilustrada na Figura 2.4, onde vemos os passos que a rede aplica para extração das informações. A rede primeiro realiza a etapa de contração, que é uma sequência de camadas onde são aplicadas convoluções e *max pooling*. Na expansão a resolução das ativações é aumentada até que o tamanho da imagem original seja atingido. De forma a facilitar a combinação de informações em diferentes escalas, durante a expansão as ativações obtidas durante a contração são concatenadas com as ativações obtidas pela expansão (setas cinzas na Figura 2.4). Por fim, na camada final é aplicada uma convolução na qual a saída é uma imagem possuindo um número de canais igual ao número de classes

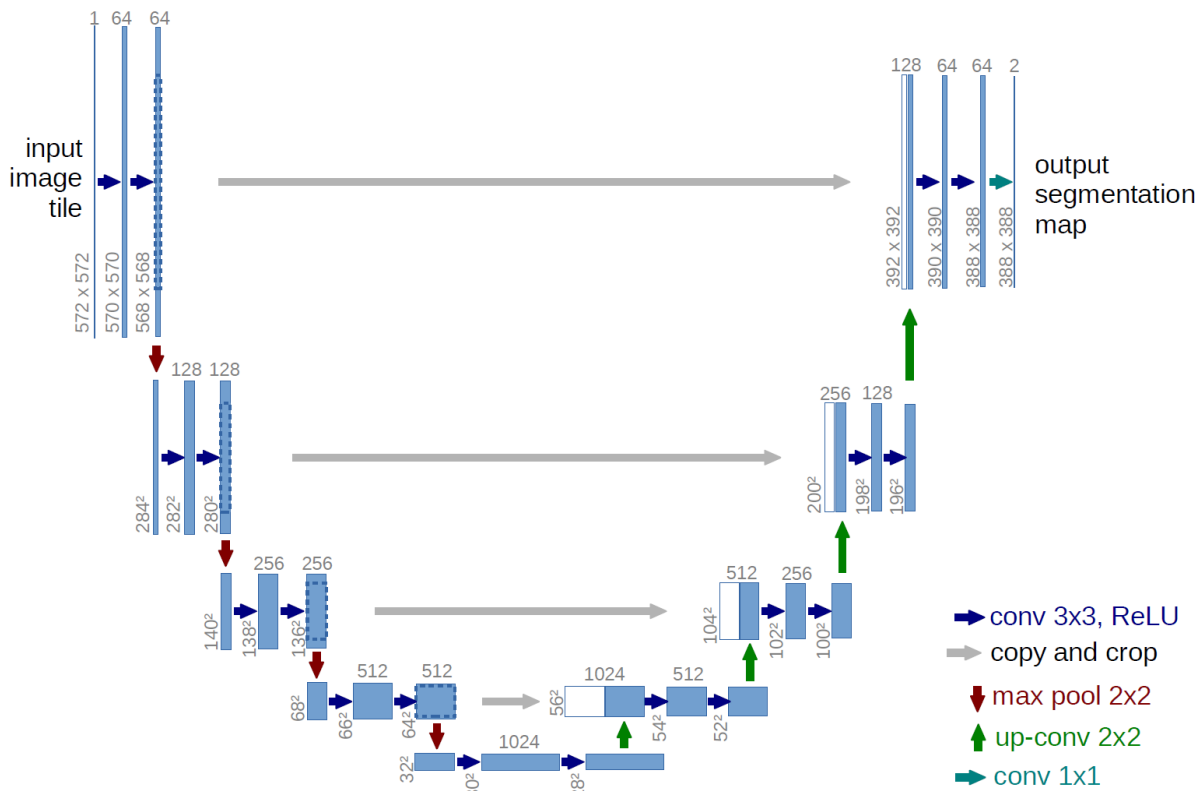


Figura 2.4 – Imagem da arquitetura de Rede neural Convolutional UNet extraída de (RONNEBERGER; FISCHER; BROX, 2015)

sendo analisadas.

A arquitetura DeepLab se caracteriza em especial por utilizar a técnica de convoluções dilatadas ou Atrous, onde os filtros de convolução são ampliados sem a necessidade de mudar o número de parâmetros, normalmente inserindo zeros nesses espaços. Uma ilustração da arquitetura está demonstrada na Figura 2.5.

Apesar de diversos progressos em pesquisas e arquiteturas, normalmente os estudos são focados em aplicações específicas e resolução dos problemas de estudos anteriores. Estudos focados em entender quais os impactos que mudanças nos dados podem provocar nas redes neurais são relativamente mais incomuns, sendo que tais estudos podem ajudar a entender como as redes se comportam com determinadas variações dos dados e com técnicas de treinamento específicos. Fazer um estudo dessa forma necessita de imagens que possam ser variadas de forma sistemática, o que possibilita caracterizar o comportamento da rede em diferentes situações de interesse. Tal variação pode ser realizada através de imagens geradas artificialmente, pois encontrar fatores isolados em bases de imagens naturais pode ser muito custoso e pode acabar não tendo a infinidade de variações que um algoritmo de imagens artificiais pode proporcionar.

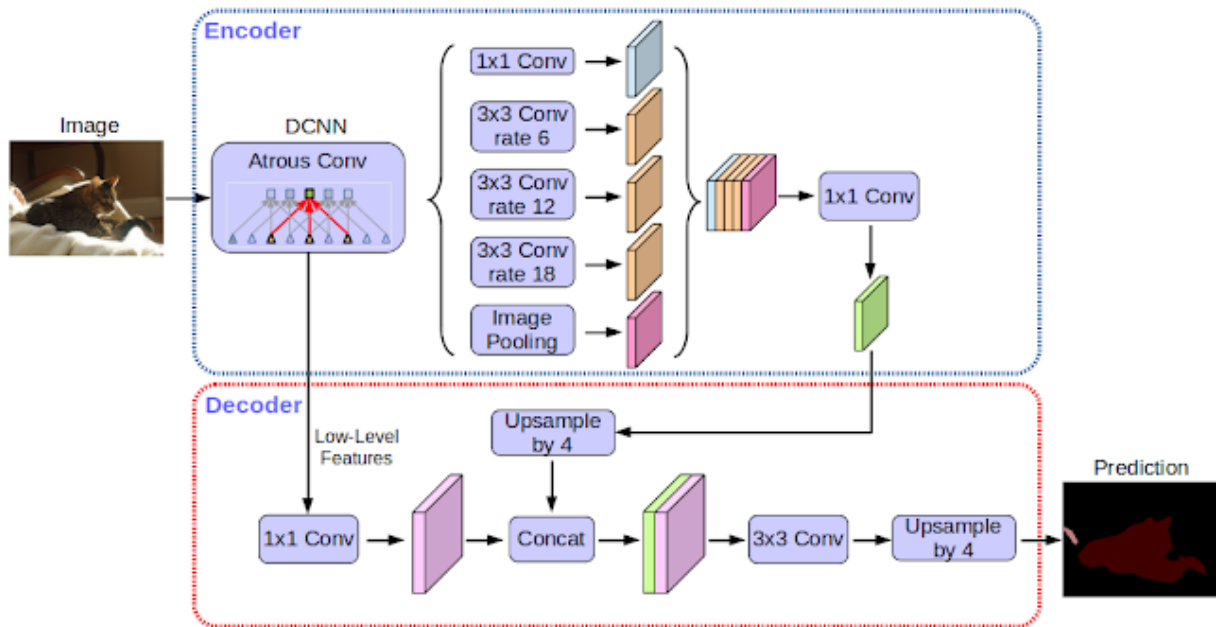


Figura 2.5 – Imagem da arquitetura de Rede neural Convolucional DeepLab extraída de (CHEN et al., 2017)

## 2.3 Medidas de performance de segmentação

Para que a qualidade da segmentação possa ser avaliada, é necessário definir medidas de qualidade que possam ser extraídas de forma automatizada, sem que a influência humana possa criar interferências na avaliação. Para que isso seja possível, é necessário ter a disposição um exemplo de como a segmentação deveria se comportar, para isso é utilizada a chamada imagem rótulo, alvo ou padrão ouro, que pode ser tida como uma referência para o resultado da segmentação. Um exemplo é mostrado na Figura 2.6. A imagem mostrada na Figura 2.6(A) representa a imagem original de uma estrutura tubular. Na Figura 2.6(B) é mostrada a imagem de rótulos, na qual branco indica o fundo da imagem e preto indica pixels pertencentes ao objeto e em (C) temos o exemplo de quando não é segmentado corretamente, causando discontinuidades.

Através da comparação entre o resultado de um algoritmo de segmentação e a imagem de rótulos, diversas métricas podem ser extraídas. Essas métricas, que são calculadas considerando todos os pixels da imagem, envolvem o conceito de Falso-Positivo (FP), Falso-Negativo (FN), Verdadeiro-Positivo (VP) e Verdadeiro-Negativo (VN). FP consiste em pixels que foram segmentados como objeto mas que não deveriam ter sido associados ao objeto. Isso usualmente ocorre devido a ruídos na imagem ou outros objetos que se parecem com o objeto de interesse. FN consiste em pixels que deveriam ter sido associados ao objeto mas que não foram detectados. Esse erro é comum de acontecer quando o objeto possui variação de intensidade. VP está associado com pixels que foram corretamente segmentados. VN é normalmente a métrica utilizada para expressar a qualidade da




Figura 2.6 – Ilustração de conceitos relacionados à segmentação. (A) imagem original a ser segmentada. (B) Imagem de rótulos representando a segmentação de referência. (C) Exemplo de uma segmentação incorreta, gerando uma descontinuidade.




Figura 2.7 – Ilustração de exemplos de falso positivo e falso negativo. (A) representa uma imagem onde foi apresentado um erro de segmentação de Falso-Negativo, onde uma região que deveria ser segmentada como vaso foi segmentada como fundo. (B) Exemplo de segmentação com Falso-Positivo, onde parte do fundo foi considerada como fazendo parte objeto principal. (C) Segmentação ideal, sem FP nem FN.

segmentação do fundo da imagem, onde tudo que não foi incluído no objeto principal está presente. Em imagens possuindo muitos píxeis de fundo VN usualmente não é utilizado. Usualmente, a quantidade total de píxeis FP, FN, VP e VN é calculada para uma dada imagem. Podemos ver na Figura 2.7 exemplos de erros de segmentação associados com essas métricas.

Com base nesses dados é possível elaborar novas métricas que quantifiquem a qualidade dos resultados de um algoritmo de segmentação. Primeiramente, definimos a métrica de precisão, calculada pela fórmula

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (2.1)$$

O denominador dessa medida representa a contagem de todos os píxeis que foram classificados como pertencentes ao objeto segundo o algoritmo de segmentação. Já o numerador quantifica os píxeis identificados que de fato pertencem ao objeto. Portanto, a precisão quantifica, dentre os píxeis identificados pelo algoritmo, a fração deles que realmente pertencem ao objeto. O maior valor possível da precisão é 1. Outra métrica importante é a revocação, definida pela equação

$$\text{Revocação} = \frac{VP}{VP + FN} \quad (2.2)$$

Essa medida quantifica a fração de píxeis pertencentes ao objeto que foram corretamente identificadas pelo algoritmo. As medidas de precisão e revocação são complementares. Um algoritmo que classifique todos os píxeis da imagem como pertencentes ao objeto terá uma revocação muito alta, mas uma precisão baixa.

É interessante também definirmos uma única métrica que quantifique a qualidade geral da segmentação. Essa métrica, chamada de Intersecção sobre a União (IoU) é definida como

$$IoU = \frac{VP}{VP + FP + FN}. \quad (2.3)$$

Quanto mais erros o algoritmo tiver, maior será o valor de  $FP$  e/ou  $FN$ , o que diminui o valor de IoU. O melhor resultado possível é um IoU igual a 1.

As medidas apresentadas são muito utilizadas na literatura para quantificar a qualidade geral de algoritmos de segmentação. Mas elas podem esconder alguns vieses do algoritmo. Por exemplo, um algoritmo que segmente muito bem vasos sanguíneos, mas que sistematicamente não segmente a bifurcação dos vasos, poderá ainda assim ter altos valores de precisão, revocação e IoU, mas tal algoritmo poderá levar a erros consideráveis se o objetivo for estudar a bifurcação de vasos sanguíneos. Nos casos estudados neste trabalho, a área de interesse são as discontinuidades, causadas ou não por quedas na intensidade que podem existir em vasos sanguíneos, que são pequenas áreas em comparação com o restante da imagem.



---

## Capítulo 3

# Revisão Bibliográfica

---

*Neste capítulo, apresentamos uma ampla revisão da bibliografia no que se refere à técnicas de segmentação de vasos sanguíneos, principalmente levando em conta a dificuldade da segmentação quando essa apresenta oscilações de intensidade, causando assim falhas em técnicas mais simples, também expomos alguns trabalhos mais recentes que tratam da segmentação de vasos por aprendizado profundo.*

### 3.1 Segmentação de vasos sanguíneos

Na atualidade há uma infinidade de doenças e comorbidades que sejam influenciadas por alterações em vasos sanguíneos. Medidas de prevenção podem ajudar a diminuir as consequências dessas doenças. Entretanto, muitas vezes essas medidas de prevenção envolvem exames periódicos ou até mesmo específicos que precisam de uma atenção muito grande para seu entendimento, sendo necessário um especialista para verificar, aumentando a demora no diagnóstico. Muitas vezes também se encontram problemas de enviesamento, principalmente quando se leva em conta processos manuais em pesquisas na área, onde mudanças sutis nos vasos precisam ser quantificadas de forma precisa. Como consequência, a área possui muitas possibilidades e tem crescido muito nos últimos anos, pois necessita de cada vez mais técnicas para aperfeiçoar e melhorar os índices de acertos. Isso porque mesmo com bons profissionais, uma segmentação pode levar muito tempo, tendo um custo muito alto e podendo ter vieses.

Para que seja possível esse crescimento de técnicas automatizadas, estudos nas áreas são necessários para que seja obtida uma maior assertividade, precisão e menor tempo de processamento de exames. Muitas vezes tornar o processo semiautomatizado pode ajudar a resolver a questão de tempo, mas pode acabar comprometendo a precisão em muitos casos. Para isso, são necessários métodos mais robustos e preparados para massivas

quantidades de dados que possam ser gerados. Mas para que métodos automáticos possam ser aplicados, as imagens devem passar por diversos tratamentos e processamentos prévios que vão corroborar com uma melhora dos algoritmos de análise dos exames.

A maior parte desses processamentos gira em torno da segmentação, descrito no tópico 2.1. A segmentação é parte muito importante dessa cadeia de processo até chegar à análise final do exame, pois é nela em que é separado o fundo da imagem, que não deve influenciar na análise dos vasos, que são o alvo. Justamente a segmentação se torna algo tão importante, mas que pode trazer inúmeros problemas, pois a partir dela que são extraídos dados relevantes. Constantemente são estudadas e melhoradas técnicas de segmentação.

A segmentação de vasos sanguíneos pode ser feita de diversas formas, segundo (MOCCIA et al., 2018) normalmente elas são divididas em diferentes categorias:

- ❑ **Reforço/Melhoria de vasos:** Normalmente caracterizada por aumento da qualidade de percepção do vaso, como por exemplo, por meio de contraste e diversas outras técnicas que visam aumentar a visibilidade do vaso, logo seguida de uma técnica de limiarização, para que seja feita a remoção de estruturas externas.
- ❑ **Modelos deformáveis:** Os modelos deformáveis consideram curvas ou superfícies, definidas dentro do domínio da imagem, que podem se mover e deformar sob a influência de forças internas e externas. Muito utilizado para segmentação de vasos com arquitetura complexa e alta variabilidade de forma e tamanho, porém seu maior problema é o custo computacional, que para aplicações em tempo real pode se mostrar um grande obstáculo.
- ❑ **Rastreamento:** Os algoritmos de rastreamento de vasos sanguíneos geralmente consistem na definição de pontos-semente seguidos de um processo de crescimento guiado por restrições derivadas de imagens. Os pontos de sementes podem ser definidos manualmente ou obtidos por meio de abordagens de aprimoramento de vasos. É uma abordagem muito útil para segmentar árvores vasculares conectadas.
- ❑ **Aprendizado de máquina:** Essa técnica consiste em treinar por meio de algoritmo de aprendizado uma rede neural que classifica e segmenta os vasos, normalmente tendo como base aprendizado supervisionado ou não-supervisionado, que basicamente diferem pela presença ou não de imagens anotadas manualmente para o aprendizado.

Essas diferentes categorias se diferem principalmente pelas formas de abordagem. Cada tipo de abordagem tem suas peculiaridades, pontos positivos e negativos. Apresentaremos a seguir alguns estudos relevantes envolvendo essas abordagens.

(ZHANG et al., 2018) propõe uma abordagem utilizando um método de segmentação através de uma modelagem matemática da propagação de linhas e contornos. Diferentemente de pesquisas anteriores, seu método emprega o processo de complementação de




Figura 3.1 – Ilustração da criação de uma dimensão adicional associada com a direção dos vasos sanguíneos proposta por (ZHANG et al., 2018), que possibilita segmentar vasos com menos erros.

contorno no grupo de roto-translação  $SE(2) \equiv \mathbb{R}^2 \times S^1$ , que basicamente consiste em definir uma terceira dimensão na qual as orientações dos vasos são levados em consideração, definindo camadas de análise possuindo vasos com orientações similares. Um exemplo é mostrado na Figura 3.1. A consideração da orientação dos vasos proporciona resultados melhores do que trabalhos anteriores, mas vasos possuindo grandes interrupções não são bem segmentados.

Em (KIRST et al., 2020) são apresentadas técnicas para a aquisição de imagens de vasos sanguíneos de alta qualidade. São estudados diferentes reagentes e a qualidade das imagens resultantes. Uma técnica de enaltecimento de estruturas tubulares foi desenvolvida e utilizada para segmentar os vasos. Para que fosse possível um resultado de maior qualidade, foi aplicada uma rede neural convolucional especializada em fechamento de buracos dos vasos segmentados. A rede auxiliou com sucesso a correção de falhas.

(TODOROV et al., 2020) apresenta uma abordagem de aprendizado de máquina para segmentar todos os vasos sanguíneos cerebrais de um camundongo em imagens 3D. O processo desenvolvido envolve 3 passos para a extração de informações relevantes, sendo eles: 1) Extração das imagens 2) Segmentação e rastreamento através de redes neurais convolucionais e 3) extração das características vasculares de regiões do cérebro.

Em (LISKOWSKI; KRAWIEC, 2016) temos um estudo sobre a segmentação de vasos sanguíneos da retina, o estudo utiliza uma arquitetura de aprendizado profundo para o processamento das imagens, tendo um resultado de alta qualidade, mas que, segundo os autores, necessita de aprimoramentos principalmente nos vasos menores.

Outra abordagem relacionada à segmentação utilizando CNNs pode ser citado (TETTEH et al., 2020), onde é apresentada a DeepVesselNet, que é uma arquitetura de aprendizado profundo para a segmentação de estruturas tubulares conectadas em árvores em angiografias 3D. O artigo apresenta uma nova arquitetura que se mostra muito eficiente nesse tipo de imagem, com pouco custo de memória e processamento.

A segmentação de vasos sanguíneos pode ser utilizada para diversas aplicações médicas e com diversas arquiteturas, como por exemplo em (ZHANG; CHUNG, 2018), onde é aplicada a U-Net para segmentação de vasos sanguíneos de imagens de fundo da retina. No artigo, é proposta uma melhoria na arquitetura U-Net através da adição de supervisão profunda, que consiste na utilização de uma função de perda em mapas de ativação intermediários da rede. Essa técnica reduz problemas de perda de informação durante a aplicação do *backpropagation*. Também são discutidas melhorias na imagem de entrada para que a rede possa ter um melhor desempenho. Pode ser citado também (XIAO et al., 2018), que aplica a U-Net com blocos residuais e mecanismos de atenção (BAHDANAU; CHO; BENGIO, 2014) para aprimorar a segmentação de vasos finos. Pesquisas que tentam modificar arquiteturas de redes neurais adicionando novas camadas podem ter um desempenho melhor que as arquiteturas comuns, mas como pode ser visto em (JIN et al., 2019), mudanças mais drásticas, como modificar a forma que é feita a convolução, trocando de convolução comum para convolução deformável, onde o filtro de convolução pode ser alterado conforme o objeto a ser estudado, pode ser uma direção interessante de futuras pesquisas.

Dentre as arquiteturas citadas, todas são modificações da U-Net, mas algo em comum se repete, que são problemas relacionados à segmentação de vasos muito finos. Isso ocorre porque a U-Net envolve a redução sucessiva do tamanho dos mapas de ativação. Apesar da rede possuir atalhos que, a princípio, possibilitam a propagação da informação sobre vasos finos, na prática tais vasos tendem a possuir menor qualidade de segmentação. Considerando essa dificuldade, (GU et al., 2019) propõe uma nova arquitetura, chamada de CE-Net. Ela se inspira na U-Net para a parte do codificador e decodificador, mas entre essas duas etapas são aplicadas duas técnicas de processamento. Primeiro, uma convolução dilatada e logo após um *pooling* de vários filtros residuais que é utilizado principalmente para corrigir possíveis problemas com objetos de diferentes tamanhos.

Mesmo com todo o avanço e tentativas de encontrar o método ou arquitetura de rede neural que tem uma assertividade maior, muitos problemas ainda pairam sobre a segmentação de vasos sanguíneos. Um dos principais problemas é a descontinuidade desses vasos, podendo ser causados por bifurcações, variações de intensidade e até mesmo por sua complexidade estrutural, causando problemas na segmentação e conseqüentemente nos dados extraídos após o processamento. Isolar fatores que podem influenciar nessas falhas pode ser um passo muito importante para avanços ainda maiores na área.

## 3.2 Descontinuidades de segmentação

Apesar de constantes avanços em técnicas de segmentação e melhorias de imagens, ainda é comum que sistemas automatizados apresentem problemas relacionados principalmente à falhas de segmentação em regiões específicas de objetos. No caso de vasos

sanguíneos, é comum que parte de um vaso não seja segmentada corretamente, gerando uma descontinuidade no vaso, que em inglês é chamada de *gap*. A Figura 2.6(C) apresenta um exemplo de descontinuidade. Tais descontinuidades podem levar a conclusões incorretas sobre as propriedades de vasos sanguíneos.

Segundo (HSU et al., 2017), normalmente a conectividade é perdida devido a quatro razões: (1) grandes variações na intensidade da imagem ao longo das linhas centrais dos vasos, (2) mudanças de sinal nos valores próximos a bifurcações, (3) lacunas artificiais introduzidas em segmentos de vasos devido à imagem finita e espaçamento entre planos de profundidade e (4) artefatos devido a estruturas sobrepostas, como superfícies corticais ou espaços do líquido cefalorraquidiano.

Dentre os artigos citados no tópico 3.1, temos em especial algumas técnicas aplicadas que podem solucionar esses problemas descritos. Como apresentado anteriormente, (ZHANG et al., 2018) define uma técnica que ajuda a melhorar o desempenho dos métodos de segmentação, sua técnica consiste em criar uma nova dimensão na imagem tem um resultado muito promissor em pequenas descontinuidades, mas acaba tendo problemas em descontinuidades de grande tamanho.

(HSU et al., 2017) descrevem técnicas de pré processamento, usando um processo onde é feito o aprimoramento de contraste multiescala e normalização da imagem. Os autores mostram que o procedimento desenvolvido não altera informações relevantes sobre os vasos, mas aprimora o contraste dos vasos e remove ruídos de fundo. Esse processo pode melhorar o desempenho da segmentação, dificultando assim o aparecimento de descontinuidades, principalmente em bifurcações e em estruturas muito complexas.

Em (MOU et al., 2019), temos uma abordagem que aplica aprendizagem profunda para segmentação. Sobre a saída da rede, que é um mapa probabilístico contendo as probabilidades dos pixels pertencerem a um vaso, é aplicada uma caminhada probabilística para a correção de falhas. A algoritmo verifica possíveis avanços da fronteira dos vasos usando o mapa probabilístico, possibilitando assim a identificação de vasos mais finos e a redução de descontinuidades.

Uma forma interessante de abordar o problema é aplicar tratamentos prévios nas imagens, ou até mesmo adicionar novas validações que possam melhorar a segmentação, como em (HAKIM et al., 2021), onde é adicionado um regularizador baseado nas características de Euler durante o treinamento das redes, o que leva a uma maior preservação da topologia dos vasos e ajuda a encontrar principalmente vasos menores, que em uma rede U-Net padrão seriam detectados com menor acurácia.

Porém nem sempre esses problemas são ocasionados apenas em problemas de exames em 2D, mas também em exames em 3D, como pode ser visto em (HAN et al., 2016) para imagens de angiografia por tomografia computadorizada. A metodologia desenvolvida por Han et al. consiste em utilizar um modelo de vaso sanguíneo definido pelos pontos do eixo medial e dos respectivos diâmetros do vaso nesses pontos. A partir de um ponto semente,

novos pontos que maximizam a probabilidade de ajuste do modelo são adicionados. Se a maior probabilidade encontrada for menor do que um limiar, é verificado se o ponto define uma terminação ou se ocorreu uma descontinuidade nas intensidades do vaso. Para isso, pontos a uma distância menor ou igual a  $T_{th}$  e que representem uma mudança de direção do vaso de no máximo  $T_\theta$  são checados. O ponto com maior intensidade acima de um limiar é adicionado.

Em (MORALES-VARGAS et al., 2018) são estudadas imagens de contraste de padrões de interferência de lasers, modalidade de imageamento utilizada para medir fluxo sanguíneo. Os autores consideram o problema da descontinuidade, porém eles consideram que descontinuidades tendem a ser causadas por ruídos na imagem, e portanto tendem a possuir tamanho muito pequeno. O fechamento dessas descontinuidades é feito por meio de análises na vizinhança imediata (vizinhança-8) dos píxeis.

Também são comuns outras abordagens fora da aplicação de vasos sanguíneos, podendo ser aplicadas técnicas variadas em diversos tipos de exames e aplicações, como em neurônios. (YANG et al., 2020) aborda uma técnica de rede convolucional multinível para segmentação que é auxiliada pelo enaltecimento da imagem através dos autovalores da matriz Hessiana. Ainda seguindo com os neurônios, (CHEN et al., 2015), utiliza um algoritmo de rastreamento chamado APP2, porém aponta que o algoritmo por padrão interrompe o traçado quando se depara com uma descontinuidade. Os autores definem uma técnica pós traçado para corrigir descontinuidades, chamada de SmartTracing. O algoritmo é implementado como um plugin para a aplicação Vaa3D<sup>1</sup>. Nesse algoritmo é aplicado um procedimento de pré-processamento adaptável e de autotreinamento que segmenta a imagem em primeiro plano contendo sinais de neurônios e os voxels de fundo, sendo proposta uma medida de verossimilhança que serve para identificar regiões confiáveis na reconstrução dos neurônios, utilizando alguns algoritmos de rastreamento existentes. Por ser feita a extração de amostras de treino e os traços característicos de forma individualizada, todo o processo é adaptável a diferentes imagens.

Outras pesquisas utilizam a mesma plataforma citada anteriormente. Por exemplo, (LIU et al., 2016) propõe um algoritmo chamado Rivulet, que busca cada ramo por rastreamento reverso (back-tracking) de uma região mais externa até a localização do soma, ou até encontrar outro ramo descoberto anteriormente. É proposto também uma pontuação de confiança para os ramos, sendo assim, os ramos novos só podem se fundir com ramos cuja segmentação possui alta confiabilidade. O ponto que pode se destacar do trabalho é a utilização de vários algoritmos do estado da arte para validação da técnica, e, diferentemente de diversos outros trabalhos, são utilizadas imagens sintéticas. As imagens sintéticas são geradas de forma criteriosa para destacar pontos fracos dos algoritmos utilizados.

Uma abordagem relacionada à segmentação de vasos mas que difere um pouco em sua

<sup>1</sup> <<https://alleninstitute.org/what-we-do/brain-science/research/products-tools/vaa3d/>>

essência, é o rastreamento de partículas, onde é estudado o movimento das partículas em um dado fluido. A principal tarefa em geral é a detecção de pontos relevantes das trajetórias das partículas. Mas as técnicas de rastreo, que utilizam câmeras que monitoram o movimento dessas partículas podem ter perdas de informação, pois pode ser que as partículas se movam entre os quadros capturados, podendo criar assim um *Frame-GAP*, que seria uma perda de informação do rastreo de um quadro para outro. (LI et al., 2008) aborda uma técnica para que seja corrigido isso, principalmente na presença de ruído, utilizando um método de regressão para estimar a posição futura da partícula.

Como mostrado, a maior parte dos artigos e pesquisas relacionadas são orientados à aplicação de técnicas para melhorar o desempenho da segmentação, muitas vezes buscando uma melhora numérica na qualidade da segmentação. O que pode ser visto é normalmente uma busca por melhorar as técnicas em dados já utilizados anteriormente em outras pesquisas, tentando alcançar um desempenho melhor. Por outro lado, não identificamos nenhum trabalho no qual as interrupções são estudadas de forma sistemática. Por exemplo, os trabalhos não definem um método para simular essas interrupções, de tentar identificar quais os parâmetros, tamanhos e variações de intensidade que pode causar ou não essas interrupções nas diferentes técnicas estudadas. Tentar isolar fatores quando utilizado uma base de dados pronta pode ser um problema, já que as análises para a detecção de diferentes variações para um mesmo parâmetro poderiam ser desafiadoras, podendo até mesmo ser influenciados por outros parâmetros.

Essas descontinuidades, por serem resultado de diferentes fatores causadores, podem aparecer de diversas formas que serão estudadas e discutidas na Seção 4.2 e posteriormente serão abordadas também para o aumento de dados na seção 4.6.



---

# Capítulo 4

## Metodologia

---

*Neste capítulo, são abordadas as metodologias para quantificação da dificuldade de segmentação de vasos sanguíneos. Também é descrita uma metodologia de aumento de dados para melhorar a qualidade de algoritmos de segmentação.*

### 4.1 Dados reais utilizados

Durante as análises serão utilizadas imagens reais para a validação das metodologias. As imagens utilizadas pertencem a uma extensa base de dados de microscopia confocal do córtex de camundongos (FREITAS-ANDRADE et al., 2022). Ela é composta por 2641 imagens cujo processo de obtenção é resumido abaixo:

- ❑ Cérebros são removidos do camundongo logo após a eutanásia.
- ❑ Os bulbos olfativos e o cerebelo são removidos.
- ❑ O córtex é colocado em PBS (Solução Salina Tamponada com Fosfato) com o estriado voltado para cima e, em seguida, o corpo estriado e o hipocampo são removidos.
- ❑ Córtices são colocados em 4% PFA (paraformaldeído) durante a noite em um prato de cultura de células de plástico. No dia seguinte, os córtices são embebidos em sacarose a 30%/PBS a 4°C para criopreservação. O córtex deve permanecer na solução de sacarose a 4°C até afundar completamente no fundo do tubo (ou poço da placa).
- ❑ O cérebro crio-protégido é incorporado no composto de temperatura de corte ideal (OCT) em gelo seco dentro de um receptáculo de moldagem e logo após são armazenados os cérebros incorporados a -80°C (até 1 ano para imunofluorescência de alta qualidade).




Figura 4.1 – Imagens extraídas por meio de microscopia confocal por colaboradores da Universidade de Ottawa.

- ❑ Após esse processo é feito o processo de preparação das amostras para captura em microscópio, sendo feita a preparação de soluções especiais em cada lâmina para que seja possível extrair uma boa imagem.
- ❑ É feita a captura utilizando um microscópio Zeiss Axio Imager M2 equipado com uma câmera digital (AxioCam 506 mono) e o módulo Zeiss ApoTome.2 para seccionamento ótico.

Todo o processo detalhado junto com todas as informações químicas e biológicas foram descritas por (FREITAS-ANDRADE et al., 2022), sendo os procedimentos para extração feitos por colaboradores da Universidade de Ottawa, do instituto de pesquisa de cérebro e mente. Exemplos de imagens são mostrados na Figura 4.1.

## 4.2 Método de geração de dados artificiais

Por se tratar de objetos de alta complexidade e variabilidade, trabalhar diretamente com vasos reais para criar variações de interesse pode ser custoso. A criação de vasos artificiais pode ajudar a entender como se comportam algoritmos especializados de segmentação. O estudo da complexidade e dificuldade de geração dos vasos pode ajudar a entender como processar imagens de vasos com maior precisão. Para o estudo, foi criado um método para geração de dados artificiais, facilitando assim entender quais propriedades são relevantes para a identificação de vasos em imagens.

Para que isso fosse possível, foi criado um algoritmo de criação de imagens de vasos sanguíneos, onde são utilizados diversos parâmetros para a criação de vasos com variação da geometria e intensidade. No contexto do algoritmo de geração, o termo região de queda de intensidade (RQI) é utilizado para expressar a área definida para variação de intensidade. Os principais parâmetros do método são ilustrados na Figura 4.2. Eles são:

- ❑ Tamanho da RQI (gs): O tamanho do espaço em que se encontra a falha ou decaimento de intensidade do vaso artificial.




Figura 4.2 – Ilustração de diversos parâmetros do modelo de criação de vasos artificiais.

- ❑ Tamanho da linha (ll): tamanho do vaso artificial em pixels.
- ❑ Posição relativa da RQI (gp): posição relativa da falha ou decaimento em relação ao vaso artificial.
- ❑ Largura da linha (lw): largura do vaso artificial definido em pixels.
- ❑ Posição horizontal da linha na imagem (lp): definição da posição horizontal do centro do vaso artificial.
- ❑ Ângulo (la): o ângulo do vaso em relação à direção vertical.
- ❑ Intensidade da linha (li): intensidade do vaso artificial, sendo definido numa intensidade entre 0 e 255 em escala de cinza.
- ❑ Intensidade do fundo (bi): intensidade do fundo da imagem, sendo definido entre 0 e 255 em escala de cinza.
- ❑ Intensidade da RQI (gi): intensidade mínima relativa em que o decaimento deve chegar no centro da descontinuidade.
- ❑ Curvatura (cw): curvatura do vaso. O valor 0 representa um vaso reto.

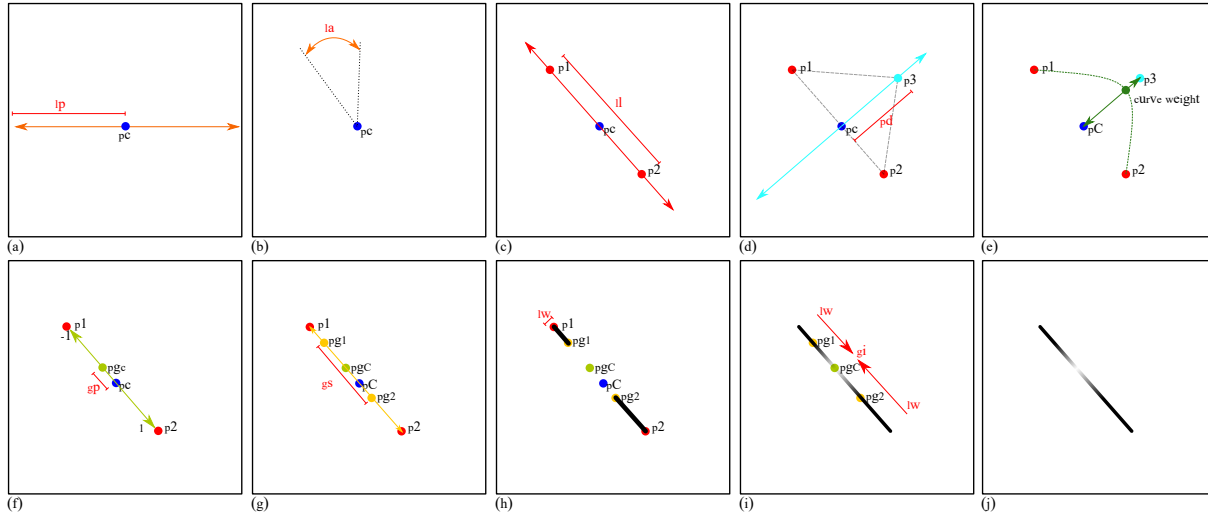


Figura 4.3 – Ilustração das etapas da metodologia de criação de vasos com descontinuidades.

- Distância do ponto de curva (pd): distância entre o centro da região de curva e uma linha reta passando entre o ponto inicial e final do vaso.

A geração de um vaso com RQI é realizada através de diversas etapas. A Figura 4.3 ilustra essas etapas. Primeiramente, é definida a posição do vaso, que pode variar ao longo do eixo horizontal. A posição é definida pela distância  $lp$ , que define um ponto de referência chamado  $pc$  (Figura 4.3(a)). O ângulo do vaso em relação à direção vertical é dado pelo parâmetro  $la$  (Figura 4.3(b)). Com base no ângulo e no comprimento  $ll$  do vaso são calculados os pontos  $p_1$  e  $p_2$  (Figura 4.3(c)), que são as extremidades do vaso. Para o cálculo de  $p_1$  é utilizada a fórmula

$$p_{1x} = pc_x - \frac{ll \times \cos(la)}{2} \quad (4.1)$$

$$p_{1y} = pc_y - \frac{ll \times \sen(la)}{2} \quad (4.2)$$

onde os subscritos  $x$  e  $y$  indicam as coordenadas de cada ponto nos eixos  $x$  e  $y$ . O ponto  $p_2$  é calculado como

$$p_{2x} = pc_x + \frac{ll \times \cos(la)}{2} \quad (4.3)$$

$$p_{2y} = pc_y + \frac{ll \times \sen(la)}{2}. \quad (4.4)$$

Após a definição dos três pontos iniciais do vaso, é iniciada a fase de cálculo da curva que pode ser vista na Figura 4.3(d), onde é utilizado o parâmetro  $pd$  para a definição do

ponto  $p_3$  com base na fórmula  $p_3 = pc + pd\vec{n}$  onde  $\vec{n}$  é um vetor normal à reta entre  $p_1$  e  $p_2$ . Os pontos  $p_1$ ,  $p_2$  e  $p_3$  são utilizados para definir uma curva de Bézier (Figura 4.3(e)), na qual o parâmetro  $cw$  ajusta a curvatura. Quanto maior o valor de  $cw$ , menos suave a curva vai ser. O tamanho final da curva  $lc$  é então calculado. Na sequência, são calculados todos os pontos presentes no vaso. Para facilitar o entendimento do modelo, na Figura 4.3 os próximos passos do modelo serão ilustrados considerando  $pd = 0$ .

Com a curvatura definida e os pontos calculados, o próximo passo é definir a posição da RQI,  $pgc$ , através do parâmetro  $gp$  (Figura 4.3(f)).  $pgc$  é calculado de forma relativa ao vaso,  $gp$  pode receber valores entre -1 e 1, onde -1 indica que  $pgc = p_1$  e 1 resulta em  $pgc = p_2$ . Note que o intervalo de valores entre -1 e 1 representa um eixo referenciado ao vaso, que é utilizado também em outros cálculos. Valores definidos nesse eixo serão chamados de *relativos ao vaso*. Usando o parâmetro  $gs$  é calculado o tamanho da RQI na curva final com a fórmula  $tgp = \frac{2(gs \times IC)}{lc}$ , onde  $IC = lc/ll$  representa a razão de aumento do tamanho da linha devido à curvatura adicionada. Na sequência são calculados os pontos  $pg_1$  e  $pg_2$ , sendo que  $pg_1 = gp - tgp/2$  e  $pg_2 = gp + tgp/2$ , que são as delimitações da RQI, definidos de forma relativa ao vaso e a  $pgc$ . A Figura 4.3(g) mostra os pontos calculados.

Após serem definidos todos os pontos do eixo medial do vaso, é iniciada a construção das intensidades do vaso. A intensidade do vaso fora da RQI (de  $p_1$  até  $pg_1$  e de  $pg_2$  até  $p_2$ ) é dada por  $li$ , e o vaso possui espessura  $lw$  (Figura 4.3(h)). O último passo é definir o decaimento de intensidade na região da RQI. A fórmula utilizada para calcular as intensidades de cada ponto da RQI é dada por

$$I(px) = \frac{(li - gi)}{(pg_1 - gp)^2} \times (px - gp)^2 + gi \quad (4.5)$$

onde  $I$  é a intensidade do ponto e  $px$  é a posição ao longo da RQI. Dessa forma, o valor inicial de intensidade da RQI é  $li$  em  $pg_1$  e  $pg_2$ , o mesmo da linha, e a intensidade decai quadraticamente até atingir o valor  $gi$  no centro da RQI (posição  $gp$  relativa ao vaso). A Figura 4.3(i) ilustra o decaimento. Note que  $gp$  é a posição do centro da RQI relativa ao vaso, que é equivalente à posição  $pgc$  definida em coordenadas absolutas.  $gi$  é definido como  $gri + bi$  de forma que  $gri$  controla a diferença de intensidade entre o mínimo da RQI e o fundo da imagem (com intensidade dada por  $bi$ ). A imagem final é mostrada na Figura 4.3(j).

A Figura 4.4 apresenta alguns exemplos de vasos artificiais gerados pelo algoritmo para ilustração.




Figura 4.4 – Imagens obtidas por meio do algoritmo de geração de imagens desenvolvido. No exemplo podemos ver em (A) uma imagem gerada com ângulo de  $45^\circ$ , curvatura com  $cw = 3$  e  $pd = 50$ , com tamanho de RQI de 200 e intensidade de 10, já em (B) temos uma imagem gerada com angulo de  $90^\circ$ , RQI de tamanho 100 e curvatura zerados e em (C) temos a mesma parametrização de (B) porém com parâmetro de curva de (A).

### 4.3 Análise de descontinuidades utilizando vasos artificiais

Redes neurais serão testadas para diferentes características de vasos sanguíneos gerados pelo modelo artificial. Investigaremos diversas situações para verificar até que ponto a rede neural treinada em determinado conjunto de vasos generaliza para vasos com características distintas. Por exemplo, verificaremos se uma rede treinada em vasos possuindo pequenas RQIs conseguem segmentar corretamente vasos com grandes RQIs. De forma similar, verificaremos se redes treinadas em vasos majoritariamente retos apresentam bons resultados em casos com alta curvatura. A investigação proposta envolverá variar parâmetros do modelo, de forma isolada e também de forma conjunta.

Com a finalidade de testar o modelo de geração de vasos e a segmentação utilizando CNNs, nossos experimentos envolvem a segmentação de vasos possuindo diferentes ângulos. É esperado que uma rede treinada para vasos possuindo um ângulo específico não generalize bem para vasos em outros ângulos. Em contrapartida, ao treinarmos uma rede com vasos possuindo diferentes ângulos é esperado que o resultado tenha uma melhora significativa.

### 4.4 Quantificação da saliência de vasos sanguíneos

A avaliação de imagens utilizando métricas como a IoU se mostra ineficaz quando se avalia imagens reais sem o conhecimento das áreas que podem ser mais problemáticas. A IoU pode mostrar uma boa segmentação na imagem completa, mas pode não revelar deficiências de métodos de segmentação em regiões de vasos possuindo baixa saliência.

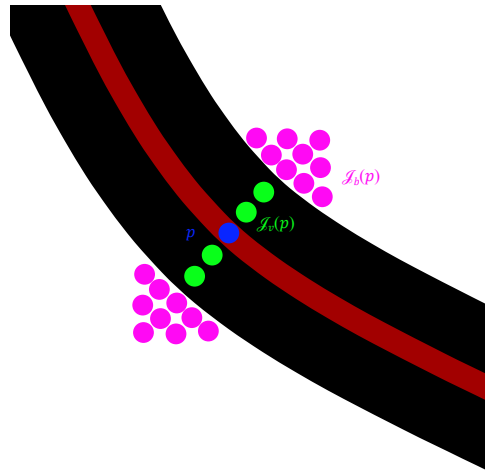


Figura 4.5 – Ilustração do processo de cálculo de intensidades locais do vaso e do fundo em torno de um ponto  $p$  (mostrado em azul). Os pixels pertencentes às retas de menor comprimento entre  $p$  e as bordas do vaso são mostrados em verde. Os pixels de fundo da imagem próximos aos pixels de contorno são mostrados em rosa.

Tais regiões podem ser pequenas comparadas ao restante da imagem. Para que seja possível identificar vasos pouco salientes, foi desenvolvida uma métrica que busca avaliar a complexidade de segmentação de cada pixel para cada segmento de vaso da imagem. O cálculo da métrica assume que é dado como entrada uma imagem em nível de cinza de vasos sanguíneos e também uma imagem de rótulos manualmente anotada indicando quais pixels pertencem aos vasos e ao fundo da imagem.

O primeiro passo para o cálculo da métrica é a obtenção de um grafo representando os vasos de uma imagem. Nesse grafo, os nós representam bifurcações e terminações de vasos e arestas conectam nós possuindo segmentos de vasos entre as respectivas bifurcações e terminações. Para a obtenção do grafo foi utilizado o pacote Pyvane <sup>1</sup>. Uma descrição detalhada da metodologia utilizada pelo Pyvane para a criação do grafo é descrita em (FREITAS-ANDRADE et al., 2022). Cada aresta do grafo gerado pelo Pyvane possui informação sobre o respectivo segmento de vaso representado pela aresta. A principal informação que utilizaremos nas análises são os pixels pertencentes ao eixo medial do vaso, que é uma curva que passa pelo centro do segmento de vaso.

Dado um segmento de vaso, o processo para a quantificação da saliência está ilustrado na Figura 4.5. Para cada pixel  $p$  do eixo medial é calculado o ponto de borda mais próximo em cada extremidade do vaso. Duas retas são então criadas entre o pixel do eixo medial e os dois pixels de borda. Os pixels pertencentes a essas retas,  $L_v(p)$ , representam uma seção do vaso na posição do pixel de referência, e serão utilizados para o cálculo da intensidade média do vaso nesta posição. Representaremos o conjunto de intensidades desses pixels como  $\mathcal{I}_v(p)$ .

<sup>1</sup> <<https://github.com/chcomin/pyvane>>




Figura 4.6 – Exemplo de expansão dos valores do eixo medial.

As intensidades dos píxeis de fundo próximos ao ponto  $p$  também são calculadas. Para isso, todos os píxeis de fundo com uma distância Euclideana menor ou igual a  $r$  em relação aos dois píxeis de contorno são identificados. Esses píxeis serão representados como  $L_b(p)$ . As intensidades desses píxeis são armazenadas em um conjunto  $\mathcal{I}_b(p)$ .

A saliência é calculada utilizando as intensidades obtidas. Primeiro, são obtidas as médias dos valores  $I_v(p) = \text{média}(\mathcal{I}_v(p))$  e  $I_b(p) = \text{média}(\mathcal{I}_b(p))$ . A diferença relativa entre os valores de vaso e fundo é então calculada como

$$\Delta I(p) = \frac{I_v(p) - I_b(p)}{\max(I_v(p), I_b(p))} \quad (4.6)$$

O valor de  $\Delta I(p)$  está relacionado com a dificuldade em segmentar determinado pixel. Valores pequenos de  $\Delta I(p)$  indicam vasos muito parecidos com o fundo. Como  $\Delta I(p)$  é uma medida para cada pixel do eixo medial, verificamos experimentalmente que em alguns casos os valores dessa medida tenderam a apresentar flutuações. Para tornar a medida mais suave, realizamos a média dos valores de píxeis próximos a  $p$ , definindo a métrica chamada de *saliência local de vaso* (LVS, do inglês local vessel saliency):

$$\text{LVS}(p) = \frac{1}{2k+1} \sum_{i=p-k}^{i=p+k} \Delta I(p). \quad (4.7)$$

O processo descrito possibilita calcular a LVS para píxeis do eixo medial, mas nosso objetivo é definir um valor para cada pixel do vaso. Isso é feito da seguinte forma. Para cada pixel do vaso, o pixel do eixo medial mais próximo a ele é encontrado, e o valor de LVS deste pixel é atribuído ao pixel do vaso. Esse processo representa uma expansão dos valores de LVS do eixo medial para o restante do vaso. A Figura 4.6 ilustra a expansão.

## 4.5 Métrica para avaliação da segmentação de vasos pouco salientes

Baseando-se na métrica LVS desenvolvemos também uma métrica para quantificar a qualidade de um algoritmo de segmentação em regiões de difícil identificação de vasos. A medida é baseada na métrica de revocação, mas focada em regiões de baixa LVS. A revocação, definida na Equação 2.2, quantifica a fração de píxeis pertencentes a vasos sanguíneos que são corretamente recuperados por um algoritmo de segmentação. Mas como já discutido, alguns píxeis são mais difíceis de segmentar do que outros. Portanto, definimos uma métrica, chamada de revocação em baixa saliência (LSRecall, do inglês *low-salience recall*), capaz de avaliar a qualidade de segmentação dependendo do grau de dificuldade da tarefa.

É assumido como entrada a imagem original em nível de cinza, uma imagem binária contendo a anotação manual dos vasos (imagem de rótulos) e outra imagem binária contendo o resultado da segmentação de um algoritmo. Primeiramente, o valor de LVS para cada pixel é calculado utilizando o procedimento descrito na Seção 4.4. É feita então uma filtragem na anotação manual na qual apenas píxeis de vaso com LVS abaixo de um limiar  $t$  são mantidos. O limiar é um valor no intervalo  $[0, 1]$  indicando o grau de dificuldade dos píxeis a serem considerados na métrica. O resultado é uma nova imagem binária de rótulos que será utilizada para quantificar a qualidade do resultado do algoritmo. Essa nova imagem é utilizada no cálculo da revocação ao invés da imagem de anotação manual original. Dessa forma, é obtido um valor de revocação considerando apenas píxeis com baixa LVS, definindo a métrica de LSRecall.

A métrica pode ser utilizada principalmente para casos onde a segmentação pode ter pequenas alterações não identificadas por métricas comuns. Na Imagem 4.7 é mostrado um exemplo, sendo (a) a imagem anotada manualmente e (b) a imagem original com uma marcação de destaque para a área que vai ser abordada. Em (c) e (d) são mostrados dois possíveis resultados de segmentação. Em ambos o valor da revocação tradicional será próximo de 1, indicando uma segmentação quase perfeita, mas é possível notar que uma das segmentações gerou descontinuidade em um seguimento de vaso.

A métrica proposta possibilita avaliar a qualidade da segmentação especificamente em regiões de difícil segmentação. Nesse caso, apenas regiões do vaso de baixa saliência são consideradas. Com isso, a diferença de qualidade entre os resultados mostrados nas Figuras 4.7(c) e (d) será maior.

A métrica se mostra muito relevante para avaliar a qualidade de algoritmos de segmentação em relação à preservação da continuidade dos vasos e à identificação de vasos pouco salientes.




Figura 4.7 – Motivação para a métrica de revocação em regiões difíceis. (a) Anotação manual. (b) Imagem original. (c) Resultado de um algoritmo de segmentação. (d) Outro possível resultado de um algoritmo de segmentação, no qual apenas uma pequena região de difícil identificação foi alterada.

## 4.6 Método de aumento de dados para geração de vasos pouco salientes

O avanço dos algoritmos de redes neurais e aprendizado de máquina tem criado diversos desafios para o aperfeiçoamento e melhoria constante dos modelos, onde o principal fator é a qualidade e variabilidade dos dados de treinamento. Com isso, é cada vez mais necessário o uso de algoritmos de criação de dados artificiais ou aumento de base de dados reais, criando assim uma base mais robusta e com desempenho melhorado.

Pensando nisso foi desenvolvido um algoritmo de aumento de dados baseado na criação dos vasos artificiais apresentado na seção 4.2. O algoritmo consiste em reduzir aleatoriamente a intensidade de segmentos de vasos, de forma a tornar uma rede neural mais robusta a variações na saliência de vasos em imagens. O algoritmo também permite a criação de descontinuidades nos vasos, que são regiões possuindo intensidade igual ao fundo da imagem.

Para explicar o algoritmo consideraremos primeiro um segmento de vaso específico a ser alterado e parâmetros fornecidos para controlar a alteração. Posteriormente apresentaremos os parâmetros aleatórios do processo para realizar o aumento de dados. A alteração de um segmento de vaso possui dois parâmetros. O parâmetro  $l$  define o comprimento total da região a ser alterada enquanto que o parâmetro  $l_d$  controla o comprimento da descontinuidade a ser criada. É importante salientar que as distâncias calculadas na implementação do método consistem em distâncias ao longo do segmento (comprimento de arco) e não a distância mínima entre dois pontos.

Primeiramente, um pixel  $p_c$  do segmento a ser alterado é sorteado aleatoriamente. Apenas píxeis com distância de arco maior ou igual a  $l/2$  em relação às terminações do segmento são considerados no sorteio para garantir que será possível criar a região de queda. Na sequência, os dois píxeis a uma distância  $l/2$  de  $p_c$  em ambas as direções do segmento são identificados. Esses píxeis são representados como  $p_1$  e  $p_2$  e indicam o início




Figura 4.8 – Exemplo de modificação de um segmento. (a) São mostrados os pontos relevantes para a alteração de um segmento,, onde são os pontos definidos no método para a modificação do segmento. (b) Resultado final da alteração do segmento. O algoritmo consiste em remover parte do segmento designado para que seja haja mais dificuldade ao segmentar.

e fim da região de queda de intensidade. A Figura 4.8(a) ilustra os píxeis utilizados. De forma similar, dois píxeis  $p_{d1}$  e  $p_{d2}$  a uma distância  $l_d/2$  de  $p_c$  são identificados. Esses píxeis indicam o começo e fim da região de descontinuidade.

É definido um fator de preservação de intensidade indicando o quanto da intensidade original do vaso será preservada. O fator de preservação entre os píxeis  $p_1$  e  $p_{d1}$  é dado por

$$f_1(p_i) = \frac{d(p_i, p_{d1})}{d(p_1, p_{d1})} \quad (4.8)$$

onde  $p_i$  representa um pixel no eixo medial do vaso e  $d(p_x, p_y)$  representa o comprimento de arco entre dois píxeis. Intuitivamente,  $f_1 = 1$  no pixel  $p_1$  e  $f_1 = 0$  no pixel  $p_{d1}$ . Uma definição similar é feita para o fator de preservação  $f_2$  entre os píxeis  $p_2$  e  $p_{d2}$ . Entre os píxeis  $p_{d1}$  e  $p_{d2}$  o fator de preservação é definido como zero. Um fator de preservação geral  $f$  é então definido para todos os píxeis do eixo medial, que é então expandido para os demais píxeis do vaso de forma similar ao realizado no cálculo da LVS na Seção 4.4. Um exemplo de fator de preservação é mostrado na Figura 4.9(a).

As intensidades são então transformadas usando o fator de preservação. A intensidade mínima deve ser similar ao fundo da imagem na região do vaso. Para isso, o valor médio  $I_b$  da intensidade do fundo da imagem na região do segmento é calculado. A região considerada na média consiste em uma região retangular delimitando os limites do segmento a ser alterado. As intensidades são então transformadas como

$$\hat{I}(p) = f(I(p) - I_b) + I_b. \quad (4.9)$$

onde  $I(p)$  representa a intensidade de um pixel  $p$ . A intensidade resultante representa

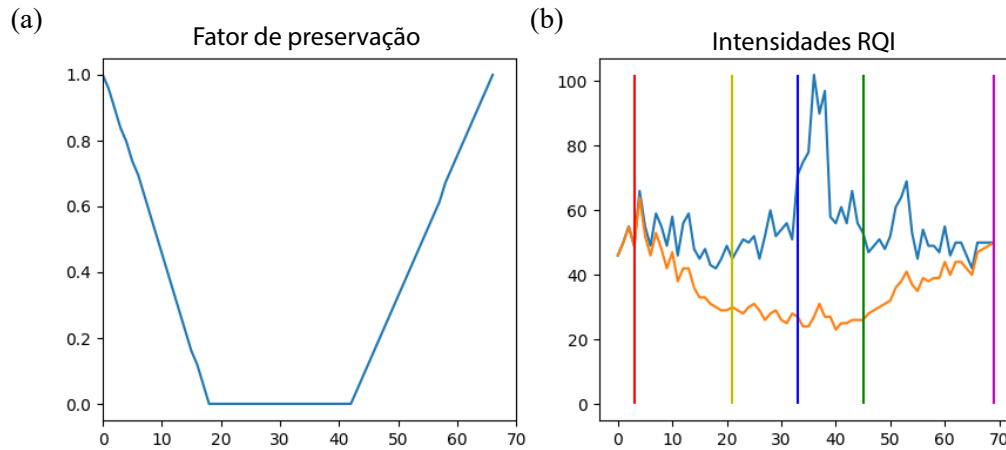


Figura 4.9 – Exemplo de queda de intensidade de um segmento. (a) Fator de preservação de intensidade. (b) Intensidade original (azul) e intensidade após a redução (laranja) ao longo do segmento. São também mostradas as posições dos pontos indicados na Figura 4.8(a).

uma RQI similar à utilizada no algoritmo de geração de vasos artificiais. A Figura 4.9(b) apresenta um exemplo de decaimento de intensidade.

A região de descontinuidade possuirá valor  $I_b$  após a aplicação do fator de preservação. É interessante que essa região seja o mais parecida possível com o fundo da imagem, inclusive com textura similar. Para isso, é buscada uma região de fundo possuindo o mesmo tamanho que a região de descontinuidade. Um critério de similaridade é utilizado para identificar regiões parecidas com o fundo local do segmento sendo processado. O critério consiste em calcular a diferença média entre as intensidades do contorno externo da região de descontinuidade e as intensidades da região de fundo candidata. Um fundo com diferença menor do que um limiar pré-estabelecido é então inserido na região de descontinuidade. Usualmente, o limiar utilizado é em torno de 2 ou 3 para imagens com intensidade no intervalo  $[0,255]$ . A Figura 4.8.(b) mostra o resultado final do segmento alterado após todo o processo.

O processo foi descrito para um segmento específico. O aumento de dados durante o treinamento de uma rede neural é realizado da seguinte forma. O número de segmentos a serem alterados em uma imagem é sorteado dentro de um intervalo que é parâmetro do modelo. Na sequência, os valores de  $l$  e  $l_d$  são sorteados dentro de um intervalo. Um segmento com tamanho maior que  $l$  é então sorteado e alterado segundo o procedimento descrito.

---

# Capítulo 5

## Resultados

---

*Este capítulo apresenta os resultados das metodologias propostas. Primeiramente, serão apresentados os resultados relativos ao modelo de geração de vasos. Na sequência, as medidas de saliência e revocação de vasos pouco salientes serão calculadas para a base de imagens. Ao final do capítulo, serão apresentados os resultados relativos à metodologia de aumento de dados.*

### 5.1 Geração de Imagens Artificiais

Para mostrar a generalidade do algoritmo de geração de vasos, na Figura 5.1 são mostrados diferentes vasos gerados. Em (a) é possível notar uma imagem simples, onde a RQI tem uma queda de intensidade muito baixa comparada ao restante do vaso, e o vaso não possui curvas. Essa imagem é simples de ser segmentada. Já em (b) o vaso possui maior complexidade, com uma curva muito acentuada, mas ainda com a intensidade na região de descontinuidade muito próxima ao restante do vaso, com um tamanho de RQI pequeno. Em (c) pode ser notado uma mudança mais brusca de intensidade, causando assim um problema maior que os anteriores, mas a RQI é relativamente pequena e ela está localizada em uma região na qual o vaso é reto.

Em (d) temos um vaso menor, com uma curva bem acentuada e com uma RQI muito perto da ponta, sendo muito complexo para alguns cenários de testes identificar o vaso todo. É possível que em diversos testes a parte direita do vaso seja segmentada incorretamente. Já em (e) é possível identificar uma grande RQI, com intensidade muito próxima ao fundo em uma boa parte do vaso, estando bem no centro da curva, podendo assim criar uma ambiguidade para muitos algoritmos. Já na última imagem (f) temos um dos casos mais desafiadores, onde é possível identificar uma grande quantidade de ruído, muitas vezes se confundindo com parte do vaso, principalmente na parte da RQI, que se encontra muito perto do centro da curva, até mesmo olhares mais atentos podem ter problemas




Figura 5.1 – Exemplos de imagens criadas pelo algoritmo de geração de vasos artificiais.

para identificar como sendo um único vaso. A dificuldade é causada pelo vaso ter um diâmetro muito grande e uma suavização muito alta, fazendo ele dispersar pelo ruído muito facilmente.

O modelo se mostra com grande potencial para o estudo da robustez de redes neurais em relação a descontinuidades de vasos. No restante desta seção apresentaremos uma análise inicial exemplificando o uso do modelo para o estudo da performance de redes neurais. Uma análise mais sistemática é proposta como trabalhos futuros.

Para a análise, foram feitos experimentos variando as características dos vasos do conjunto de treinamento e teste. Foi utilizada a rede neural UNet (ZHANG et al., 2020) devido à sua aplicabilidade em segmentação de imagens complexas, principalmente relacionadas à saúde (RAHMAN et al., 2022) e da área de imagens de satélites (DIAKOGIANNIS et al., 2020), mas também pela sua facilidade de utilização, já que existem diversas implementações dessa arquitetura disponíveis.

A rede é treinada em um conjunto de imagens de treinamento possuindo vasos gerados com determinados valores do parâmetro de interesse. Após o treinamento, a rede é aplicada em um conjunto de teste possuindo vasos gerados com outros valores do mesmo parâmetro, para que se entenda se a segmentação realizada pela rede neural generaliza bem para vasos distintos dos utilizados no treinamento.

O experimento inicial foi verificar se redes treinadas com vasos posicionados em deter-



Figura 5.2 – Exemplos de imagens geradas utilizando diferentes ângulos.

minado ângulo de inclinação generalizam para vasos em outros ângulos. Primeiramente, foram geradas 10 imagens de vasos posicionados em um ângulo de  $45^\circ$ . As respectivas segmentações ideais também foram geradas. Para evitar um resultado trivial, os vasos foram gerados em diferentes posições da imagem, sendo que a posição ao longo do eixo horizontal (coluna da imagem) foi sorteada aleatoriamente e a posição vertical (linha da imagem) foi fixada no centro da imagem. Após experimentos iniciais, foi observado que a posição do vaso não influenciou no resultado, como esperado pelo uso de CNNs. Os demais parâmetros do método foram fixados nos seguintes valores:  $gs=60$ ,  $ll=200$ ,  $gp=0$ ,  $lw=2$ ,  $lp=100$ ,  $li=150$ ,  $bi=20$ ,  $gri=10$ ,  $cw=0$ ,  $pd=0$  e  $gi=10$ .

A rede neural foi treinada por 75 épocas nessas imagens. Na sequência, imagens possuindo vasos em diferentes ângulos foram geradas, e utilizadas para testar a qualidade da segmentação pela rede neural. A Figura 5.2 mostra exemplos de vasos gerados. Como apresentado na seção 2.3, para quantificar a qualidade da rede utilizamos a métrica IoU no vaso todo e também a métrica IoU calculada apenas para a RQI. É importante notar que, dada a simplicidade das imagens analisadas, são esperados valores altos de IoU. Os resultados principais desse experimento são apresentados na Tabela 5.1.

É possível verificar que imagens de teste possuindo vasos em ângulos diferentes dos utilizados no treinamento resultam em valores relativamente baixos de IoU, pois a rede neural não adquiriu invariância à rotação. A rede treinada com vasos em dois ângulos distintos obteve valores ligeiramente maiores do que a rede treinada em apenas um ângulo.

Na sequência, verificamos se a rede treinada em vasos retos e com ângulos específicos é capaz de segmentar vasos possuindo curvatura. Os vasos de treinamento foram gerados com os mesmos parâmetros do experimento anterior. Para os vasos de teste foram definidas 6 configurações de parâmetros. A Figura 5.3 mostra exemplos de vasos gerados para cada configuração. Na tabela 5.1 são mostrados os parâmetros utilizados e os resultados para cada tipo de vaso.

Na configuração (1) a rede foi treinada com vasos retos e com ângulos de  $45^\circ$ , e as

Parâmetro	Tipo Treino	Valor teste	IOU RQI	IOU IMG
Ângulo	$\theta = 45$	$\theta = 45$	1.000	0.994
Ângulo	$\theta = 45$	$\theta = 90$	0.235	0.234
Ângulo	$\theta = 45$	$\theta = 50$	0.957	0.946
Ângulo	$\theta = 45$	$\theta = 60$	0.883	0.854
Ângulo	$\theta = 45$	$\theta = 70$	0.786	0.764
Ângulo	$\theta = 45$	$\theta = 80$	0.623	0.618
Ângulo	$\theta = 90/0$	$\theta = 90$	1.000	1.000
Ângulo	$\theta = 90/0$	$\theta = 0$	1.000	1.000
Ângulo	$\theta = 90/0$	$\theta = 45$	0.871	0.871
Ângulo	$\theta = 90/0$	$\theta = 135$	0.964	0.964
Ângulo	$\theta = 90/0$	$\theta = 60$	0.903	0.906
Ângulo	$\theta = 90/0$	$\theta = 75$	0.957	0.944

Tabela 1 – Qualidade da segmentação para diferentes ângulos de treinamento e teste dos vasos. A coluna IoU RQI indica a métrica IoU calculada apenas para a região do RQI, enquanto a coluna IoU img indica a métrica calculada para todo o vaso.

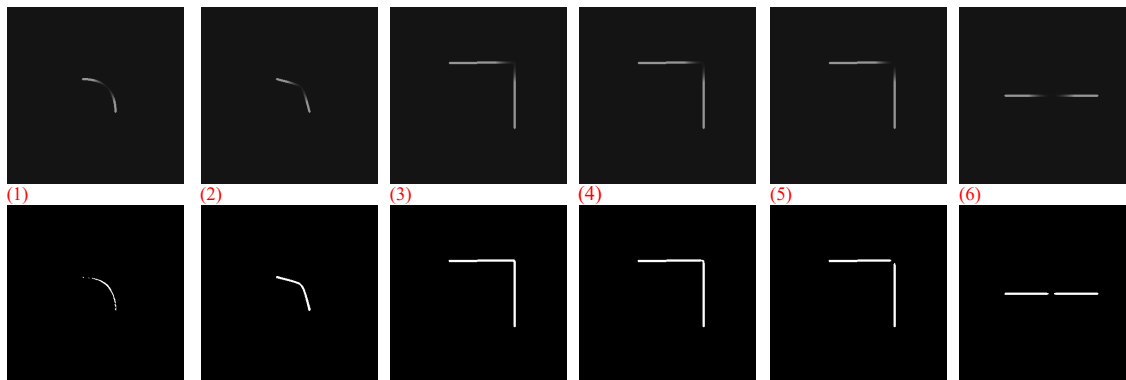


Figura 5.3 – Imagens geradas com diversas variações de parâmetros expressos na Tabela 2. Na primeira linha de imagens são mostradas as imagens geradas e na segunda o resultado da aplicação da rede.

imagens de teste possuem vasos com pequenas curvaturas. Vemos que a IoU da segmentação foi muito baixa, ou seja, a rede não foi capaz de generalizar o treinamento com vasos retos para a segmentação de vasos curvos. Observamos até mesmo uma falha de segmentação onde não há queda de intensidade, ou seja, mesmo sem queda de intensidade pode surgir descontinuidades graças a outras características do vaso. Na configuração (2) a rede foi treinada com vasos retos a  $0^\circ$  e  $90^\circ$ , e testada em imagens similares às da configuração (1). É interessante verificar que nesse caso as segmentações possuíam boa qualidade. Portanto, o treinamento com vasos retos em diferentes ângulos parece possibilitar que a rede generalize para vasos com pequenas curvas.

Ao decorrer dos testes foi percebido que a alteração do tamanho do RQI, aliado a baixas intensidades, pode gerar uma maior chance de erros de segmentação. É interessante

Parâmetro	Tipo Treino	Valor teste	IOU RQI	IOU IMG
Configuração (1)	$\theta = 45$	$\theta = 45/pd=50/cw=1/ll=100$	0.513253	0.451197
Configuração (2)	$\theta = 90/0$	$\theta = 45/pd=30/cw=5/ll=100$	0.933174	0.926391
Configuração (3)	$\theta = 90/0$	$\theta = 45/pd=100/cw=100$	0.994186	0.992313
Configuração (4)	$\theta = 90/0$	$\theta = 45/pd=100/cw=100/gi=5$	0.970874	0.983916
Configuração (5)	$\theta = 90/0$	$\theta = 45/pd=100/cw=100/gi=1$	0.862136	0.944755
Configuração (6)	$\theta = 90/0$	$\theta = 90/gs=100/gi=1$	0.882353	0.928994

Tabela 2 – Qualidade da segmentação obtida para diferentes combinações de parâmetros do modelo de vaso no conjunto de treinamento e teste. Na tabela é expresso o valor de IoU para toda a imagem e também para a RQI. Os números mostrados entre parênteses na coluna “Parâmetro” são referentes às configurações mostradas na Figura 5.3.

verificar a influência da intensidade mínima da RQI,  $g_i$ , na segmentação. Essa variação é realizada nas configurações (3), (4) e (5). É possível constatar que aumentar a intensidade do centro do RQI pode ajudar a remover problemas de segmentação até mesmo em curvas mais acentuadas, podendo assim ser necessário apenas algum tipo de tratamento prévio nas imagens, como enaltecimento de estruturas finas, para que seja obtido um resultado mais satisfatório.

Na configuração (6) consideramos vasos retos no conjunto de teste mas com uma grande RQI. Nesse caso o IoU é relativamente alto, mas é criada uma descontinuidade na segmentação, separando o vaso em dois.

Com os resultados obtidos nos testes foi possível constatar que aumentar a variedade de intensidades, ângulos e áreas de queda de intensidade pode ajudar a rede a melhorar seus resultados. Os experimentos realizados com o modelo serviram de base para o desenvolvimento do restante do trabalho. Em especial para o desenvolvimento do método de aumento de imagens.

## 5.2 Análise da saliência local de vasos

A utilização de métricas tradicionais para avaliar erros de segmentação se mostra de grande valia para imagens simples. Porém, para imagens complexas com estruturas irregulares, estruturas finas e em grande quantidade, métricas comuns como IoU podem se mostrar ineficientes, principalmente em casos onde apenas pequenas partes da imagem são afetadas. A criação da métrica de saliência local de vasos objetiva uma avaliação de performance mais precisa, possibilitando quantificações mais realistas de melhorias nos treinos de redes em imagens com problemas de segmentação.

A Figura 5.4 mostra resultados do cálculo da LVS para seis imagens de exemplo. Os resultados mostram que segmentos de vasos possuindo alta similaridade com o fundo da imagem tendem a possuir menor valor de LVS. Na última linha de figuras é indicado




Figura 5.4 – LVS para algumas imagens de exemplo. A primeira linha de figuras mostra as imagens originais, a segunda mostra a LVS calculada para cada pixel de vaso. Na terceira linha são mostradas em vermelho as regiões com LVS abaixo de 0,2. As regiões são indicadas apenas no esqueleto para que seja possível ver com mais facilidade o restante do vaso.

em vermelho os píxeis com LVS menor que 0,2. Muitos desses segmentos são quase imperceptíveis nas imagens originais. Segmentos com alta LVS são simples de serem identificados, e portanto é interessante que a análise de performance foque nos segmentos mais desafiadores.

Na Figura 5.5 estão mostradas regiões de baixa saliência para diferentes limiares da LVS. O limiar claramente define regiões de diferentes níveis de dificuldade. Um limiar em torno de 0,4 separa os vasos em segmentos de difícil visualização e segmentos facilmente detectáveis.

A LVS é utilizada para calcular o LSRecall, que permite quantificar a qualidade de uma segmentação em áreas de baixa LVS. Para verificar o potencial desta métrica, foi utilizada uma rede neural CNN treinada para segmentar vasos sanguíneos. A rede utilizada se baseia na arquitetura U-Net usando blocos residuais. A arquitetura utilizada é ilustrada na Figura 5.6. A rede foi treinada com um total de 45 imagens aleatoriamente escolhidas do banco de imagens e validada em outras 5 imagens, também escolhidas aleatoriamente. O uso de um treinamento com poucas imagens possui como objetivo representar situações reais nas quais apenas algumas imagens são manualmente anotadas. Depois de treinada, a rede foi aplicada em todo o banco de imagens, totalizando 2641 imagens, incluindo as imagens de treinamento e validação. As imagens de treinamento foram utilizadas nos resultados porque o foco das análises é avaliar a diferença entre diferentes métricas de qualidade, e não nos valores absolutos dessa métricas.




Figura 5.5 – Resultados para diferentes limiares da LVS para uma mesma imagem. Os valores de limiar são indicados acima de cada imagem. Regiões vermelhas indicam segmentos abaixo do limiar.

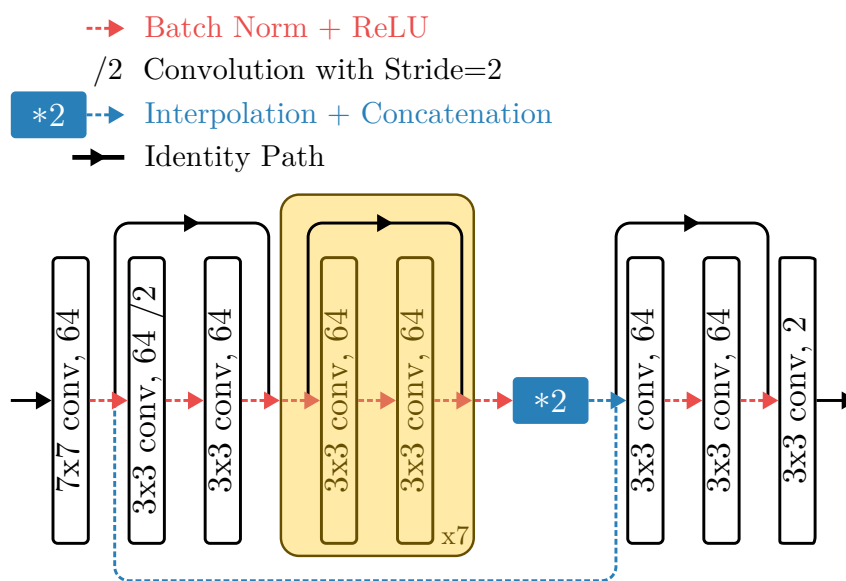


Figura 5.6 – Arquitetura de rede neural utilizada nos experimentos. Observe que as camadas indicadas em amarelo são repetidas 7 vezes.




Figura 5.7 – Resultados referentes à métrica LSRrecall. (a) Comparação entre a revocação (*Recall*) e o LSRrecall obtidos para todas as amostras do conjunto de dados. Cada ponto representa uma amostra. A linha tracejada indica a função  $y = x$ . (b) Média de LSRrecall em função do limiar de saliência usado para calcular a métrica.

A rede foi treinada utilizando 500 épocas, usando uma taxa de aprendizagem de 0,01 com um escalonador de taxa de aprendizagem polinomial e um tamanho de lote de 10 imagens. O otimizador AdamW (LOSHCHILOV; HUTTER, 2019) foi usado com um momento de 0,9. O modelo com menor perda de validação durante o treinamento foi escolhido para os experimentos. Para evitar desequilíbrio de classes, as classes foram ponderadas de acordo com a frequência inversa dos pixels de fundo e vaso para o cálculo da função de perda. O único aumento de dados utilizado consistiu em cortes aleatórios de tamanho  $256 \times 256$  pixels. As imagens foram normalizadas de acordo com o Z-score para cada imagem (ou seja, cada imagem foi normalizada por seu valor de média e desvio padrão). A rede atingiu um valor de IoU de 0,82 em todo o conjunto de dados.

Na Figura 5.7 é mostrada a relação entre a revocação (*Recall*) e o LSRrecall calculado para todas as amostras do conjunto de dados. Um limiar de 0,2 foi utilizado para o cálculo do LSRrecall. Como esperado, imagens com baixa saliência apresentam um pior resultado de segmentação utilizando o LSRrecall, com algumas apresentando resultado igual a zero. Curiosamente, muitas amostras com revocação alta exibem um LSRrecall próximo de 0,2.

O parâmetro de limiar do LSRrecall define a maior saliência a ser considerada ao medir o desempenho da segmentação. A Figura 5.7(b) mostra o LSRrecall médio de todas as amostras no conjunto de dados para diferentes valores de limiar. Há uma tendência clara de que a CNN perca cada vez mais pixels de vaso à medida que o limiar diminui. Quando o limiar é um, o LSRrecall é igual à métrica de revocação.

Ter uma métrica que quantifica o desempenho da segmentação em regiões de baixa saliência permite estudar a influência das alterações de parâmetros na melhoria dos resultados nessas regiões. Uma possível mudança é a inclusão de aumentos de dados

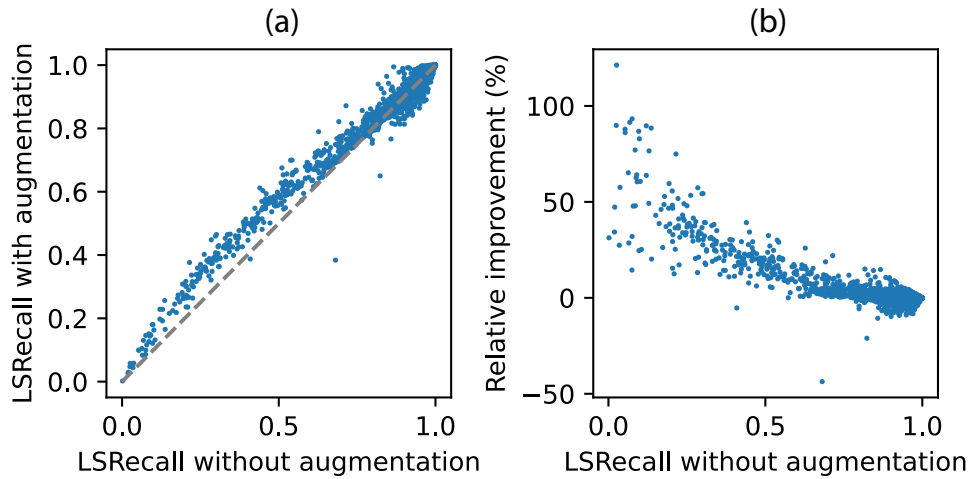


Figura 5.8 – Resultados do aumento de dados. (a) Comparação do LSRecall obtido quando a CNN foi treinada com e sem aumento de dados. (b) Os mesmos dados, porém com  $y$  indicando a melhoria relativa entre os valores de LSRecall. Um limiar de 0,5 foi utilizado para o cálculo do LSRecall.

específicos para tornar o método mais robusto às alterações na intensidade dos vasos sanguíneos. Esta abordagem é estudada a seguir.

### 5.3 Aumento de imagens

Com os testes efetuados na Seção 5.1, foi possível constatar que a variação da aparência dos vasos pode ajudar a criar redes neurais mais robustas. Uma das melhores formas para isso é o aumento de imagens, onde são feitos tratamentos para as imagens terem características marcantes que ajudem a rede a se tornar mais geral.

Para que o método de aumento de imagens pudesse ser avaliado, foi aplicada a mesma rede descrita na Seção 5.2, alterando apenas o aumento de dados com base no algoritmo de diminuição de saliência descrito na Seção 4.6. Para cada imagem, o número de segmentos a serem alterados,  $n$ , é selecionado aleatoriamente com probabilidade uniforme no intervalo  $[50, 100]$ . A seguir, os parâmetros  $l$  e  $l_d$  são selecionados aleatoriamente com probabilidade uniforme nos intervalos  $[20, 100]$  e  $[0, 30]$ , respectivamente. Um segmento com comprimento maior que  $l$  é então selecionado aleatoriamente e o procedimento descrito na Seção 4.6 é aplicado para toda a imagem, até que  $n$  vasos sejam alterados. Um valor de  $t_b = 5$  foi utilizado para encontrar regiões de fundo adequadas para gerar descontinuidades de vasos.

A Figura 5.8(a) mostra uma comparação entre o LSRecall das CNNs treinadas com e sem aumento de dados. Um limiar de 0,5 foi utilizado para o cálculo do LSRecall. O resultado mostra que o procedimento de aumento tende de fato a tornar a CNN mais robusta para vasos sanguíneos com baixa saliência. A diferença absoluta entre os valores de LSRecall tende a ser pequena, mas a diferença tende a ser mais relevante para amostras com baixo LSRecall. Isso pode ser verificado usando uma abordagem alternativa para

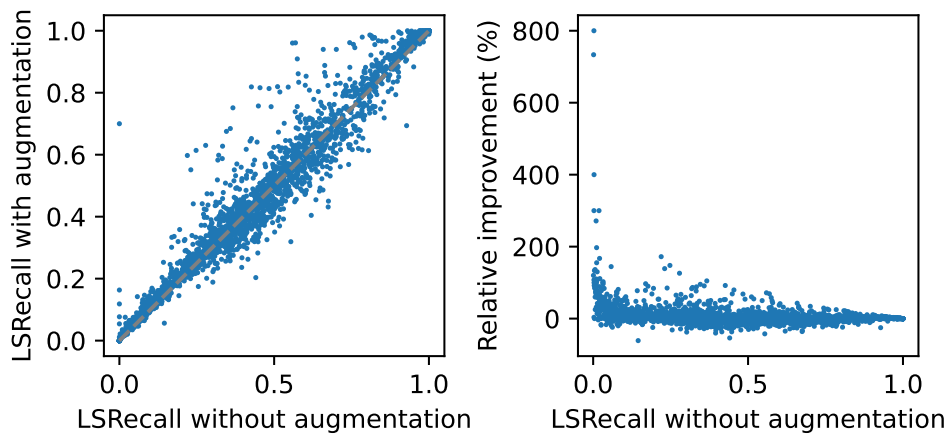


Figura 5.9 – Resultados do aumento de dados para um limiar de 0,05 no cálculo do LSRrecall. (a) Comparação do LSRrecall obtido com e sem aumento de dados. (b) Os mesmos dados, porém com  $y$  indicando a melhoria relativa entre os valores de LSRrecall.

comparar os valores. A Figura 5.8(b) mostra a melhora relativa em LSRrecall usando o aumento plotado como uma função de LSRrecall sem aumento. A melhoria relativa é calculada como a diferença entre os valores de LSRrecall com e sem aumento dividida pelo LSRrecall sem aumento. A figura mostra que o procedimento de aumento melhorou significativamente a precisão para amostras com baixo LSRrecall.

A precisão média (valor preditivo positivo) das CNNs treinadas com e sem aumento foi, respectivamente, 0,72 e 0,73. Assim, a precisão não se alterou significativamente entre os dois procedimentos de treino.

Foi demonstrado assim que a utilização do aumento de imagens leva a melhorias no resultado, e que a métrica LSRrecall permite quantificar de forma precisa tal melhoria. O aumento de qualidade é mais expressivo em regiões de baixo LSRrecall. Um exemplo mais extremo de quantificação em regiões de baixa saliência é mostrado na Figura 5.9, na qual foi utilizado um limiar de 0,05 para o cálculo do LSRrecall. Esse limiar define regiões muito similares ao fundo da imagem. Vemos que o resultado é mais ruidoso do que o obtido com um limiar de 0,5. Provavelmente, isso ocorre porque os vasos são tão similares ao fundo que não há características salientes que os separem claramente do fundo. Nessas regiões pode ocorrer inclusive incertezas nas imagens de rótulos utilizadas como referência para calcular a qualidade da segmentação. Ainda assim, em geral o treinamento com aumento de dados levou a valores maiores de LSRrecall, com muitas amostras apresentando melhorias acima de 100%.

---

## Capítulo 6

# Considerações Finais

---

*Neste capítulo, apresentamos as considerações finais deste trabalho. Retomamos brevemente nossa justificativa inicial e experimentos realizados e apresentamos as análises futuras.*

Após pesquisas, análises e estudos dos problemas envolvendo segmentação de vasos e o problema da descontinuidade, foi possível identificar a importância da melhoria contínua de técnicas e métodos de detecção de vasos sanguíneos. Entretanto, mesmo com uma constante busca por melhoria, a maior parte dos estudos da literatura buscam uma melhora numérica e estatística, onde o principal fator é o índice de acerto calculado por meio da métrica IoU, fator esse que pode camuflar problemas nos resultados, especialmente de descontinuidades nas segmentações.

Por se tratar de uma estrutura fina e complexa, métodos focados em melhoria da IoU tendem a segmentar incorretamente e gerar interrupções nos vasos, muitas vezes não se atentando para a preservação da geometria, que pode ser fator crucial para a análise das imagens dado que propriedades como tortuosidade e quantidade de bifurcações podem estar relacionadas com patologias.

Buscar novas formas de avaliar algoritmos de segmentação se mostra importante para casos onde os vasos apresentam variações de aparência muito grandes. É necessário que se tenha uma métrica robusta e assertiva para que se possa ter certeza se mudanças realizadas em um algoritmo apresentam melhorias ou não. Como foi mostrado ao decorrer do trabalho, a métrica criada se mostra promissora, tendo um grande potencial para aplicações de segmentação.

O aumento de imagens desenvolvido também se mostra promissor para tornar redes neurais mais robustas à variações de aparência de vasos. É interessante notar que se todos os vasos de uma base de imagens possuem baixa saliência, é esperado que uma CNN possua boa performance. Mas problemas surgem quando os vasos apresentam alta

variabilidade de saliência, com alguns vasos sendo difíceis de segmentar. Uma CNN pode apresentar boa performance em geral, pois ela é facilmente treinada para segmentar vasos salientes. Nesses casos, erros sistemáticos em vasos de baixa saliência podem permanecer indetectados. O método de alteração de saliência desenvolvido busca reduzir tais erros.

Em geral a métrica e o aumento de dados mostram sucesso no que foram propostos, mas ainda estão abertos a melhorias. Uma perspectiva interessante é definir a métrica de LSRecall de forma diferenciável, o que permitiria otimizar diretamente uma rede neural para ter o maior valor possível dessa métrica. O uso da métrica LSRecall também se mostra interessante para a realização de comparações entre algoritmos de segmentação da literatura em relação ao grau de preservação da continuidade dos vasos.

A métrica ainda necessita de melhorias, as principais limitações são o custo computacional, que exige muito tempo e recursos para o processamento, sendo ponto interessante para futuros estudos. Também é possível ver um problema na métrica, onde é necessário uma imagem de padrão ouro para comparação e pontuação da segmentação, então esse ponto pode interferir em alguns casos.

Um ponto interessante a ser abordado em futuros trabalhos é a expansão, utilizando a métrica e o aumento de dados para comparação com outros trabalhos no mesmo cenário, comparando outras métricas e outras técnicas de aumento de dados.

A métrica e o aumento de dados pode se mostrar promissor quando expandido também para outros cenários, onde estruturas finas e complexas podem ser estudadas, como ruas em mapas, imagens espaciais, redes de transportes e diversas outras aplicações. Com adaptações, os métodos descritos podem ser utilizados para tais situações.

## 6.1 Contribuições do trabalho

Como resultado desse trabalho, foi disponibilizado um repositório no GitHub para consultas e utilização dos algoritmos criados. O repositório pode ser acessado no endereço [https://github.com/jpparella/vessel\\_algorithm](https://github.com/jpparella/vessel_algorithm). As orientações para uso do código estão presentes no repositório.

Os resultados do trabalho foram submetidos a um periódico internacional. O artigo submetido foi disponibilizado em um repositório aberto (PARELLA; SILVA; COMIN, 2024).

---

## Referências

---

- BAHDANAU, D.; CHO, K.; BENGIO, Y. Neural machine translation by jointly learning to align and translate. **arXiv preprint arXiv:1409.0473**, 2014.
- CAO, K.; LIU, E.; JAIN, A. K. Segmentation and enhancement of latent fingerprints: A coarse to fine ridgestructure dictionary. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, v. 36, n. 9, p. 1847–1859, 2014.
- CHEN, H. et al. Smarttracing: self-learning-based neuron reconstruction. **Brain informatics**, SpringerOpen, v. 2, n. 3, p. 135–144, 2015.
- CHEN, L.-C. et al. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs. **IEEE transactions on pattern analysis and machine intelligence**, IEEE, v. 40, n. 4, p. 834–848, 2017.
- DIAKOGIANNIS, F. I. et al. Resunet-a: A deep learning framework for semantic segmentation of remotely sensed data. **ISPRS Journal of Photogrammetry and Remote Sensing**, Elsevier, v. 162, p. 94–114, 2020.
- DIJKSTRA, K. et al. Centroidnetv2: A hybrid deep neural network for small-object segmentation and counting. **Neurocomputing**, Elsevier, v. 423, p. 490–505, 2021.
- FREITAS-ANDRADE, M. et al. Unbiased analysis of mouse brain endothelial networks from two-or three-dimensional fluorescence images. **Neurophotonics**, SPIE, v. 9, n. 3, p. 031916, 2022.
- FUKUSHIMA, K.; MIYAKE, S. Neocognitron: A self-organizing neural network model for a mechanism of visual pattern recognition. In: **Competition and cooperation in neural nets**. [S.l.]: Springer, 1982. p. 267–285.
- GATOS, B.; STAMATOPOULOS, N.; LOULLOUDIS, G. Icdar2009 handwriting segmentation contest. **International Journal on Document Analysis and Recognition (IJ DAR)**, Springer, v. 14, n. 1, p. 25–33, 2011.
- GU, Z. et al. Ce-net: Context encoder network for 2d medical image segmentation. **IEEE transactions on medical imaging**, IEEE, v. 38, n. 10, p. 2281–2292, 2019.
- HAKIM, L. et al. Regularizer based on euler characteristic for retinal blood vessel segmentation. **Pattern Recognition Letters**, Elsevier, v. 149, p. 83–90, 2021.

- HAN, D. et al. Automatic coronary artery segmentation using active search for branches and seemingly disconnected vessel segments from coronary ct angiography. **PLoS One**, Public Library of Science San Francisco, CA USA, v. 11, n. 8, p. e0156837, 2016.
- HE, K. et al. Deep residual learning for image recognition. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. [S.l.: s.n.], 2016. p. 770–778.
- HINTON, G. E. et al. Improving neural networks by preventing co-adaptation of feature detectors. **arXiv preprint arXiv:1207.0580**, 2012.
- HSU, C.-Y. et al. Gap-free segmentation of vascular networks with automatic image processing pipeline. **Computers in Biology and Medicine**, Elsevier, v. 82, p. 29–39, 2017.
- HUBEL, D. H.; WIESEL, T. N. Receptive fields and functional architecture of monkey striate cortex. **The Journal of physiology**, Wiley Online Library, v. 195, n. 1, p. 215–243, 1968.
- JIN, Q. et al. Dunet: A deformable network for retinal vessel segmentation. **Knowledge-Based Systems**, Elsevier, v. 178, p. 149–162, 2019.
- KIRST, C. et al. Mapping the fine-scale organization and plasticity of the brain vasculature. **Cell**, Elsevier, v. 180, n. 4, p. 780–795, 2020.
- LECUN, Y. et al. Handwritten digit recognition with a back-propagation network. **Advances in neural information processing systems**, v. 2, 1989.
- LI, D. et al. A multi-frame particle tracking algorithm robust against input noise. **Measurement Science and Technology**, IOP Publishing, v. 19, n. 10, p. 105401, 2008.
- LISKOWSKI, P.; KRAWIEC, K. Segmenting retinal blood vessels with deep neural networks. **IEEE transactions on medical imaging**, IEEE, v. 35, n. 11, p. 2369–2380, 2016.
- LIU, S. et al. Rivulet: 3d neuron morphology tracing with iterative back-tracking. **Neuroinformatics**, Springer, v. 14, n. 4, p. 387–401, 2016.
- LOSHCHILOV, I.; HUTTER, F. Decoupled weight decay regularization. In: **International Conference on Learning Representations**. [S.l.: s.n.], 2019.
- MOCCIA, S. et al. Blood vessel segmentation algorithms—review of methods, datasets and evaluation metrics. **Computer methods and programs in biomedicine**, Elsevier, v. 158, p. 71–91, 2018.
- MORALES-VARGAS, E. et al. A morphological approach for locating blood vessels in laser contrast speckle imaging. In: **IEEE. 2018 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)**. [S.l.], 2018. p. 1–6.
- MOU, L. et al. Dense dilated network with probability regularized walk for vessel detection. **IEEE transactions on medical imaging**, IEEE, v. 39, n. 5, p. 1392–1403, 2019.

- PARELLA, J. P.; SILVA, M. V. da; COMIN, C. H. A new approach for evaluating and improving the performance of segmentation algorithms on hard-to-detect blood vessels. **arXiv preprint arXiv:2406.13128**, 2024.
- RAHMAN, H. et al. A deep learning approach for liver and tumor segmentation in ct images using resunet. **Bioengineering**, MDPI, v. 9, n. 8, p. 368, 2022.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: SPRINGER. **International Conference on Medical image computing and computer-assisted intervention**. [S.l.], 2015. p. 234–241.
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014.
- SZEGEDY, C. et al. Going deeper with convolutions. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. [S.l.: s.n.], 2015. p. 1–9.
- TETTEH, G. et al. Deepvesselnet: Vessel segmentation, centerline prediction, and bifurcation detection in 3-d angiographic volumes. **Frontiers in Neuroscience**, Frontiers, p. 1285, 2020.
- TIWARI, A.; SRIVASTAVA, S.; PANT, M. Brain tumor segmentation and classification from magnetic resonance images: Review of selected methods from 2014 to 2019. **Pattern Recognition Letters**, Elsevier, v. 131, p. 244–260, 2020.
- TODOROV, M. I. et al. Machine learning analysis of whole mouse brain vasculature. **Nature methods**, Nature Publishing Group, v. 17, n. 4, p. 442–449, 2020.
- XIAO, X. et al. Weighted res-unet for high-quality retina vessel segmentation. In: IEEE. **2018 9th international conference on information technology in medicine and education (ITME)**. [S.l.], 2018. p. 327–331.
- YANG, B. et al. Neuron image segmentation via learning deep features and enhancing weak neuronal structures. **IEEE Journal of Biomedical and Health Informatics**, IEEE, v. 25, n. 5, p. 1634–1645, 2020.
- ZEILER, M. D.; FERGUS, R. Visualizing and understanding convolutional networks. In: SPRINGER. **European conference on computer vision**. [S.l.], 2014. p. 818–833.
- ZHANG, J. et al. Reconnection of interrupted curvilinear structures via cortically inspired completion for ophthalmologic images. **IEEE Transactions on Biomedical Engineering**, IEEE, v. 65, n. 5, p. 1151–1165, 2018.
- \_\_\_\_\_. Attention gate resu-net for automatic mri brain tumor segmentation. **IEEE Access**, IEEE, v. 8, p. 58533–58545, 2020.
- ZHANG, Y.; CHUNG, A. Deep supervision with additional labels for retinal vessel segmentation task. In: SPRINGER. **International conference on medical image computing and computer-assisted intervention**. [S.l.], 2018. p. 83–91.