



UNIVERSIDADE FEDERAL DO MARANHÃO

Curso de Ciência da Computação

Francisco Ylderlan Chaves de Oliveira

**Seleção automática de técnicas de
melhoramento para segmentação de imagens
usando otimização por enxame de partículas e
*superpixel***

São Luís - MA

2020

Francisco Ylderlan Chaves de Oliveira

**Seleção automática de técnicas de melhoramento para
segmentação de imagens usando otimização por enxame
de partículas e *superpixel***

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão como parte dos requisitos necessários para obtenção do grau de bacharel em Ciência da Computação.

Orientador: Prof. Msc. Giovanni Lucca França da Silva

São Luís - MA

2020

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

de Oliveira, Francisco Ylderlan Chaves.

Seleção automática de técnicas de melhoramento para segmentação de imagens usando otimização por enxame de partículas e superpixel / Francisco Ylderlan Chaves de Oliveira. - 2020.

49 f.

Orientador(a): Giovanni Lucca França da Silva.

Monografia (Graduação) - Curso de Ciência da Computação, Universidade Federal do Maranhão, São Luís, 2020.

1. Otimização por enxame de partículas. 2. Pré-processamentos. 3. Processamento de imagens. 4. Segmentação. 5. Superpixel. I. da Silva, Giovanni Lucca França. II. Título.

Francisco Ylderlan Chaves de Oliveira

Seleção automática de técnicas de melhoramento para segmentação de imagens usando otimização por enxame de partículas e *superpixel*

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão como parte dos requisitos necessários para obtenção do grau de bacharel em Ciência da Computação.

Trabalho aprovado 08/05/2020 - São Luís - MA:

Prof. Msc. Giovanni Lucca França da Silva
Orientador
Universidade Federal do Maranhão

Prof. Dr. Aristófanês Corrêa Silva
Examinador
Universidade Federal do Maranhão

Prof. Msc. João Otávio Bandeira Diniz
Examinador
Instituto Federal do Maranhão

São Luís - MA
2020

A todos que contribuíram direta e indiretamente até aqui.

Agradecimentos

Sou grato a Deus por estar me capacitando a cada manhã com sua Força. Sem Ele nada eu pude fazer, se não por Sua permissão. Com muita alegria agradeço as minhas mães Maria Zilda Chaves Carreiro e Maria do Socorro Chaves Carreiro as quais sempre me apoiaram nas minhas lutas diárias. Sou grato ao meu tio Antônio Neto que foi um referência de homem em minha família. E ao meu pai Francisco Ernando que não esteve presente em minha infância mas que permaneço honrando por ser o meu pai. Agradeço aos meus avós por incentivarem meus estudos e me darem amor e carinho além de bons exemplos de conduta.

Sou grato também pelos meus irmãos, em Cristo Jesus, da Igreja Batista Nacional Siloé, pastoreada pelos meus líderes Pr. Gilmar de Andrade e Conceição de Andrade, pessoas que contribuíram no ensino da Palavra, que desde de criança vem ensinado, a mim e a todos que se dispuseram aprender, os ensinamento de Cristo pregando o evangelho a toda criatura. A esta congregação agradeço o apoio e as orações que me fortalecem e fazem crescer, em Cristo Jesus, espiritualmente, profissionalmente e como pessoa. Agradecimento especial aos jovens Daniel Victor, João Victor, Thiago Paradela, Rebecca Rios e Iasmim Costa. Iasmim Costa minha companheira e melhor amiga a qual esteve comigo nos momentos bons e ruins prestando seu apoio, agradeço a ela e família pela paciência e companheirismo.

Agradeço também a minha terceira família, a qual nunca conheceria se não fosse pelo apoio e o carinho em ensinar do professor Giovanni Lucca. Giovanni que eu tenho como um exemplo a ser seguido, meu amigo e irmão em Cristo confiou em mim e me proporcionou estar hoje em um lugar onde sou extremamente feliz e grato, que é o Núcleo de Computação Aplicada (NCA). Quando entrei não tinha muitas expectativas mas estava feliz de estar em um ambiente com tantas pessoas inteligentes. Agradeço a todos os alunos de graduação por estar aprendendo junto comigo, todos alunos de mestrado por ter paciência e a disposição de ensinar e a todos alunos de doutorado que mesmo tão ocupados ainda tem tempo de ensinar e a paciência para explicar, em especial a João Bandeira pela disponibilidade em aconselhar e ajudar em todos os momentos. Também agradeço ao professor Aristófanés, Ari, por sempre me incentivar conscientemente ou inconscientemente a extrair o meu melhor, o que tem feito eu evoluir profissionalmente, e a todos os demais professores que compõem essa grande família, o meu sincero obrigado.

Naquele auditório, quando o professor Ari e o professor Anselmo falaram que o NCA é uma família, não acreditei que essas palavras fossem tão verdadeiras. Hoje tenho uma terceira família e casa que é o NCA. Neste laboratório eu tenho alegria de trabalhar

e aprender e todos os dias agradeço a Deus por ter me dado esse privilégio e a alegria de trabalhar neste lugar. Tenho prazer de ajudar e vejo a reciprocidade vinda dos meus amigos de laboratório em fazer o mesmo. Agradeço a paciência dos professores e colegas em ensinar e a ânsia de todos em aprender. Todos, professores e alunos neste laboratório são inspirações para mim. Estou muito feliz de conviver e de trabalhar com vocês. Tenho orgulho de ser NCA.

Dou meu profundo agradecimento também a turma do curso de ciência da computação 2015.1 a qual todos foram muito prestativos e ajudaram nas adversidades e festejaram nas alegrias. Um agradecimento especial a Paulo Renato por ser sempre disposto a ajudar, Pedro Almeida por sempre estar dando bons aconselhamentos e a Robert Douglas pelas constantes caronas e aconselhamentos também.

Eu espero e oro do fundo do coração que todos alcancem o que almejam, rogo a Deus que ilumine os passos de vocês nessa caminhada que não é fácil, até que Ele volte. E fortaleço mais uma vez minha profunda gratidão a todos que me ajudaram consciente e inconscientemente, de forma direta e indireta, a todos vocês meu muito obrigado.

*“Portanto, quer comais quer bebais,
ou façais qualquer outra coisa,
fazei tudo para Glória de Deus”
(1 Coríntios 10:31)*

Resumo

Em processamento de imagem, a etapa de pré-processamento é responsável por preparar as imagens para as etapas posteriores. A seleção apropriada e a ordem de aplicação das técnicas de melhoramento, geralmente depende da intuição do pesquisador e da experiência no domínio do problema. Este trabalho tem como principal objetivo desenvolver um método heurístico capaz de selecionar quais técnicas de melhoramento de imagem aplicar e suas respectivas ordens. Para isso, será utilizado o algoritmo de otimização por enxame de partículas (PSO), que baseia-se no comportamento natural de grupos, para seleção do melhor indivíduo, ou seja, o melhor conjunto de pré-processamentos. Para validação do melhor conjunto e sequência das técnicas de pré-processamento no PSO utilizou-se a técnica de agrupamento iterativo linear simples de superfície intrínseca (IMSLIC), um método de segmentação por agrupamento. O grau de semelhança da segmentação resultante com a marcação feita pelo especialista foi calculada baseada no coeficiente de similaridade Dice. A finalidade desta aplicação está em demonstrar a usabilidade e eficácia do PSO para seleção e a definição da ordem procedural de um conjunto de técnicas de melhoramento em diferentes bases de imagens.

Palavras-chaves: Processamento de imagens, Pré-processamentos, Segmentação, Otimização por enxame de partículas, *Superpixel*.

Abstract

Preprocessing is an important step in image processing methods which has the purpose of preparing images for later steps. The selection of appropriate techniques usually is based solely on intuition and experience of the problem domain by researchers. The purpose of this work is to develop a heuristic method that, for any given domain, selects the best set of image enhancement techniques and their specific order of application. For this, we use particle swarm optimization (PSO), which is an algorithm based on the natural behavior of animal groups, to select the best individual, that is, the best set of preprocessing techniques. In order to validate the preprocessing sequences generated by PSO, we use intrinsic manifold simple linear iterative clustering (IMSLIC). The degree of similarity between the resulting segmentations with the marking made by specialists were calculated using Dice similarity coefficient. The objective of the proposed method is to demonstrate the usability of PSO for selection and ordering of the best set of enhancement techniques for a given domain.

Keywords: Image processing, Preprocessing, Segmentation, Particle swarm optimization, Superpixel.

Lista de ilustrações

Figura 1 – Etapas fundamentais em processamento digital de imagens (GONZALEZ, 2000)	19
Figura 2 – Aplicação do filtro da média.	20
Figura 3 – Aplicação do filtro gaussiano.	21
Figura 4 – Aplicação do filtro mediana.	21
Figura 5 – Aplicação da equalização adaptativa limitada do histograma por contraste.	22
Figura 6 – Aplicação do realce de contraste baseado em intrínseca decomposição.	23
Figura 7 – Aplicação da técnica correção do campo de viés N4.	23
Figura 8 – Aplicação da técnica máscara de nitidez.	24
Figura 9 – Aplicação da quantização uniforme.	25
Figura 10 – Aplicação da técnica gradiente anisotrópico.	26
Figura 11 – Mapeamento dos <i>pixels</i> (YE et al., 2019).	28
Figura 12 – Comparação visual entre a aplicação das duas técnicas (YE et al., 2019).	29
Figura 13 – Movimentação da partícula.	30
Figura 14 – Aplicação da especificação do histograma.	31
Figura 15 – Fluxograma do método proposto.	32
Figura 16 – Representação da partícula.	34
Figura 17 – Representação visual do processo de decodificação da partícula em técnicas aplicadas na imagem.	35
Figura 18 – Etapas do algoritmo PSO.	38
Figura 19 – Avaliação qualitativa da etapa de execução do algoritmo PSO para a base de exames de RM da próstata.	41
Figura 20 – Avaliação qualitativa da etapa de execução do algoritmo PSO para base de imagens dermatográficas.	43
Figura 21 – Avaliação qualitativa da etapa de execução do algoritmo PSO para a base de imagens radiográficas do tórax	44
Figura 22 – Avaliação qualitativa da etapa de execução do algoritmo PSO para base de imagens de glaucoma.	46

Lista de tabelas

Tabela 1 – Parâmetros definidos para o algoritmo PSO na etapa de execução. . . .	39
Tabela 2 – Definição das partículas da etapa de pré-processamento no método proposto para a base 3D.	40
Tabela 3 – Definição das partículas da etapa de pré-processamento no método proposto para bases 2D.	40
Tabela 4 – Resultados obtidos na etapa de execução do algoritmo PSO para a base de exames de RM da próstata.	41
Tabela 5 – Resultados obtidos na etapa de execução do algoritmo PSO para base de imagens dermatoscópicas.	42
Tabela 6 – Resultados obtidos na etapa de execução do algoritmo PSO para base de imagens radiográfica do tórax.	44
Tabela 7 – Resultados obtidos na etapa de execução do algoritmo PSO para base de imagens de glaucoma.	45

Lista de abreviaturas e siglas

CLAHE	<i>Contrast Limited Adaptive Histogram Equalization</i>
CIELAB	<i>International Commission on Illumination Lightness A B</i>
DSC	Coeficiente de Similaridade Dice
DICOM	<i>Digital Imaging and Communications in Medicine</i>
ERC	Bobina Endorretal
FN	Falso Negativo
HSV	<i>Hue, Saturation and Value</i>
IMSLIC	<i>Intrinsic Manifold Simple Linear Iterative Clustering</i>
MC	<i>Montgomery County</i>
NCIA	<i>National Cancer Imaging Archive</i>
PAC	Bobina de Matriz em Fases
PSO	<i>Particle Swarm Optimization</i>
SLIC	<i>Simple Linear Iterative Clustering</i>
RGB	<i>Red, Green and Blue</i>
RM	Ressonância Magnética
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

Sumário

1	INTRODUÇÃO	15
1.1	Justificativa	16
1.2	Objetivo geral	16
1.2.1	Objetivos específicos	17
1.3	Organização do trabalho	17
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	Processamento de imagens digitais	18
2.1.1	Melhoramento de imagem	19
2.1.1.1	<i>Filtro da média</i>	19
2.1.1.2	<i>Filtro da gaussiana</i>	20
2.1.1.3	<i>Filtro da mediana</i>	20
2.1.1.4	<i>Equalização de histograma adaptativo limitado por contraste</i>	21
2.1.1.5	<i>Aprimoramento de contraste baseado em intrínseca decomposição de imagem</i>	22
2.1.1.6	<i>Correção de campo de viés N_4</i>	22
2.1.1.7	<i>Máscara de nitidez</i>	24
2.1.1.8	<i>Quantização uniforme</i>	24
2.1.1.9	<i>Difusão anisotrópica e afins</i>	25
2.1.2	<i>Superpixel</i>	26
2.1.2.1	Agrupamento iterativo linear simples	27
2.1.2.2	Agrupamento iterativo linear simples de superfície intrínseca	27
2.2	Algoritmo evolutivo	28
2.2.1	Otimização por enxame de partícula	29
2.3	Especificação do histograma	30
2.4	Métrica de avaliação	31
2.4.1	Coeficiente de similaridade Dice	31
3	MÉTODO PROPOSTO	32
3.1	Materiais	32
3.1.1	PROMISE12	32
3.1.2	Prostate 3T	33
3.1.3	PH^2	33
3.1.4	Montgomery County chest X-ray set	33
3.1.5	RIM-ONE	33
3.2	Modelagem do problema de otimização	34
3.2.1	Codificação	35

3.2.2	Agrupamento e classificação dos <i>superpixels</i>	36
3.2.3	Função objetivo	36
3.3	Execução do Algoritmo PSO	37
4	RESULTADOS E DISCUSSÃO	39
4.1	Avaliação dos pré-processamentos selecionados para bases de imagem de exames de RM da próstata	40
4.2	Avaliação dos pré-processamentos selecionados para base de imagens dermatoscópicas	42
4.3	Avaliação dos pré-processamentos selecionados para bases de imagens radiográficas do tórax para segmentação do pulmão	43
4.4	Avaliação dos pré-processamentos selecionados para base de imagens de glaucoma	45
5	CONCLUSÃO	47
	REFERÊNCIAS	48

1 Introdução

Processamento digital de imagens é tema presente desde o surgimento da base dos computadores digitais modernos, os quais foram as primeiras máquinas capazes de aplicar técnicas de processamento de imagens. Seu surgimento proveio da disponibilidade destas máquinas, e do início de programas espaciais, paralelamente a aplicações de técnicas na área da medicina, geografia, além da astronomia. A criação de formas distintas para representar as imagens convergiu no surgimento de diferentes técnicas de processamento. Desde então, processamento de imagem é tema recorrente nas mais variadas áreas de aplicação (GONZALEZ, 2000).

O processamento digital em imagens contribui na melhora da qualidade visual, correção, adequação e agrupamento de regiões de interesse (QUEIROZ, 2006). Há três níveis de processamento: baixo, médio e alto. Processos de baixo nível incluem processos rudimentares, como correção da captação dos sensores, redução de ruídos, realce do contraste e adequação da imagem ao domínio do problema. O processamento de nível médio envolve tarefas de segmentação das regiões de interesse. O processo de nível alto realiza análise cognitiva da imagem, atribuindo sentido aos objetos na imagem (GONZALEZ, 2000).

Entre as etapas de processamento de imagens, a etapa de segmentação tem sido ponto importante e desafiador por possuir múltiplos objetivos como redução de complexidade, reconhecimento e extração de regiões. Desempenha frequentemente um papel crítico na maioria das análises sobre imagens (SIVAKUMAR, 2016). Há várias técnicas de segmentação, dentre estas, a técnica de segmentação por *superpixels* consiste em agrupar *pixels* por um conjunto de características similares (ACHANTA, 2012). Essa técnica tem sido abordada em diferentes domínios em processamento de imagem. O constante uso desta abordagem é devido a redução no número de entradas, diminuindo a complexidade de processamento (BAN JIANGUO LIU, 2018).

A utilização de pré-processamento tendem a maximizar os efeitos positivos no processo de segmentação. Para comparação, pré-processamento de imagem é similar à normalização matemática de um conjunto de dados, etapa comum para métodos de descrição de características (KRIG, 2014). A escolha de pré-processamentos geralmente é realizada intuitivamente baseada na experiência do usuário (ELGENDY, 2018). Apesar do pré-processamento ser uma parte importante ainda é raro encontrar aplicações voltadas a seleção automática de conjunto de pré-processamentos e a ordem de aplicação destes, que melhorem os resultados de tarefas posteriores, como exemplo a etapa de segmentação.

Os algoritmos evolutivos são frequentemente utilizados como técnicas para solução

de problemas de otimização, por ter como característica, uma população de candidatos a solução (GABRIEL; DELBEM, 2008). Uma técnica evolutiva que agrega esta característica de evolução é o algoritmo de otimização por enxame de partícula (PSO). O algoritmo PSO é inspirado no comportamento de enxames, bando de pássaros e peixes (KENNEDY; EBERHART; SHI, 2001). Esta técnica vem sendo muito utilizada por ter como característica rápida convergência e por ser robusta ao tamanho na população e a quantidade de dimensões (SHI; EBERHART, 1999) (ENGELBRECHT, 2008).

Diferentes tipos de instrumentos de aquisição de imagem, formas de iluminação e características das imagens são algumas das variáveis determinantes na melhor escolha do conjunto de pré-processamentos necessários para ajustar a qualidade das imagens para os processamentos subsequentes (VIDAL, 2012). Diante dos múltiplos contextos e das diferentes possibilidades, uma aplicação voltada para seleção otimizada de pré-processamentos proporcionaria uma melhora nos resultados iniciais após a aquisição de imagens.

1.1 Justificativa

Independentemente do hardware, a aquisição de imagens é aprimorada continuamente através da criação de sensores mais rápidos e poderosos, incluindo novos sistemas de refrigeração ou fontes de iluminação aprimoradas. No entanto, há diferentes problemas que precisam ser resolvidos antes de iniciar a análise dos dados de qualquer amostra (como realce de regiões, compactação de imagem, remoção de planos de fundo, picos, *pixels* de intensidade comprometida, etc.). Portanto, a etapa de pré-processamento de imagem é quase sempre necessária (VIDAL, 2012).

A aplicação de técnicas de pré-processamentos é geralmente uma tarefa realizada empiricamente pelo profissional em processamento de imagem baseada no conhecimento prévio deste na área. Um método heurístico capaz de tornar essa etapa de seleção automatizada possibilitaria que houvesse uma melhora no processo inicial de escolha de quais pré-processamentos utilizar para diferentes domínios de problemas.

1.2 Objetivo geral

Desenvolver um método automático de seleção e da melhor ordem de aplicação das técnicas de pré-processamento baseado no algoritmo de otimização PSO, para assim, aprimorar os resultados obtidos em processos posteriores.

1.2.1 Objetivos específicos

- Analisar formas de codificação numérica de todas as possíveis combinações de pré-processamento.
- Aplicar técnicas de pré-processamento de imagens.
- Tornar o método versátil tanto para imagens 2D quanto para imagens 3D.
- Realizar testes com diferentes bases de dados de imagens com diferentes domínios de problemas.

1.3 Organização do trabalho

Este trabalho está organizado em cinco capítulos, de forma a apresentar o conteúdo mais claramente, conforme os parágrafos a seguir.

O Capítulo 2, Fundamentação teórica, apresenta o embasamento teórico necessário para o entendimento e desenvolvimento do método proposto.

O Capítulo 3, Método proposto, apresenta as etapas realizadas de forma detalhada para seleção da ordem e das técnicas de melhoramento em bases de imagens.

O Capítulo 4, Resultados e discussão, compara e discute os resultados obtidos pelo método proposto em diferentes bases de imagens.

O Capítulo 5, Conclusão, apresenta as considerações finais acerca do trabalho realizado, as contribuições do mesmo e as propostas de trabalhos futuros.

2 Fundamentação Teórica

Neste capítulo são apresentadas técnicas e conceitos, utilizados no desenvolvimento deste trabalho, necessários na compreensão do método proposto para seleção automática da ordem e do conjunto de pré-processamentos.

2.1 Processamento de imagens digitais

Processamento digital de imagem são conjunto de técnicas que viabilizam a aquisição, representação e transformação de imagens por intermédio do computador. Essas técnicas objetivam a melhora na qualidade da imagem a fim de facilitar a interpretação, seja ela feita pelo homem, ou de forma automática, por meio de computadores (HELIO; SCHWARTZ, 2008).

A representação digital de uma imagem é dada pela função bidimensional f , cuja as variáveis, x e y , pertencentes a esta função são coordenadas espaciais que representam a localização de um conjunto discreto de pontos pertencentes a imagem, onde cada ponto representado é chamado de *pixel*. A intensidade ou nível de cinza de cada *pixel*, é dado por $f(x,y)$ (GONZALEZ, 2000). No caso da representação de imagens tridimensionais (3D), a função será tridimensional, com as coordenadas x , y e z , onde z representa a profundidade e cada ponto na imagem é chamado de *voxel*.

O processamento de imagens consiste em um conjunto de técnicas visto que, a saída gerada por cada técnica é utilizado como entrada para a técnica posterior. Este conjunto de etapas visam a melhor representação das informações contidas na imagem. Onde a saída pode ser ou não representado por uma imagem digital. Este conjunto de etapas em processamento de imagens são:

1. Aquisição de imagens: aquisição é a etapa inicial onde, por meio de algum dispositivo de captura, é gerada a representação da informação obtida para os processamentos posteriores.
2. Pré-processamento: consiste em utilizar técnicas como realce de estruturas, diminuição de ruídos e suavização para melhorar e ou corrigir a imagem adquirida na fase de aquisição.
3. Segmentação: usada para identificação e extração de áreas de interesse que compõem a imagem, ou seja, tem a função de decompor a imagem original deixando apenas regiões de interesse.

4. Representação e descrição: tem como objetivo extrair características dos diferentes estruturas que compõem a imagem a fim de possibilitar a distinção entre diferentes classes de objetos.
5. Reconhecimento e interpretação: é o processo de atribuição de rótulos aos objetos identificados na imagem. Interpretação é, dado o conjunto de rótulos, atribuir significado ao conjunto de rótulos da imagem.

As etapas descritas podem ser vistas na Figura 1:

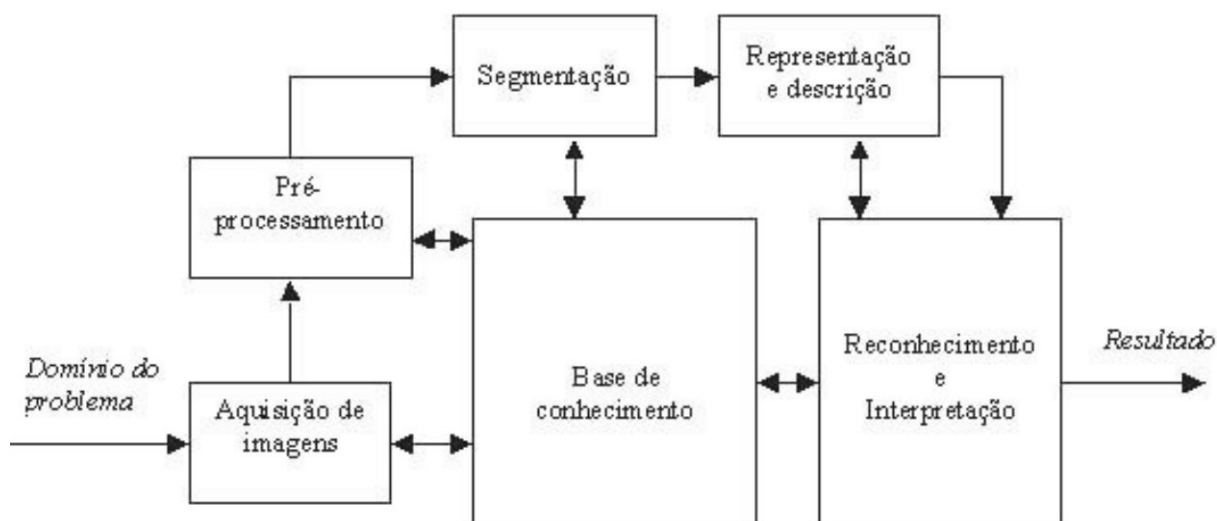


Figura 1 – Etapas fundamentais em processamento digital de imagens (GONZALEZ, 2000)

2.1.1 Melhoramento de imagem

Consiste em uma subetapa de processamento de imagens, conhecida também como etapa de pré-processamento, onde utilizado técnicas como realce de regiões , redução de ruídos buscando melhorar e ou corrigir a imagem adquirida na fase de aquisição (GONZALEZ, 2000). Estas técnicas de melhoramento foram utilizadas neste trabalho na etapa de execução do algoritmo PSO, para a otimização do melhor conjunto e da ordem de aplicação deste pré-processamento para cada base de imagens.


2.1.1.1 Filtro da média

Consiste em um filtro de suavização cujo o objetivo é borrar a imagem, obtendo a representação mais geral dos objetos contidos na imagem, uma vez que a intensidade dos objetos menores é mesclada ao fundo, e os objetos maiores ganham características de intensidade mais uniforme, tornando-se mais fácil de serem detectados. O tamanho da máscara define o tamanho relativo dos objetos que serão mesclados ao fundo (GONZALEZ, 2000). O processo de suavização usando a média é dado pela convolução de uma máscara

$k(x,y)$ onde, x e y correspondem ao centroide onde será aplicado a média. A máscara utilizada geralmente possui dimensões iguais onde a dimensão M é igual N , além da propriedade cuja a soma de todos os *pixels* contidos na máscara sejam iguais a 1. O filtro da média é dado pela soma do centroide e de todos os seus vizinhos dividido pela dimensão M da máscara (GONZALEZ, 2000). A Figura 2 demonstra o resultado a aplicação do filtro da média ao lado da imagem original sem pré-processamento.



(a) Imagem original.



(b) Imagem com filtro da média.

Figura 2 – Aplicação do filtro da média.

2.1.1.2 Filtro da gaussiana

Assim como o filtro da média, o filtro gaussiano tem como objetivo borrar regiões com incidência de ruídos. O filtro gaussiano difere do filtro da média, por conta de seu *kernel*, que possui propriedade gaussiana, onde os elementos centrais possuem maior peso que os elementos mais externos, fazendo com que os vizinhos mais próximos possuam peso maior ao ser calculado o novo valor de *pixel* (GONZALEZ, 2000). A Figura 3 mostra resultado da aplicação da técnica e a imagem original.

2.1.1.3 Filtro da mediana

Os filtros de estatística de ordem são filtros espaciais não lineares cuja resposta se baseia na ordenação (classificação) dos *pixels* contidos na área da imagem coberta pelo filtro e substituindo o valor do *pixel* central pelo valor determinado pelo resultado da classificação. O filtro mais conhecido dessa categoria é o filtro de mediana, o qual, como o nome sugere, substitui o valor de um *pixel* pela mediana dos valores de intensidade na vizinhança desse *pixel* (o valor original do *pixel* é incluído no cálculo da mediana). Os filtros de mediana são bastante populares, porque, para certos tipos de ruído aleatório, proporcionam excelentes resultados na redução de ruído, com borrarmento consideravelmente menor do que filtros




Figura 3 – Aplicação do filtro gaussiano.

lineares de suavização de tamanho similar (GONZALEZ, 2000). A Figura 4 mostra a aplicação do filtro da mediana ao lado da imagem sem aplicação de pré-processamentos.




Figura 4 – Aplicação do filtro mediana.

2.1.1.4 Equalização de histograma adaptativo limitado por contraste

Uma variante da equalização adaptativa do histograma, conhecida como equalização adaptativa limitada do histograma por contraste (CLAHE) foi proposta por Zuiderveld (1994), para evitar que o ruído seja amplificado em regiões homogêneas da imagem. Essa abordagem limita a amplificação do ruído por recorte o histograma através de um valor especificado antes de compor a função de distribuição cumulativa. Em vez de descartar a parte do histograma que excede o limite do corte, ele é redistribuído uniformemente entre todas as posições no histograma. Na Figura 5 podemos ver um comparativo visual entre a imagem sem pré-processamento e logo após a aplicação da técnica CLAHE.



(a) Imagem original.



(b) Imagem aplicada CLAHE.

Figura 5 – Aplicação da equalização adaptativa limitada do histograma por contraste.

2.1.1.5 Aprimoramento de contraste baseado em intrínseca decomposição de imagem

A técnica de ajuste de intensidade por decomposição intrínseca proposta por [Yue et al. \(2017\)](#), é uma técnica de realce por ajuste da camada de iluminação e refletância. Essa técnica consiste em realizar uma decomposição, e aplicar correção gama na camada de iluminação para aumentar os detalhes globalmente, além de utilizar a técnica CLAHE para promover melhora dos detalhes locais. Esta técnica consiste nas seguintes etapas:

1. Dada uma imagem RGB de entrada, primeiro a convertemos em representação HSV.
2. Logo após, a imagem do canal de valor (V) é decomposta em duas camadas: iluminação (L) e refletância (R).
3. É feito realce gama na camada (L) produzindo uma camada (L) ajustada, denotado por (La). Então, o (La) ajustado é multiplicado pela camada de refletância (R) para gerar o canal (V) aprimorado, (Ve).
4. Utilização do CLAHE para aumentar ainda mais o contraste local de (Ve).
5. A imagem HSV é transformada para RGB.

Na Figura 6 pode ser visualizado um comparativo qualitativo entre a imagem sem pré-processamento e com pré-processamento.

2.1.1.6 Correção de campo de viés $N4$

A correção de *bias field* é uma abordagem para calcular o campo aditivo na imagem e amenizar seus efeitos colaterais. As abordagens corretivas atuais podem ser categorizadas em prospectivas e retrospectivas. As abordagens prospectivas destinam-se



(a) Imagem original.



(b) Imagem com realce do contraste.

Figura 6 – Aplicação do realce de contraste baseado em intrínseca decomposição.

regular e aprimorar o processamento de aquisição de imagens nos scanners de RM. Contudo essa técnica não corrige a heterogeneidade induzida pela presença do paciente no scanner de RM (SONG; ZHENG; HE, 2017).

As abordagens retrospectivas se constituem apenas nas imagens adquiridas e, às vezes, de algum conhecimento prévio. Assim, elas são comparativamente mais gerais e podem ser utilizadas na correção da heterogeneidade impelida pelo paciente enquanto realiza o exame. As abordagens retrospectivas podem ser baseadas em filtragem, histograma ou segmentação (TUSTISON et al., 2010). A Figura 7 ilustra um exemplo da aplicação.



(a) Imagem original.



(b) Imagem aplicada correção do campo de viés N4.

Figura 7 – Aplicação da técnica correção do campo de viés N4.

2.1.1.7 Máscara de nitidez

A técnica de máscara de nitidez, como o nome sugere, busca aumentar a nitidez da imagem (GONZALEZ, 2000). Esta técnica é amplamente usada para melhorar a qualidade perceptiva de uma imagem enfatizando seus componentes de alta frequência (POLESEL A., 1997). Podendo ser descrita pela Equação 2.1, na qual k representa a constante de aprimoramento da nitidez, $f(x, y)$ é a imagem de entrada, $f_{smooth}(x, y)$ é a imagem de saída de um filtro passa-baixa linear e $f_{sharp}(x, y)$ é a imagem de correção com a máscara de nitidez já aplicada.

$$f_{sharp}(x, y) = f(x, y) + k * f_{smooth}(x, y) \quad (2.1)$$

O filtro de passa-baixa utilizado neste trabalho foi o gaussiano. Está técnica consistem nas seguintes etapas:

1. Borrar a imagem original.
2. Subtrair a imagem borrada da original (a diferença resultante é chamada de máscara.)
3. Adicionar a máscara à imagem original.

A Figura 8 mostra a comparação qualitativa entre a imagem original e a imagem pré-processada.



(a) Imagem original.



(b) Imagem aplicado a técnica de máscara de nitidez.

Figura 8 – Aplicação da técnica máscara de nitidez.

2.1.1.8 Quantização uniforme

Uma imagem ao ser representada por uma imagem digital é discretizada espacialmente em x e y , e também em intensidade luminosa. A discretização por intensidade de *pixel* é

conhecida como quantização e a outra, por amostragem (GONZALEZ, 2000). A quantização uniforme divide a imagem em intervalos uniforme de escala de intensidade de *pixels*, onde a escala de cinza é dada por $[0, L' - 1]$ (HELIO; SCHWARTZ, 2008). Onde o nível de cinza da imagem quantizada é menor que o nível da imagem original.

A Equação 2.2 que descreve o processo de quantização.

$$q(i, j) = \left((2^b - 1) \cdot \frac{p(i, j) - I_{min}}{I_{max} - I_{min}} \right) \quad (2.2)$$

Onde $Q(x, y)$ é o nível de cinza da imagem quantizada, $P(x, y)$ é o nível de cinza da imagem original, $[I_{min}, I_{max}]$ e a escala de cinza da imagem original, e b é o número de *pixels* necessários para armazenar em cada *pixel* da imagem quantizada.

A Figura 9 mostra a comparação qualitativa entre a imagem original e a imagem pré-processada.



(a) Imagem original.



(b) Imagem aplicada quantização uniforme de 4 bits.


Figura 9 – Aplicação da quantização uniforme.

2.1.1.9 Difusão anisotrópica e afins

Técnica utilizada para remoção de ruídos e preservação de borda. O formalismo desse problema é a ideia da filtragem, ou transformação, do espaço-escala. A teoria espaço-escala é uma base teórica para a representação de imagens, ou sinais, em múltiplas escalas, desenvolvido pelas comunidades de processamento de imagens e processamento de sinais. Esta técnica possui como característica manusear estruturas de imagens em diferentes escalas, de maneira que atributos em escalas maiores podem ser sucessivamente suprimidos e um parâmetro de escala t pode ser associado com cada nível da representação espaço-escala. A ideia essencial para essa abordagem tem como base envolver a imagem original, $I_0(x, y)$, numa família de imagens derivadas, $I(x, y; t)$, obtidas pela convolução a imagem



(a) Imagem original.



(b) Imagem aplicada difusão anisotrópico.

Figura 10 – Aplicação da técnica gradiente anisotrópico.

original com um filtro gaussiano $G(x, y, t)$, com variância t (PERONA; SHIOTA; MALIK, 1994):

$$\frac{\partial g(x, y, t)}{\partial t} = \nabla \cdot c(x, y, t) \nabla g(x, y, t) \quad (2.3)$$

onde $\partial g(x, y, t)/\partial t$ é a imagem discretizado espacial e temporalmente, t representa o passo de tempo discreto (número de iterações, onde maior que 0. O termo $c(x, y, t)$ é definido como o coeficiente de difusão que controla a taxa de difusão e $g(x, y, t) = I(x, y) \otimes G(\sqrt{2t})$, sendo $I(x, y)$ a imagem de entrada e $G(\sqrt{2t})$ uma função gaussiana de largura $\sqrt{2t}$.

O tempo t é um parâmetro de escala: incrementos em t geram representações mais simples da imagem, ou com resoluções menores. O agrupamento da imagem original nesse conjunto de imagens simplificadas, é chamado espaço-escala. Esta técnica possibilita a suavização intra-região e evitando a suavização inter-região. Com isso, os ruídos são eliminados e a imagem é simplificada ao mesmo tempo em que mantém as arestas nítidas.

A Figura 10 mostra a comparação qualitativa entre a imagem original e a imagem pré-processada.

2.1.2 Superpixel

Superpixel é uma técnica de segmentação por agrupamento de *pixels*, onde este agrupamento é realizado mediante a similaridade de intensidade entre o *pixel* e sua vizinhança (REN; MALIK, 2003). O uso da técnica *superpixel* mostra eficácia quanto a redução da complexidade, agrupando regiões que possuem informação redundante, para os tarefas subsequentes de processamento de imagem (ACHANTA et al., 2010).

2.1.2.1 Agrupamento iterativo linear simples

Consiste em uma técnica que utiliza o algoritmo de agrupamento K-means para geração de *superpixel*, que utiliza o sistema de cores proposto pela comissão internacional de iluminação com os canais de luminância, magenta e azul, Comissão Internacional de Iluminação Luminância Magenta Azul (CIELAB) (ALSABTI; RANKA; SINGH, 1997). O algoritmo de agrupamento iterativo linear simples (SLIC) funciona da seguinte forma:

1. É feita a conversão da imagem para o sistema de cores CIELAB.
2. É inicializado k centroides de cada agrupamento, opcionalmente os centroides podem ser inicializados nas posições de gradiente mais baixo para evitar a inicialização em *pixels* ruidosos, ou em borda.
3. Após a inicialização, cada *pixel* é associado ao centroide mais próximo de acordo com a distância euclidiana D na Equação 2.6.
4. Após isto, é feita o ajuste dos centroides, onde é calculado a média do conjunto de *pixels* que pertencem ao agrupamento.
5. O passo 4 é repetido até que 10 iterações sejam realizadas, para garantir maior eficácia na convergência do erro, de acordo com Achanta et al. (2010).

O cálculo da distância D é representado pela equação 2.6.

$$dc = \sqrt{(l_i - l_j)^2 + (a_i - a_j)^2 + (b_i - b_j)^2} \quad (2.4)$$

$$ds = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (2.5)$$

$$D = \sqrt{dc^2 + \left(\frac{ds}{S}\right)^2 * m^2} \quad (2.6)$$

no qual m é responsável por mensurar a importância entre a distância espacial ds e a dissimilaridade de cor dc , onde quanto maior o valor de m , maior será importância da proximidade espacial resultando em *superpixels* mais compactos. No caso inverso, o resultará em *superpixels* serão mais aderentes as contidas na imagem, mas têm tamanho e forma menos regulares.

2.1.2.2 Agrupamento iterativo linear simples de superfície intrínseca

Esta técnica de agrupamento é uma extensão da técnica de *superpixel* SLIC, cuja a qual foi proposta por Liu et al. (2017). Este algoritmo gera *superpixels* a partir de informações de intensidade de *pixel* a partir do sistema de cores CIELAB combinado

a informações espaciais geradas por intermédio de um mapa de alongamento 5D, sem perder características herdadas da técnica SLIC, como ser um algoritmo simples e ter alta performance. Este mapeamento 5D dos *pixels* é ilustrado na Figura 11




Figura 11 – Mapeamento dos *pixels* (YE et al., 2019).

Segundo Liu et al. (2017), a técnica de agrupamento iterativo linear simples de superfície intrínseca (IMSLIC) apresenta as seguintes evoluções com relação ao SLIC:


1. A utilização do algoritmo de otimização local Lloyd para inicialização dos k centroides.
2. Substituição da distância euclidiana pela distância do diagrama de Voronoi centroidal geodésico. Ao fazer isso é garantido a conectividade única entre cada célula de Voronoi.

Na Figura 12, vemos uma comparação visual entre o SLIC e a técnica IMSLIC.


Neste trabalho foi utilizado o IMSLIC no agrupamento de *pixels*, afim de avaliar a eficácia das técnicas de pré-processamento aplicadas.

2.2 Algoritmo evolutivo

São técnicas computacionais que se baseiam no comportamento evolutivo encontrado na natureza. Estes algoritmos vem sendo aplicados em problemas de otimização por possuírem uma série de características interessantes na resolução deste domínio de problema. Em sua essência estes tipos de algoritmos têm como princípio um conjunto de soluções candidatas, representando os indivíduos, onde a cada geração estes indivíduos evoluem e competem pela sobrevivência, onde apenas os melhores indivíduos possuem maior chance de sobrevivência (GABRIEL; DELBEM, 2008).



(a) Aplicação da técnica de *superpixel* SLIC.



(b) Aplicação da técnica de *superpixel* IMSLIC.

Figura 12 – Comparação visual entre a aplicação das duas técnicas (YE et al., 2019).

2.2.1 Otimização por enxame de partícula

O algoritmo de otimização por enxame de partículas (PSO) foi proposto por Eberhart e Kennedy (1995). Trata-se de uma técnica evolutiva baseada no comportamento de enxames, bando de pássaros e cardumes (EBERHART; KENNEDY, 1995). O algoritmo PSO é inicializado com um conjunto de soluções denominado de enxame, onde cada possível solução, pertencente ao enxame é denominada de partícula. Estas partículas são lançadas aleatoriamente no espaço multidimensional. Cada iteração deste algoritmo representa a movimentação das partículas com base na experiência obtida pelo enxame, ou seja, leva em consideração, a experiência própria da partícula e a experiência da melhor partícula pertencente a este enxame, a representação desta movimentação pode ser vista na Figura 13.

A atualização da movimentação das partículas no decorrer de cada iteração é realizada a partir das Equações 2.7 e 2.8:

$$v_i = w \cdot v_i + (C_1 \cdot r_1 \cdot (Pbest - x_i)) + (C_2 \cdot r_2 \cdot (Gbest - x_i)) \quad (2.7)$$

$$x_i = x_i + v_i \quad (2.8)$$

onde, i representa a partícula em questão, e x sua posição no espaço, w representa a constante de inércia que representa o impacto das velocidades anteriores na velocidade

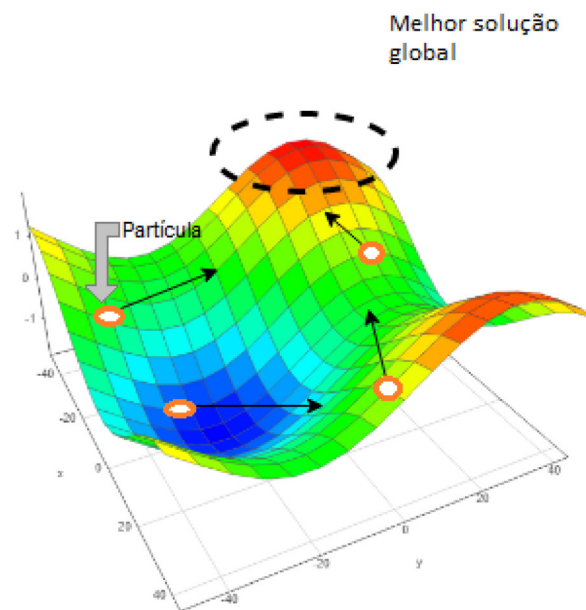


Figura 13 – Movimentação da partícula.

atual, C_1 é a constante que atrai cada partícula para sua melhor posição local, C_2 é a constante que atrai a partícula para a melhor posição, e r_1 e r_2 são números aleatórios entre 0 e 1.

O algoritmo PSO foi aplicado neste trabalho como a técnica escolhida para otimização da escolha dos pré-processamentos.

2.3 Especificação do histograma

O histograma de uma imagem digital com níveis de intensidade no intervalo $[0, L - 1]$ é uma função discreta $h(rk) = nk$, onde rk é o k -ésimo valor de intensidade e nk é o número de *pixels* da imagem com intensidade rk . (GONZALEZ, 2000). Assim, é uma forma de representação na forma de gráfico, da distribuição de valores de *pixel* de uma imagem, (CRÓSTA, 1992) onde o eixo vertical representa o número de *pixels* com dado valor, e o eixo horizontal representa o valor da intensidade do *pixel*. O processo de especificação do histograma corresponde em transformar o histograma de uma imagem a partir de outro histograma de uma imagem de referência, resultando em um distribuição de *pixel* semelhante a especificada. (GONZALEZ, 2000) O processo de especificação do histograma é feito da seguinte forma:

1. A partir do histograma de uma determinada imagem $hi(x)$ e com o histograma de referência $ho(y)$ é feita a equalização do histograma a partir da fórmula 2.9 $hi(x)$ resultando no intermediário $h(z)$
2. Feita a equalização,


$$y(i) = \frac{L-1}{N} \sum_{i=0}^{L-1} n_i \quad (2.9)$$



(a) Imagem original.



(b) Imagem de referência.



(c) Imagem resultante.

Figura 14 – Aplicação da especificação do histograma.

A técnica de especificação do histograma foi utilizado neste trabalho como uma das possíveis técnicas de pré-processamento a serem selecionadas pelo PSO.

2.4 Métrica de avaliação

2.4.1 Coeficiente de similaridade Dice

O coeficiente de similaridade Dice (DSC), também conhecido por índice de sobreposição, é a métrica mais utilizada na validação da segmentação de imagens médicas. Pode ser descrita pela Equação 2.10.

$$DSC = \frac{2 \cdot VP}{(2 \cdot VP) + FP + FN} \quad (2.10)$$

Onde VP representa a taxa de verdadeiro positivos, FP é a taxa de falso positivos e FN é a taxa de falso negativos.

Esta métrica tem o objetivo de medir o desempenho do método proposto, além de servir como a função objetivo para validação das técnicas de pré-processamento aplicadas.

3 Método proposto

Este capítulo descreve o método proposto para a seleção automática do conjunto de técnicas de pré-processamentos e da ordem de aplicação destas para melhorar etapas posteriores, como a segmentação, usando o algoritmo PSO e a técnica de *superpixel* IMSLIC. O método está dividido em três etapas, como descrito na Figura 15:



Figura 15 – Fluxograma do método proposto.

3.1 Materiais

As bases de imagens neste método proposto foram obtidas através de cinco repositórios de imagens públicas disponíveis na internet, a *Prostate 3T* (TURKBEY et al., 2011), *PROMISE12* (LITJENS OSCAR DEBATS, 2012), *PH²* (MENDONCA et al., 2015), *RIM-ONE* (MENDONCA et al., 2015) e a *Montgomery County chest X-ray set* (AMERICA; RSNA; RADIOLOGY,).

3.1.1 PROMISE12

A base *PROMISE12* foi disponibilizada pelo desafio de segmentação de próstata em imagem de ressonância magnética (RM) do MICCAI no ano de 2012. A base contém 50 exames juntamente com as marcações feitas pelo especialista. Esta base possui como característica grande variação de intensidade de *voxel* e faixa dinâmica. As imagens que constituem essa base foram adquiridas de diferentes hospitais, com diferentes equipamentos e protocolos de aquisição, como os scanners Siemens 1.5T e 3.0T, utilizando uma bobina de matriz em fase (PAC) pélvica ou uma bobina endorretal (ERC) (LITJENS OSCAR DEBATS, 2012). Foram utilizadas na metodologia apenas as imagens adquiridas pela PAC, resultando na redução da base para 26 imagens. A exclusão dos exames adquiridos usando a bobina

endorretal é devido as deformidades causadas pelo uso de gel e ao efeito de massa que pode ocasionar escurecimento da imagem comprometendo a detecção de um possível câncer entre outras razões de ponto de vista clínico (LITJENS OSCAR DEBATS, 2012).

3.1.2 Prostate 3T

A Prostate 3T é uma base de exames de ressonância magnética (RM) de próstata, foi obtida a partir do desafio de segmentação automática de estruturas da próstata do Arquivo Nacional de Imagens de Câncer (NCIA). A base tem 30 exames de RM ponderados T2, juntamente com a marcação da próstata feita pelo especialista. Todas as imagens estão no formato DICOM e têm 320 x 320 de dimensões com 16 bits por *voxel*, espaçamento de 0,6 x 0,6 x 4,0 mm^3 e espessura de fatia de 4 mm. O número de fatias varia de 15 a 24. A base de imagens foram adquiridas em diferentes hospitais a partir de diferentes protocolos scanner *Siemens* 3.0T usando uma bobina endorretal (ERC) ou uma bobina de matriz em fases (PAC) pélvica (TURKB EY et al., 2011).

3.1.3 PH²

A base de imagens PH² foi adquirida a partir de um repositório público fornecida pelo no Serviço de Dermatologia do Hospital Pedro Hispano, Matosinhos, Portugal com o sistema *Tuebinger Mole Analyzer* ampliados 20 vezes. As imagens dermatoscópicas em cores RGB de 8 bits são obtidas nas mesmas condições com uma resolução de 768 × 560. Este conjunto de dados contém 200 imagens dermatoscópicas divididas em 80 benignas, 80 displásicas e 40 lesões de melanoma. As lesões são segmentadas e seu diagnóstico histológico é por um especialista (MENDONCA et al., 2015).

3.1.4 Montgomery County chest X-ray set

A Biblioteca Nacional de Medicina dos EUA disponibilizou dois conjuntos de dados de radiografias de tórax: o aparelho de raios X do Condado de Montgomery (MC) e o aparelho de Shenzhen. O conjunto de MC contém 138 radiografia torácica frontal do programa de rastreamento de tuberculose no Condado de Montgomery, dos quais 80 são casos normais e 58 são casos com manifestações de tuberculose. O conjunto de Shenzhen contém 662 radiografias frontais, das quais 326 são casos normais e 336 são casos de tuberculose (AMERICA; RSNA; RADIOLOGY,).

3.1.5 RIM-ONE

A base de imagens de glaucoma RIM-ONE, disponível da Internet, contém três versões (TRUCCO ALFREDO RUGGERI, 2013). Este trabalho utilizou a versão 2 que possui 455 imagens separadas em 2 classes glaucoma com 200 imagens e suspeito com 255

imagens. Neste trabalho é utilizado apenas as imagens de glaucoma. Estas imagens foram fornecidas por três hospitais: Hospital Universitário de Canarias, Hospital Clínico San Carlos e Hospital Universitário Miguel Servet. As imagens são disponibilizadas no formato JPEG, o sistema de cores é RGB (Red, Green, Blue). Cada imagem possui sua respectiva marcação feita pelo especialista (TRUCCO ALFREDO RUGGERI, 2013).

3.2 Modelagem do problema de otimização

A partir da aquisição das imagens, como mostrado na Figura 15, a etapa de seleção automática de pré-processamentos pode ser solucionada a partir de técnicas de otimização. O algoritmo de otimização aplicado para seleção de pré-processamentos foi o algoritmo PSO em conjunto com a técnica de *superpixel* IMSLIC, ambas técnicas descritas respectivamente nas, Seção 2.2.1 e Seção 2.1.2. A técnica PSO tem como características permitir a possibilidade de mesclar valores reais juntamente com valores binários na composição de suas partículas, além de possuir rápida convergência.

Na modelagem do problema levou-se em consideração a quantidade de técnicas de pré-processamento que serão aplicadas bem como a ordem em que estas serão aplicadas. Desta forma, uma partícula terá as $N - 1$, sendo N o tamanho da partícula, primeiras coordenadas representando as técnicas de melhoramento de imagens utilizadas com valores binários (0 ou 1), correspondendo a aplicação ou não da técnica, além da última coordenada que representa a ordem de aplicação com valores inteiros entre 1 e $(N - 1)!$, significando todas as possíveis permutações da ordem de aplicação. Uma representação da partícula pode ser vista na Figura 16.




Figura 16 – Representação da partícula. (a) Cada posição entre 1 e $(N - 1)$ representa uma técnica de pré-processamento específica, que será aplicada ou não, representada pelos valores binários (0 ou 1). (b) A posição N representa a ordem de aplicação dos pré-processamentos, onde neste exemplo foi utilizado o código de ordenação cujo o valor é 7.

3.2.1 Codificação

A codificação do vetor de coordenadas de uma partícula é composto pelo conjunto das possíveis técnicas de melhoramento e a ordem em que estas serão aplicadas. A coordenada responsável por representar a ordem em que os pré-processamentos serão aplicados corresponde a um vetor de posições onde cada posição representa uma combinação de pré-processamentos contida no conjunto de todas as permutações possíveis, como pode ser visto na Figura 17.




Figura 17 – Representação visual do processo de decodificação da partícula em técnicas aplicadas na imagem.

- Coordenadas que representam quais pré-processamentos serão aplicados onde, para este exemplo foram utilizadas um total de 7 técnicas de melhoramento compondo as 7 primeiras coordenadas da partícula.
- Coordenada que representa a ordem em que os pré-processamentos serão aplicados, onde foi exemplificado o ordem de valor 4.
- Conjunto que representa todas as possíveis combinações de ordenação dos pré-processamentos.
- Conjunto de pré-processamentos definidos pelo usuário, neste exemplo foram definidas 7 técnicas de melhoramento.
- Código de ordenação que representa a sequência de aplicação dos pré-processamentos, neste exemplo foram demonstrados os 6 primeiros e os 6 últimos códigos de ordenação.

- f) Sequência usada pela partícula.
- g) Pré-processamentos que serão aplicados nesta partícula.
- h) Pré-processamentos que não serão aplicados.
- i) Ordem em que os pré-processamentos serão aplicados.

3.2.2 Agrupamento e classificação dos *superpixels*

Como subsidio para avaliação da qualidade de determinada ordem e conjunto de pré-processamentos, utilizou-se o *superpixel* como unidade básica de representação dos componentes pertencentes a imagem, como forma de extrair a região de interesse desta. Onde, no caso das bases 3D, por conta da desregularidade do espaçamento entre fatias, o agrupamento e a classificação foram realizadas fatia a fatia. A técnica de *superpixel* foi utilizada pois, além de reduzir o custo computacional, favorece com menor influência de ruídos, por esta ser mais robusta que a abordagem convencional baseada em *pixels*.

Para o agrupamento, o algoritmo IMSLIC, descrito na Seção 2.1.2, foi aplicado nesta subetapa. Este algoritmo possui dois parâmetros, o tamanho e o valor de compactação do *superpixel*. A técnica IMSLIC possui flexibilidade quanto a variação em tamanho e forma do *superpixel* com relação a superfície da imagem onde esta técnica é aplicada, pois possui facilidade em detectar características não homogêneas em uma imagem, apresentando pequenos *superpixels* em regiões com vasta dissimilaridade e *superpixels* grandes em regiões de conteúdo semelhante (LIU et al., 2017).

Com relação a classificação dos *superpixels*, é necessário rotular os *superpixels* em região que deseja segmentar e fundo, ou seja os outros componentes da imagem. Para isso é necessário classificar os *superpixels* em duas classes: região de interesse e não interesse. Para atribuir o rótulo de região de interesse aos *superpixels* utilizou-se a marcação do especialista. Um *superpixel* é considerado região de interesse caso haja pelo menos 70% de seus *pixels* encontrados na marcação do especialista. Caso um *superpixel* não obtiver uma proporção maior que 70%, ele será ignorado para evitar que *superpixel* que intercepta apenas área de borda da região de interesse seja classificado como região de interesse. Os demais *superpixels* são classificados como região de não interesse.

3.2.3 Função objetivo

A função de avaliação de uma determinada partícula candidata à solução, função objetivo ou *fitness*, é baseada no coeficiente de similaridade Dice, descrito na Seção 2.4.1, que é calculado a partir da marcação do especialista e o conjunto de *superpixels* das imagens pré-processadas classificados como região de interesse. Esta função leva em consideração o quanto a área composta por bordas e regiões uniformes pertencentes aos *superpixels*

classificados como região de interesse, na imagem com pré-processamento, são similares a área da marcação feita pelo especialista.

3.3 Execução do Algoritmo PSO

Para a execução do algoritmo PSO é necessário a definição de alguns parâmetros para sua inicialização. Para isso utilizou-se parâmetros convencionais da literatura. Como Kennedy, Eberhart e Shi (2001), propuseram no algoritmo clássico do método que fixa as constantes $c1$ e $c2$ com o valor 2, e a constante de inércia w com o valor de 0,7, dentro do intervalo 0,2 e 0,9 por eles proposto.

Após a definição dos parâmetros, cada partícula que compõe o enxame inicial, é inicializada aleatoriamente onde: as partículas referentes aos pré-processamentos são inicializadas com valores binários (0 ou 1) randômicos, e a última partícula referente a ordem em que essas técnicas de melhoramento serão aplicadas é inicializada com valores randômicos no intervalo de 1 e $(N - 1)!$, ou seja este intervalo consiste no número total de possíveis combinações de ordem de pré-processamentos.

Cada partícula iniciada no enxame é avaliada baseada no algoritmo de *superpixels* IMSLIC. Onde cada partícula é submetida individualmente a avaliação, utilizando a métrica de similaridade Dice, sob seu conjunto de *superpixels* classificados como região de interesse e a marcação feita pelo especialista.

Em cada iteração do algoritmo, cada partícula atualiza sua posição e velocidade de acordo com sua melhor posição alcançada, ($Pbest$) no espaço de busca, considerando também a melhor posição em todo o enxame ($Gbest$). O algoritmo PSO é repetido até que o número máximo de iterações seja atingido. Ao final da execução do PSO, a partícula representada como a $Gbest$ é constituída pelo melhor conjunto ótimo de técnicas e a melhor sequência ótima que estas técnicas devem ser aplicadas para o processo de segmentação. As etapas na execução do algoritmo PSO pode ser vista na Figura 18.

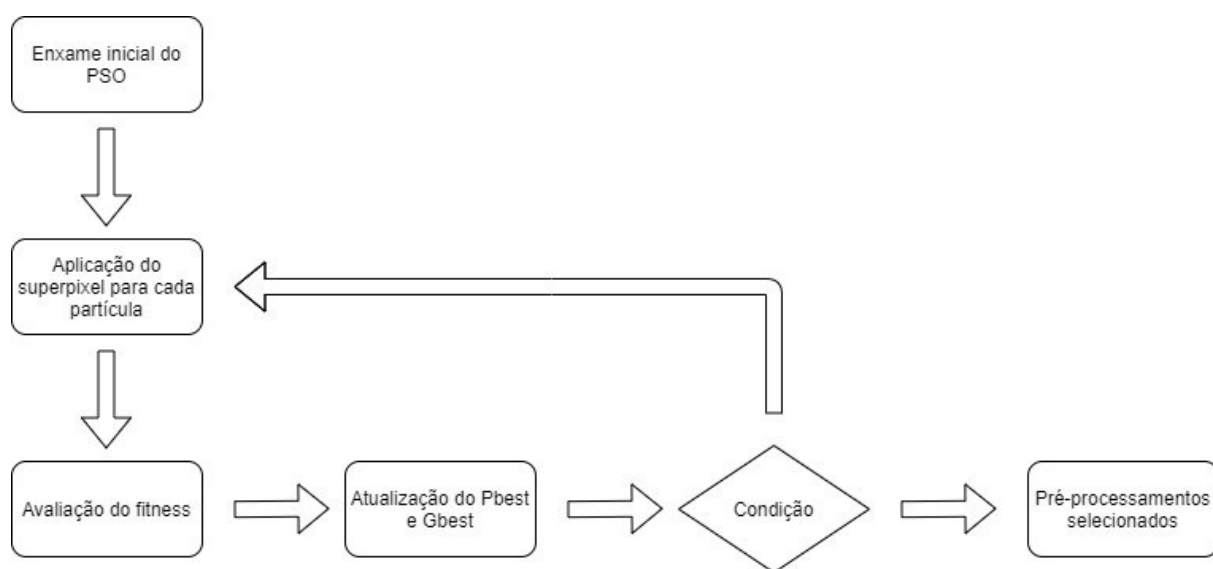


Figura 18 – Etapas do algoritmo PSO.

4 Resultados e Discussão

Neste capítulo são apresentados e discutidos os resultados obtidos nos testes efetuados a partir do método proposto para seleção automática do conjunto e ordem de aplicação dos pré-processamentos. Todos os experimentos foram implementados na linguagem de programação Python com auxílio das bibliotecas SimpleITK ([SIMPLEITK...](#),) e OpenCV ([OPENCV...](#),), executando em uma máquina com processador Intel Core i7-9700K, 16GB de RAM, GeForce RTX 2070 de 8 GB e sistema operacional Windows.

Para todos os experimentos realizados os parâmetros foram atribuídos ao algoritmo PSO da seguinte forma. As constantes cognitiva e social receberam ambas o valor 2,0 conforme a literatura demonstra que fixando estas constantes neste valor proporciona soluções mais satisfatórias ([KENNEDY; EBERHART; SHI, 2001](#)). A constante de inércia recebeu o valor de 0,7 dentro do intervalo, de 0,2 e 0,9, proposto na literatura ([KENNEDY; EBERHART; SHI, 2001](#)). O tamanho do enxame e o número de iterações foi definido como 20. Na Tabela 1 apresenta os parâmetros do algoritmo PSO.

Tabela 1 – Parâmetros definidos para o algoritmo PSO na etapa de execução.

Parâmetro	Valor
Tamanho do enxame	20
Número de iterações	20
Constante de inércia	0,7
Parâmetro cognitivo	2
Parâmetro social	2

Os parâmetros aplicados ao algoritmo IMSLIC mudaram para cada base de imagens, onde sua definição foi atribuída empiricamente. Para o tamanho médio do *superpixel* foi levado em consideração as dimensões de cada base de imagens e o tamanho da marcação feita pelo especialista. Para o fator de compacidade, optou-se por gerar *superpixels* com formas mais regulares. Segundo [Achanta et al. \(2010\)](#) um fator de compacidade pequeno reflete quão sensível e ajustado ao espaço de cores será o *superpixel* ou seja, quanto maior este fator, maior a robustez em relação a dissimilaridade de cores, e portanto a forma do *superpixel* será mais regular, ocorrendo no caso contrário. Este fator alterou-se para cada base de imagens.

A técnicas de pré-processamento passadas para o algoritmo PSO mudaram com relação as bases 2D e 3D. Para a base 3D de imagens de exames RM da próstata o conjunto de técnicas passados ao algoritmo PSO foi baseado no estado-da-arte em segmentação de próstata em imagens de RM. As técnicas escolhidas foram: especificação do histograma,

quantização uniforme em 8 bits, difusão anisotrópica do gradiente e correção de *bias field*, a definição da partícula para esta base pode ser vista na Tabela 2. Para as bases de imagens 2D foram utilizadas a mescla de técnicas de realce e filtros passa-baixa. As técnicas utilizadas foram: filtro da média, filtro gaussiano, filtro da mediana, CLAHE, máscara de nitidez e técnica de aprimoramento de contraste baseado em decomposição intrínseca, a definição da partícula para estas bases pode ser vista na Tabela 3.

Tabela 2 – Definição das partículas da etapa de pré-processamento no método proposto para a base 3D.

Coordenadas da partícula	Pré-processamento
x_1	Especificação do histograma
x_2	Quantização uniforme
x_3	Difusão anisotrópica do gradiente
x_4	Correção de <i>bias field</i>
x_5	Ordem da aplicação

Tabela 3 – Definição das partículas da etapa de pré-processamento no método proposto para bases 2D.

Coordenadas da partícula	Pré-processamento
x_1	Filtro da média
x_2	Filtro da gaussiana
x_3	Filtro da mediana
x_4	CLAHE
x_5	Máscara de nitidez
x_6	Aprimoramento de contraste baseado em decomposição intrínseca
x_7	Ordem da aplicação

4.1 Avaliação dos pré-processamentos selecionados para bases de imagem de exames de RM da próstata

Na etapa de execução do algoritmo PSO descritos na Seção 3.3, aplicada para a base de imagens de exames de RM da próstata, utilizada em conjunto com o algoritmo IMSLIC para otimizar a escolha e a ordem das técnicas de melhoramento aplicadas. Para calcular o *fitness* da partícula, foi utilizado o algoritmo IMSLIC para agrupar todas as imagens em *superpixels*. Os parâmetros do algoritmo IMSLIC foram definidos empiricamente como: tamanho base 25×25 e fator de compacidade como 10.

A Tabela 4 apresenta os as melhores partículas no conjunto de imagens da próstata ao final da execução do algoritmo PSO. A melhor partícula obteve o coeficiente de similaridade Dice médio de 85,10% com a aplicação apenas do filtro difusão anisotrópica do gradiente. Além disso, a Tabela 4 demonstra o resultado sem a aplicação de pré-processamentos na etapa de execução do algoritmo PSO. O tempo de execução total da otimização da seleção de pré-processamentos foi de aproximadamente 5 horas.

Tabela 4 – Resultados obtidos na etapa de execução do algoritmo PSO para a base de exames de RM da próstata. Especificação do histograma (HM), quantização uniforme em 8 bits (UQ), difusão anisotrópica do gradiente (GAD) e correção de *bias field* (BFC).

Técnicas de melhoramento aplicadas em sequência	DSC (%)
GAD	85,10
HM, GAD e UQ	80,93
GAD e UQ	77,85
UQ, GAD e HM	76,48
BFC, GAD, UQ e HM	75,82
Sem pré-processamento	59,71

Fazendo a análise da Tabela 4, percebe-se a escolha pelo filtro difusão anisotrópica do gradiente para as cinco melhores partículas do exame final. Esse fato deve-se a característica do filtro em reduzir os ruídos da imagem, preservando as informações de borda. Logo os *superpixels* adaptam-se melhor a borda tendo em vista que a medida que os ruídos são reduzidos o filtro de difusão anisotrópica do gradiente preserva as bordas.

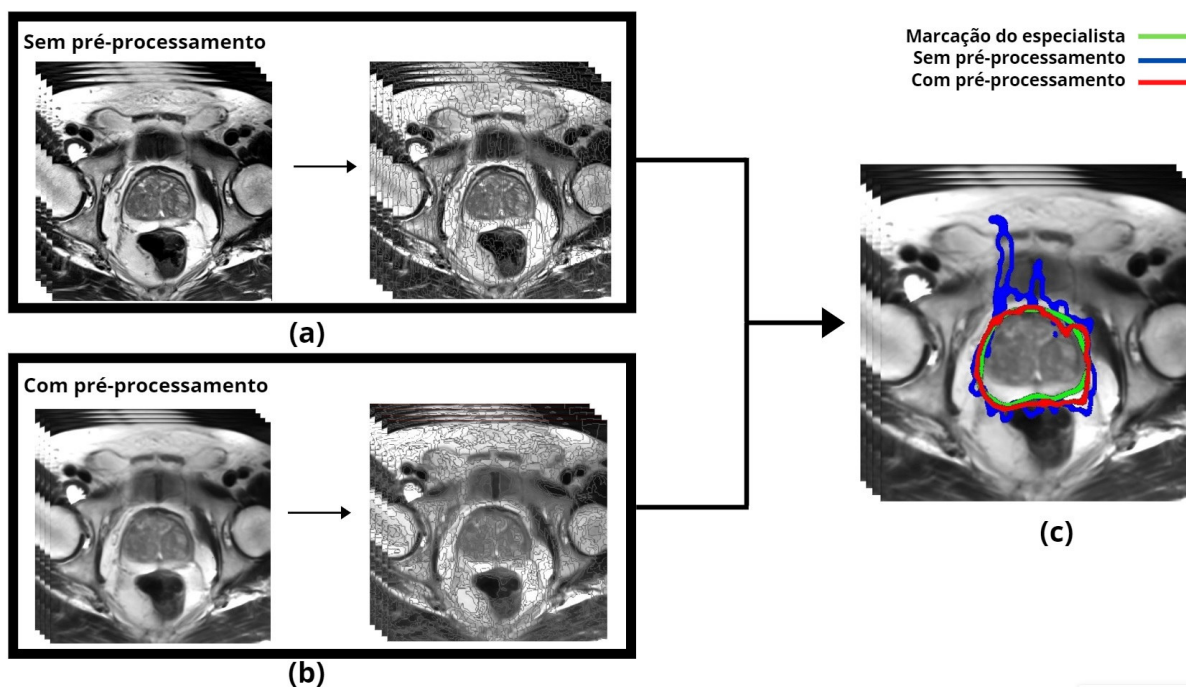


Figura 19 – Avaliação qualitativa da etapa de execução do algoritmo PSO para a base de exames de RM da próstata. (a) Fatia sem nenhum pré-processamento, (b) a mesma pré-processada com o filtro difusão anisotrópica do gradiente e a (c) imagem pré-processada com a delimitação do conjunto de *superpixels* marcados como região de interesse.

A Figura 19 apresenta uma avaliação qualitativa dos resultado adquirido após a execução do algoritmo PSO. Na Figura 19 (a) apresenta uma fatia de RM sem nenhum pré-processamento. A Figura 19 (b) está ilustrada a mesma fatia pré-processada com o filtro difusão anisotrópica do gradiente. Nota-se que a imagem pré-processada apresenta

uma textura mais homogênea resultando em *superpixels* que adaptam-se melhor a próstata na imagem pré-processada.

4.2 Avaliação dos pré-processamentos selecionados para base de imagens dermatoscópicas

Na etapa de execução do algoritmo PSO descritos na Seção 3.3, para a base de imagens dermatoscópicas, os parâmetros do algoritmo IMSLIC foram definidos empiricamente como: tamanho base 200×200 e fator de compacidade como 200.

A Tabela 5 apresenta as melhores partículas para o conjunto de imagens dermatoscópicas ao final da execução do algoritmo PSO. A melhor partícula obteve o coeficiente de similaridade Dice médio de 95,05% com a aplicação apenas da técnica de realce CLAHE. Além disso, a Tabela 5 demonstra o resultado sem a aplicação de pré-processamentos na etapa de execução do algoritmo PSO. O tempo de execução total da otimização da seleção de pré-processamentos foi de aproximadamente 5 horas.

Tabela 5 – Resultados obtidos na etapa de execução do algoritmo PSO para base de imagens dermatoscópicas. Aprimoramento de contraste baseado em decomposição intrínseca (DI), Equalização de histograma adaptativo limitado por contraste (CLAHE), Máscara de nitidez (MN).

Técnicas de melhoramento aplicadas em sequência	DSC (%)
CLAHE	95,05
DI e MN	94,64
MN e DI	94,56
CLAHE e DI	94,52
MN e CLAHE	94,39
Sem pré-processamento	92,40

Analisando a Tabela 5, pode-se notar a ocorrência da escolha da técnica CLAHE entre três das 5 partículas melhores ranqueadas. Esse resultado deve-se a natureza dessas técnicas de realçar e distinguir intensidades similares. Logo os *superpixels* gerados pelo algoritmo IMSLIC adaptam-se melhor as mudanças de tecidos devido esse realce feito por estes métodos.

A Figura 20 demonstra uma avaliação qualitativa da etapa de execução do algoritmo PSO. Na Figura 20 (a) apresenta uma imagem dermoscópica sem nenhum pré-processamento. A Figura 20 (b) está ilustrada a mesma imagem pré-processada com a técnica de realce CLAHE. Nota-se que os *superpixels* adaptam-se melhor a lesão na imagem pré-processada. É possível observar também, que os *superpixels* receberam uma redução da área isso ocorre por conta do realce dos detalhes no tecido fazendo com que haja uma distinção das intensidades similares na imagem, conseqüentemente a região lesão,

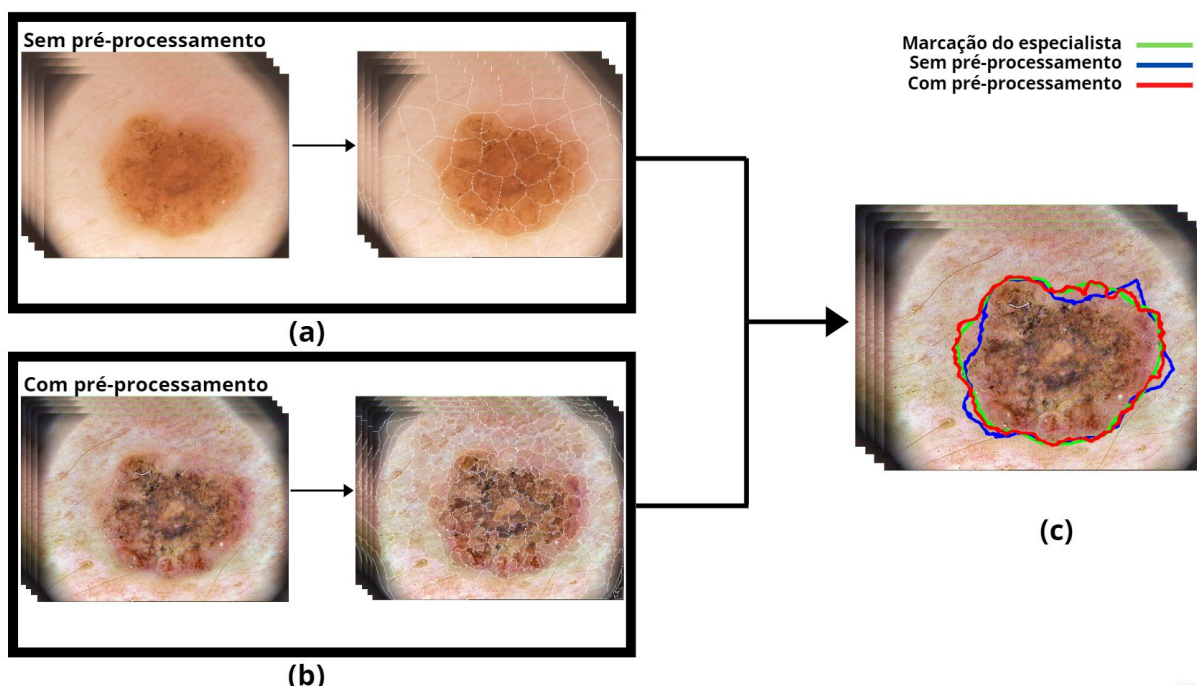


Figura 20 – Avaliação qualitativa da etapa de execução do algoritmo PSO para base de imagens dermatográficas. (a) Imagem dermatográfica sem aplicação de pré-processamentos, (b) a mesma imagem aplicada a técnica de realce CLAHE e (c) imagem pré-processada com a delimitação do conjunto de *superpixels* marcados como região de interesse.

a qual foi marcada pelo especialista, obteve realce de intensidades mais escuras e a região de não lesão intensidades mais claras.

4.3 Avaliação dos pré-processamentos selecionados para bases de imagens radiográficas do tórax para segmentação do pulmão

Para a execução do algoritmo PSO, aplicado a base de radiografia do tórax, os parâmetros do algoritmo IMSLIC foram definidos empiricamente como: tamanho médio base 50×50 e fator de compacidade como 50.

A Tabela 6 apresenta as melhores partículas para o conjunto de imagens radiográficas do tórax para segmentação do pulmão na última iteração do algoritmo PSO. A melhor partícula obteve o coeficiente de similaridade Dice médio de 93,52% com a aplicação da técnica de máscara de nitidez e CLAHE. Além disso, a Tabela 6 demonstra o resultado sem a aplicação de pré-processamentos na etapa de execução do algoritmo PSO. O tempo de execução total da otimização da seleção de pré-processamentos foi de aproximadamente 5 horas.

Analisando a Tabela 6, pode-se notar a escolha das técnicas de realce CLAHE presente em todas as cinco melhores partículas além da técnica de máscara de nitidez

Tabela 6 – Resultados obtidos na etapa de execução do algoritmo PSO para base de imagens radiográfica do tórax. Aprimoramento de contraste baseado em decomposição intrínseca (DI), Equalização de histograma adaptativo limitado por contraste (CLAHE), Máscara de nitidez (MN).

Técnicas de melhoramento aplicadas em sequência	DSC (%)
MN e CLAHE	93,52
CLAHE e MN	93,46
DI, MN e CLAHE	93,25
DI, CLAHE e MN	93,24
DI e CLAHE	93,05
Sem pré-processamento	90,52

ter sido selecionada nas 4 primeiras partículas. Esse resultado deve-se a natureza dessas técnicas que é realçar e distinguir regiões similares aumentando da nitidez destas regiões. Logo, os *superpixels* gerados pelo algoritmo IMSLIC adaptam-se melhor as mudanças de tecidos devido esse realce feito por estes métodos.

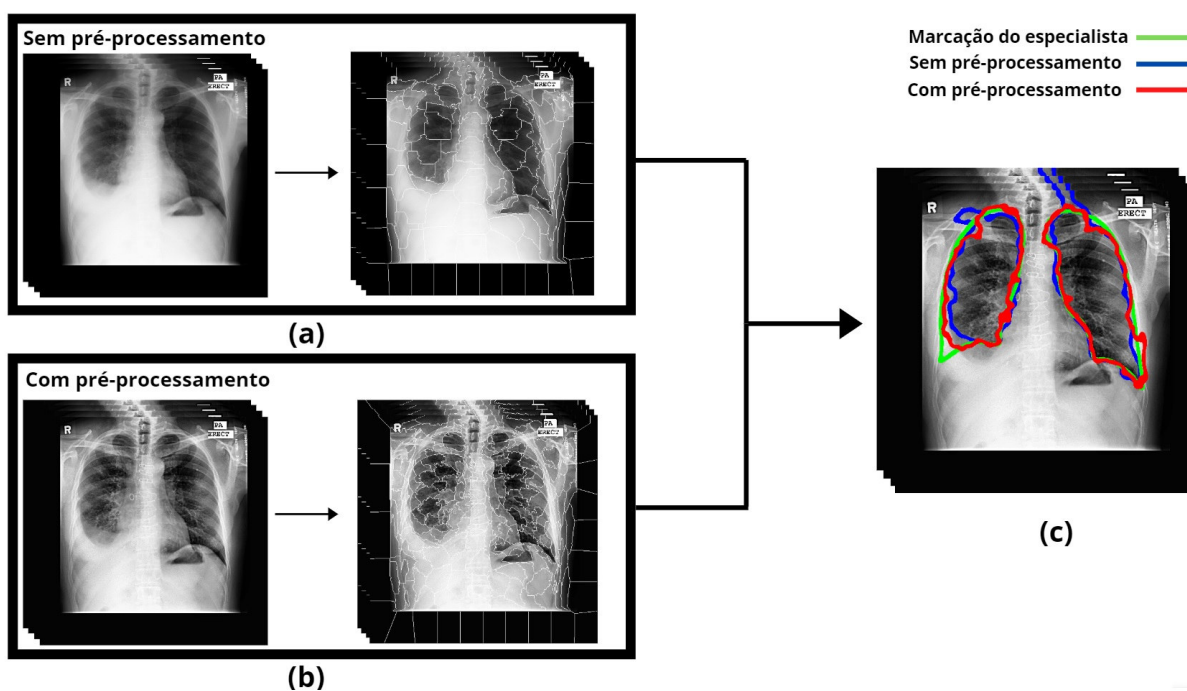


Figura 21 – Avaliação qualitativa da etapa de execução do algoritmo PSO para a base de imagens radiográficas do tórax. (a) Imagem radiográfica sem nenhum pré-processamento, (b) a mesma imagem pré-processada com as técnicas de realce máscara de nitidez e CLAHE e (c) imagem pré-processada com a delimitação do conjunto de *superpixels* marcados como região de interesse.

A Figura 22 demonstra uma avaliação qualitativa da etapa de execução do algoritmo PSO. Na Figura 22 (a) ilustra uma imagem radiográfica do tórax pré-processada com as técnicas CLAHE e a máscara de nitidez. A Figura 22 (b) apresenta a mesma fatia sem nenhum pré-processamento. Nota-se que os *superpixels* adequaram-se melhor aos

pulmões na imagem pré-processada. Também, é possível notar o clareamento das regiões consideradas não pulmão.

4.4 Avaliação dos pré-processamentos selecionados para base de imagens de glaucoma

Na etapa de execução do algoritmo PSO para a base de imagens de glaucoma, os parâmetros do algoritmo IMSLIC foram definidos empiricamente como: tamanho base 100×100 e fator de compacidade como 100.

A Tabela 7 apresenta as melhores partículas para o conjunto de imagens de glaucoma na última iteração do algoritmo PSO. A melhor partícula obteve o coeficiente de similaridade Dice médio de 93,98% com a aplicação das técnicas de aprimoramento de contraste baseado em decomposição intrínseca, CLAHE e máscara de nitidez. Além disso, a Tabela 7 demonstra o resultado sem a aplicação de pré-processamentos na etapa de execução do algoritmo PSO. O tempo de execução total da otimização da seleção de pré-processamentos foi de aproximadamente 5 horas.

Tabela 7 – Resultados obtidos na etapa de execução do algoritmo PSO para base de glaucoma. Aprimoramento de contraste baseado em decomposição intrínseca (DI), Equalização de histograma adaptativo limitado por contraste (CLAHE), Máscara de nitidez (MN).

Técnicas de melhoramento aplicadas em sequência	DSC (%)
DI,CLAHE,MN	93,98
MN, CLAHE e DI	93,29
CLAHE, MN e DI	93,22
MN e CLAHE	92,16
CLAHE e MN	92,13
Sem pré-processamento	86,46

Analisando a Tabela 7, pode-se notar que entre as três melhores partículas possuem combinações destes três pré-processamentos. Ou seja, a utilização destas três técnicas conjuntas contribui no aumento da nitidez e do realce das regiões de interesse, devido a característica destas técnicas de realçar e distinguir regiões com tecidos similares, aumentando sua nitidez, preservando a intensidade das regiões claras. Logo os *superpixels* gerados pelo algoritmo IMSLIC conseguem detectar melhor a região de interesse por conta desse realce feito por estas três técnicas de melhoramento em conjunto.

A Figura 22 demonstra uma avaliação qualitativa da etapa de execução do algoritmo PSO. Na Figura 22 (a) apresenta uma imagem sem nenhum pré-processamento. A Figura 22 (b) está ilustrada a mesma imagem com as técnicas de realce aprimoramento de contraste baseado em decomposição intrínseca, CLAHE e máscara de nitidez. Nota-se que

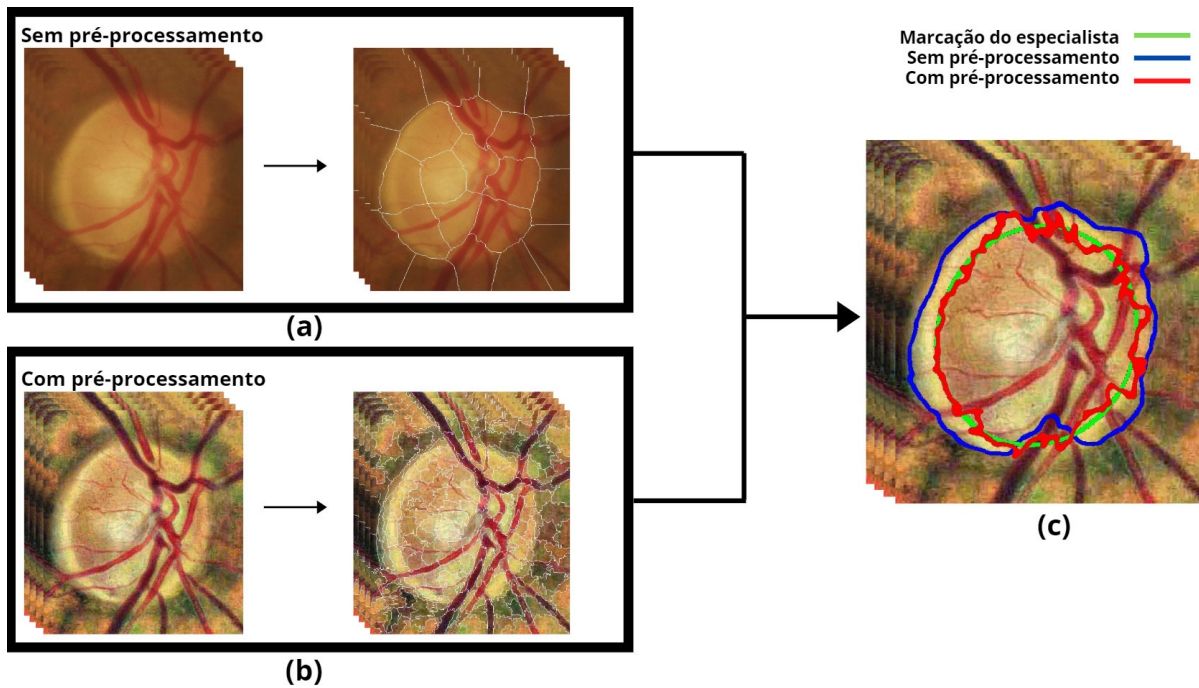


Figura 22 – Avaliação qualitativa da etapa de execução do algoritmo PSO para base de imagens de glaucoma. (a) A imagem sem pré-processamento, (b) a mesma imagem aplicada as técnicas aprimoramento de contraste baseado em decomposição intrínseca, CLAHE e máscara de nitidez e (c) imagem pré-processada com a delimitação do conjunto de *superpixels* marcados como região de interesse.

a imagem pré-processada apresenta maior realce da região de glaucoma, conseqüentemente, os *superpixels* adaptam-se melhor a região de glaucoma na imagem pré-processada.

5 Conclusão

A aplicação de pré-processamentos é uma etapa muita das vezes, necessária em processamento de imagens. A escolha de pré-processamentos pode ser determinante para etapas posteriores, como a segmentação. A seleção automática de pré-processamento pode ser uma alternativa eficiente como auxílio na decisão de quais técnicas de melhoramento aplicar, visto que a escolha das técnicas manualmente depende do conhecimento prévio, ou obtido durante o estudo do profissional sobre o domínio do problema. Isso evidencia a importância do desenvolvimento de métodos para a seleção automáticas de pré-processamentos que melhorem o processos posteriores, como exemplo o processo de segmentação.

Este trabalho propôs um método de seleção automática de pré-processamentos para segmentação de imagens. A etapa de aplicação do algoritmo PSO utilizou informações de textura local usando a técnica de segmentação por *superpixel* IMSLIC e o coeficiente de similaridade Dice para selecionar e avaliar a melhor ou as melhores técnicas e em qual a ordem de aplicação estas devem ser aplicadas.

A partir dos resultados obtidos, observa-se a eficácia do método proposto, apresenta em todos os casos de teste o aumento no Dice, garantindo que em geral, os componentes pertencentes a imagem tiveram realce em suas bordas e estruturas facilitando assim uma melhor adequação do *superpixel*. Além da utilização de bases de imagens diferentes, que demonstra que o método é invariante ao domínio do problema e mantém-se consistente independente do conjunto de imagens que a metodologia é aplicada.

Para trabalhos futuros, sugere-se um aprofundamento sobre outras formas de avaliação das melhores técnicas aplicadas para cada partícula no algoritmo PSO, que envolvesse outras características da imagem como por exemplo a variação média das intensidades de *pixel* ou *voxel* do objeto de interesse que deseja segmentar com relação ao restante da imagem. Esta forma de avaliação aperfeiçoaria a função objetivo atual, uma vez que agora seria levado em conta não apenas informação de forma, mas de intensidade de *pixel* agregando valor a função *fitness* aplicada ao algoritmo PSO.

Referências

- ACHANTA, R. "slic superpixels compared to state-of-the-art superpixel methods". *"IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE"*, 2012. Citado na página 15.
- ACHANTA, R.; SHAJI, A.; SMITH, K.; LUCCHI, A.; FUA, P.; SÜSSTRUNK, S. Slic superpixels. 2010. Citado 3 vezes nas páginas 26, 27 e 39.
- ALSABTI, K.; RANKA, S.; SINGH, V. An efficient k-means clustering algorithm. 1997. Citado na página 27.
- AMERICA, R. S. of N.; RSNA; RADIOLOGY, A. C. of. *Chest X-ray (Radiograph)*. Disponível em: <<https://www.radiologyinfo.org/en/info.cfm?pg=chestradi>>. Citado 2 vezes nas páginas 32 e 33.
- BAN JIANGUO LIU, L. C. Z. "superpixel segmentation using gaussian mixture model". *"IEEE Transactions on Image Processing"*, 2018. Citado na página 15.
- CRÓSTA, A. P. *Processamento digital de imagens de sensoriamento remoto*. [S.l.]: UNICAMP/Instituto de Geociências, 1992. Citado na página 30.
- EBERHART, R.; KENNEDY, J. A new optimizer using particle swarm theory. In: IEEE. *MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science*. [S.l.], 1995. Citado na página 29.
- ELGENDY, M. *Deep Learning for Vision Systems*. [S.l.]: Manning, 2018. Citado na página 15.
- ENGELBRECHT, A. P. *COMPUTATIONAL INTELLIGENCE: an introduction*. [S.l.]: JOHN WILEY, 2008. Citado na página 16.
- GABRIEL, P. H. R.; DELBEM, A. C. B. *Fundamentos de algoritmos evolutivos*. [S.l.]: ICMC-USP, 2008. Citado 2 vezes nas páginas 16 e 28.
- GONZALEZ, R. E. W. R. C. *Processamento Digital de Imagens*. [S.l.]: Pearson, 2000. Citado 9 vezes nas páginas 10, 15, 18, 19, 20, 21, 24, 25 e 30.
- HELIO, P.; SCHWARTZ, W. R. *Análise de imagens digitais princípios, algoritmos e aplicações*. [S.l.]: Thomson Learning, 2008. Citado 2 vezes nas páginas 18 e 25.
- KENNEDY, J.; EBERHART, R. C.; SHI, Y. *Swarm intelligence*. [S.l.]: Morgan Kaufmann, 2001. Citado 3 vezes nas páginas 16, 37 e 39.
- KRIG, S. *Computer Vision Metrics*. [S.l.]: ApressOpen, 2014. Citado na página 15.
- LITJENS OSCAR DEBATS, W. v. d. V. N. K. H. H. G. A pattern recognition approach to zonal segmentation of the prostate on mri. In: _____. [S.l.]: Springer Berlin Heidelberg, 2012. p. 413–420. Citado 2 vezes nas páginas 32 e 33.

- LIU, Y.-J.; YU, M.; LI, B.-J.; HE, Y. Intrinsic manifold slic: a simple and efficient method for computing content-sensitive superpixels. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, v. 40, n. 3, p. 653–666, 2017. Citado 3 vezes nas páginas 27, 28 e 36.
- MENDONCA, T.; CELEBI, M.; MENDONCA, T.; MARQUES, J. Ph2: A public database for the analysis of dermoscopic images. *Dermoscopy image analysis*, CRC Press, 2015. Citado 2 vezes nas páginas 32 e 33.
- OPENCV modules. Disponível em: <<https://docs.opencv.org/master/>>. Citado na página 39.
- PERONA, P.; SHIOTA, T.; MALIK, J. Anisotropic diffusion. In: *Geometry-driven diffusion in computer vision*. [S.l.]: Springer, 1994. Citado na página 26.
- POLESEL A., G. R. e. a. "adaptive unsharp masking for contrast enhancement". *"International Conference on"*, 1997. Citado na página 24.
- QUEIROZ, H. M. G. José Eustáquio Rangel de. Introdução ao processamento digital de imagens. 2006. Citado na página 15.
- REN, X.; MALIK, J. Learning a classification model for segmentation. 2003. Citado na página 26.
- SHI, Y.; EBERHART, R. Empirical study of particle swarm optimization. *Proceedings of the 1999 Congress on Evolutionary Computation-CEC99 (Cat. No. 99TH8406)*, 1999. Citado na página 16.
- SIMPLEITK Sphinx Documentation¶. Disponível em: <<https://simpleitk.readthedocs.io/en/master/#>>. Citado na página 39.
- SIVAKUMAR, S. M. P. "a review on image segmentation techniques". *"International Journal of Advanced Research in Computer Engineering Technology"*, v. 5, 2016. Citado na página 15.
- SONG, S.; ZHENG, Y.; HE, Y. A review of methods for bias correction in medical images. *Biomedical Engineering Review*, v. 1, n. 1, 2017. Citado na página 23.
- TRUCCO ALFREDO RUGGERI, T. K. L. G. E. C. J. P. H. B. a.-D. C. Y. C. D. W. M. A. G. L. D. K. P. B. N. M. B. H. F. J. F. M. G. Q. T. M. B. D. E. Validating retinal fundus image analysis algorithms: Issues and a proposal. *Investigative Ophthalmology Visual Science*, v. 54, n. 5, p. 3546, 5 2013. Citado 2 vezes nas páginas 33 e 34.
- TURKBEY, B.; MANI, H.; SHAH, V.; RASTINEHAD, A. R.; BERNARDO, M.; POHIDA, T.; PANG, Y.; DAAR, D.; BENJAMIN, C.; MCKINNEY, Y. L. et al. Multiparametric 3t prostate magnetic resonance imaging to detect cancer: histopathological correlation using prostatectomy specimens processed in customized magnetic resonance imaging based molds. *The Journal of urology*, Wolters Kluwer Philadelphia, PA, v. 186, n. 5, p. 1818–1824, 2011. Citado 2 vezes nas páginas 32 e 33.
- TUSTISON, N. J.; AVANTS, B. B.; COOK, P. A.; ZHENG, Y.; EGAN, A.; YUSHKEVICH, P. A.; GEE, J. C. N4itk: improved n3 bias correction. *IEEE transactions on medical imaging*, IEEE, v. 29, n. 6, p. 1310–1320, 2010. Citado na página 23.

- VIDAL, J. M. A. M. Chemometrics and intelligent laboratory systems. Elsevier, 2012. Citado na página 16.
- YE, Z.; YI, R.; YU, M.; LIU, Y.-J.; HE, Y. Fast computation of content-sensitive superpixels and supervoxels using q-distances. In: *Proceedings of the IEEE International Conference on Computer Vision*. [S.l.: s.n.], 2019. p. 3770–3779. Citado 3 vezes nas páginas 10, 28 e 29.
- YUE, H.; YANG, J.; SUN, X.; WU, F.; HOU, C. Contrast enhancement based on intrinsic image decomposition. *IEEE Transactions on Image Processing*, IEEE, v. 26, n. 8, 2017. Citado na página 22.
- ZUIDERVELD, K. Contrast limited adaptive histogram equalization. In: ACADEMIC PRESS PROFESSIONAL, INC. *Graphics gems IV*. [S.l.], 1994. Citado na página 21.