



Universidade Federal do Piauí
Centro de Ciências da Natureza
Programa de Pós-Graduação em Ciência da Computação

Avaliação de Algoritmos de Superpixels e Descritores de Textura Para Segmentação das Regiões do Disco Óptico

Marcos Antônio de Sousa Frazão

Número de Ordem PPGCC: M029

Teresina-PI, 28 de Abril de 2017

Marcos Antônio de Sousa Frazão

Avaliação de Algoritmos de Superpixels e Descritores de Textura Para Segmentação das Regiões do Disco Óptico

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da UFPI (área de concentração: Sistemas de Computação), como parte dos requisitos necessários para a obtenção do Título de Mestre em Ciência da Computação.

Universidade Federal do Piauí – UFPI

Centro de Ciências da Natureza

Programa de Pós-Graduação em Ciência da Computação

Orientador: Rodrigo de Melo Souza Veras

Teresina-PI

28 de Abril de 2017

Marcos Antônio de Sousa Frazão

Avaliação de Algoritmos de Superpixels e Descritores de Textura Para Segmentação das Regiões do Disco Óptico/ Marcos Antônio de Sousa Frazão. – Teresina-PI, 28 de Abril de 2017-

70 p. : il. (algumas color.) ; 30 cm.

Orientador: Rodrigo de Melo Souza Veras

Dissertação (Mestrado) – Universidade Federal do Piauí – UFPI

Centro de Ciências da Natureza

Programa de Pós-Graduação em Ciência da Computação, 28 de Abril de 2017.

1. Glaucoma. 2. Disco óptico. I. **Dr.** Rodrigo de Melo Souza Veras. II. Universidade Federal do Piauí. III. Departamento de Computação. IV. Avaliação de Algoritmos Superpixels e Descritores de Textura Para Segmentação das Regiões do Disco Óptico

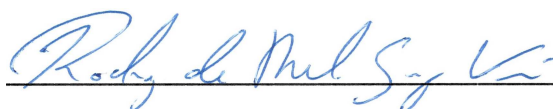
CDU 02:141:005.7

Marcos Antônio de Sousa Frazão

Avaliação de Algoritmos de Superpixels e Descritores de Textura Para Segmentação das Regiões do Disco Óptico

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da UFPI (área de concentração: Sistemas de Computação), como parte dos requisitos necessários para a obtenção do Título de Mestre em Ciência da Computação.

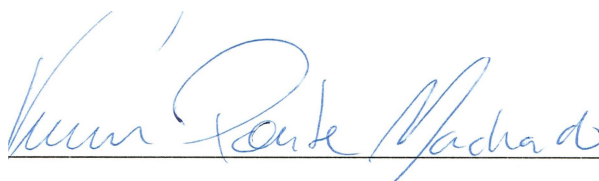
Trabalho aprovado. Teresina-PI, 28 de Abril de 2017:



Rodrigo de Melo Souza Veras
Orientador



Professor
Kelson Rômulo Teixeira Aires



Professor
Vinicius Ponte Machado



Professor
Ialis Cavalcante de Paula Júnior

Teresina-PI
28 de Abril de 2017

*Aos meus pais Antônio Frazão e Maria dos Humildes, e minha esposa Joselane Frazão
por sempre estarem comigo em todos os momentos.*

Agradecimentos

Agradeço a Deus, pelo dom de existir e por seu lugar simbólico na minha vida espiritual para o conforto nos momentos difíceis.

Aos meus familiares em especial meus pais e minha esposa pela força, incentivos, paciência e compreensão durante essa caminhada.

De modo específico ao meu orientador Doutor Rodrigo de Melo Souza Veras por todo o apoio, ideias, acolhimento, estímulo, paciência e tempo que foram capazes de contribuir para a conclusão deste trabalho.

Agradeço também aos professores da banca examinadora que aceitaram ao convite e ofertam assim de seus conhecimentos para a leitura e proposta desta dissertação.

E por fim aos colegas de mestrado pelos momentos de vivências em sala e nos laboratórios de pesquisa.

Resumo

Imagens de fundo de olho constituem um valioso recurso para o diagnóstico médico, pois muitas vezes apresentam indicações de doenças oftalmológicas e sistêmicas como: diabetes, hipertensão, entre outras. A detecção e a segmentação automática do disco óptico são comumente utilizadas no diagnóstico auxiliado por computador de várias doenças da retina, dentre elas o glaucoma. No disco, são identificadas duas regiões: a de escavação e a do disco óptico. Com a identificação dessas regiões, o glaucoma pode ser diagnosticado pelo cálculo do CDR, que é a razão da região de escavação e do disco óptico. No estado da arte, diversos autores usam o algoritmo de *superpixels Simple Linear Iterative Clustering - SLIC* sem almejar o motivo da utilização desse algoritmo. Utilizam uma quantidade de *superpixels* sem relatar o porquê da escolha dessa quantidade. Em cada um desses trabalhos citados acima, deve-se usar um descritor de textura na extração de características sem explicar a sua utilização. A partir desses requisitos, motivei-me a fazer uma avaliação de algoritmos de *superpixels* e descritores de textura para segmentação das regiões do disco óptico, com indicativos futuros para detecção do glaucoma, utilizando *superpixels*. Em se tratando de algoritmos de *superpixels*, foram avaliados seis algoritmos de *superpixels* com o intuito de determinar quais deles possuem um melhor desempenho na segmentação de imagens de disco óptico. Os algoritmos avaliados foram: *Entropy Rate Superpixel Segmentation - ERS*, *Simple Linear Iterative Clustering - SLIC*, *Simple Linear Iterative Clustering (zero parameter version) - SLIC0*, *Java Simple Linear Iterative Clustering - JSLIC*, *Spatial-Constrained Watershed - SCOW* e *Linear Spectral Clustering - LSC*. Na extração de características, foram utilizados os seguintes descritores de textura: *Grey-Level Co-occurrence Matrix - GLCM*, *Local Binary Pattern - LBP*, *Histograms of Oriented Gradients - HOG* e *Grey Level Run Length Matrix - GLRLM*. Para classificar as regiões de interesse, dois classificadores foram estudados: o Perceptron de Múltiplas Camadas e as Máquinas de Vetores de Suporte. Essas avaliações foram realizadas com o uso de um banco de imagens com padrão ouro da base DRISHTI-GS. Os resultados obtidos permitem, ao pesquisador que irá iniciar seus testes com uso de *superpixels*, um conhecimento do melhor algoritmo de *superpixel*, uma quantidade de *superpixel* a ser utilizada, qual descritor de textura e um classificador para classificar as regiões de interesse com uso de *superpixel*.

Palavras-chaves: Glaucoma, Disco Óptico, Escavação, Superpixels.

Abstract

Fundus images are a valuable resource for medical diagnosis, since they are often disclosed by ophthalmological and systemic diseases such as diabetes, hypertension, among others. Automatic detection and segmentation the optic disc are common in the computer-aided diagnosis of various diseases retina, among them glaucoma. There are no disc, two regions are identified: the cup and optic disc. With its regions, glaucoma can be diagnosed by calculating the CDR, which is a reason for the cup region and optic disc. In the state-of-the-art, various authors use the algorithm superpixels Clustering of simple linear iterations - SLIC without aiming the reason of the use algorithm. Use a quantity superpixel, without telling the reason for the quantity choice. In each works, a texture descriptor must be used in the extraction characteristics without explaining its use. From requirements, I have been motivated to make an evaluation of texture algorithms described for the segmentation optic disc regions with future indicative glaucoma detection, use superpixels. In the case superpixels algorithms, they were oriented by six algorithms superpixels in order to determine the best performance in the segmentation optic disc images. The evaluated were Algorithms : Entropy Rate Superpixel Segmentation - ERS, Simple Linear Iterative Clustering - SLIC, Simple Linear Iterative Clustering (SLIC0, Simple Linear Iterative Clustering - JSLIC, Spatial-Constrained Watershed - SCOW and Linear Spectral Clustering - LSC. In the Grey-Level Co-occurrence Matrix - GLCM, Local Binary Pattern - LBP, Oriented Gradient Histograms - HOG, Gray Level Execution Matrix - GLRLM. To classify as regions interest, two classifiers were studied: the Multilayer Perceptron and Support Vector Machine. These evaluations were performed with the use a DRISHTI-GS pattern gold image. The results are successful, and the investigator who initiates his tests using the texts, knowledge, knowledge, the best algorithm superpixel, a quantity superpixel to be used, what the Texture descriptor and a classifier to classify as regions interest using superpixel.

Keywords: Glaucoma, Optic Disc, Cup, Superpixels.

Lista de ilustrações

Figura 1 – Estrutura do olho humano. Adaptado de (JUNIOR; SASSON, 1989).	2
Figura 2 – Exemplos de imagens da retina centradas no DO.	3
Figura 3 – Exemplos de marcação do contorno do disco óptico (verde) e escavação (vermelho) feita por um especialista.	4
Figura 4 – Fluxograma com a sequência de passos com uso de <i>superpixel</i> na detecção do glaucoma.	5
Figura 5 – Sistema proposto no formato de diagrama, Adaptado Cheng et al. (2013).	9
Figura 6 – Fluxograma do modelo proposto por Alghmdi et al. (2015).	10
Figura 7 – Sistema proposto em fluxograma adaptado de Indira, Vinodhini e Sneha (2015).	10
Figura 8 – Fluxograma adaptado ao sistema proposto de Thorat e Raut (2015).	11
Figura 9 – Sistema proposto no formato de diagrama de Tan et al. (2015).	11
Figura 10 – Exemplos de Imagens na base DRISHTI-GS.	13
Figura 11 – Resultados da segmentação com 200 <i>superpixels</i> dos algoritmos avaliados na geração de <i>superpixel</i>	15
Figura 12 – Exemplo de segmentação com três superpixels.	25
Figura 13 – Resultado da supersegmentação: (a) região da escavação, (b) região do DO da base <i>DRISHTI-GS</i>	27
Figura 14 – Resultado da subsegmentação: (a) região da escavação, (b) a região do DO da base <i>DRISHTI-GS</i>	28
Figura 15 – Método de fase única.	31
Figura 16 – Método de duas fases primeiro teste.	32
Figura 17 – Método de duas fases segundo teste.	32
Figura 18 – Resultado da segmentação nos classificadores MLP e SVM, no descritor de textura GLCM.	34
Figura 19 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura LBP.	35
Figura 20 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura HOG.	36
Figura 21 – Resultado da segmentação no classificador MLP e SVM no descritor de textura GLRLM.	37
Figura 22 – Resultado da segmentação nos classificadores MLP e SVM na união dos dois descritores de texturas.	38
Figura 23 – Resultado da segmentação com pré-processamento na imagem, nos classificadores MLP e SVM no descritor de textura GLCM.	39

Figura 24 – Resultado da segmentação com pré-processamento na imagem, nos classificadores MLP e SVM, no descritor de textura LBP.	40
Figura 25 – Resultado da segmentação com pré-processamento na imagem, nos classificadores MLP e SVM, no descritor de textura HOG.	41
Figura 26 – Resultado da segmentação com pré-processamento na imagem, nos classificadores MLP e SVM, no descritor de textura GLRLM.	42
Figura 27 – Resultado da segmentação dos classificadores MLP e SVM, no descritor de textura GLCM no método de duas fases.	44
Figura 28 – Resultado da segmentação nos classificadores MLP e SVM, no descritor de textura GLCM no método duas fases, com adição da distância do centroide do centro da imagem.	45
Figura 29 – Resultado da segmentação nos classificadores MLP e SVM, no descritor de textura GLCM.	56
Figura 30 – Resultado da segmentação nos classificadores MLP e SVM, no descritor de textura LBP.	57
Figura 31 – Resultado da segmentação nos classificadores MLP e SVM, no descritor de textura HOG.	58
Figura 32 – Resultado da segmentação nos classificadores MLP e SVM, no descritor de textura GLRLM.	59
Figura 33 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura GLCM com 100% dos atributos com pré-processamento na imagem.	61
Figura 34 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura GLCM com 100% dos atributos com adição do centroide.	62
Figura 35 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura GLCM com 30% dos atributos.	64
Figura 36 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura LBP com 30% dos atributos.	65
Figura 37 – Resultado da segmentação nos classificadores MLP e SVM, no descritor de textura HOG com 30% dos atributos.	66
Figura 38 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura GLRLM com 30% dos atributos.	67
Figura 39 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura GLCM com 30% dos atributos.	68
Figura 40 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura GLCM com 30% dos atributos com adição do centroide.	70

Lista de tabelas

Tabela 1 – Resultado da classificação do descritor de textura GLCM nos classificadores MLP e SVM.	33
Tabela 2 – Resultado da classificação do descritor de textura LBP nos classificadores MLP e SVM.	34
Tabela 3 – Resultado da classificação do descritor de textura HOG nos classificadores MLP e SVM.	35
Tabela 4 – Resultado da classificação no descritor de textura GLRLM nos classificadores MLP e SVM.	36
Tabela 5 – Resultado da classificação dos descritores de textura GLCM e LBP nos classificadores MLP e SVM.	37
Tabela 6 – Resultado da classificação do descritor de textura GLCM com imagem com pré-processamento, nos classificadores MLP e SVM.	39
Tabela 7 – Resultado da classificação do descritor de textura LBP com pré-processamento nas imagens, nos classificadores MLP e SVM.	40
Tabela 8 – Resultado da classificação do descritor de textura HOG com um pré-processamento, nos classificadores MLP e SVM.	41
Tabela 9 – Resultado da classificação do descritor de textura GLRLM com pré-processamento, nos classificadores MLP e SVM.	42
Tabela 10 – Resultado da classificação do descritor de textura GLCM com método de duas fases, nos classificadores MLP e SVM.	43
Tabela 11 – Resultado da classificação do descritor de textura GLCM com método de duas fases, com adição da distância do centroide do centro da imagem, nos classificadores MLP e SVM.	44
Tabela 12 – Resultado da classificação no descritor de textura GLCM nos classificadores MLP e SVM com 100% dos atributos.	55
Tabela 13 – Resultado da classificação no descritor de textura LBP nos classificadores MLP e SVM com 100% dos atributos.	56
Tabela 14 – Resultado da classificação do descritor de textura HOG, nos classificadores MLP e SVM com 100% dos atributos.	57
Tabela 15 – Resultado da classificação no descritor de textura GLRLM, nos classificadores MLP e SVM com 100% dos atributos.	59
Tabela 16 – Resultado da classificação do descritor textura GLCM nos classificadores MLP e SVM com 100% dos atributos com pré-processamento da Imagem.	60
Tabela 17 – Resultado da classificação do descritor textura GLCM com adição do centroide nos classificadores MLP e SVM com 100% dos atributos.	62

Tabela 18 – Resultado da classificação no descritor GLCM, nos classificadores MLP e SVM com 30% dos atributos.	63
Tabela 19 – Resultado da classificação do descritor de textura LBP, nos classificadores MLP e SVM com 30% dos atributos.	64
Tabela 20 – Resultado da classificação do descritor de textura HOG nos classificadores MLP e SVM com 30% dos atributos.	65
Tabela 21 – Resultado da classificação do descritor textura GLRLM nos classificadores MLP e SVM com 30% dos atributos.	66
Tabela 22 – Resultado da classificação no descritor GLCM, nos classificadores MLP e SVM com 30% dos atributos.	68
Tabela 23 – Resultado da classificação do descritor textura GLCM com adição do centroide nos classificadores MLP e SVM com 30% dos atributos.	69

Lista de abreviaturas e siglas

CAD	<i>Computer-Aided Diagnosis</i>
CDR	<i>Cup-to-Disc-Ratio</i>
DO	Disco óptico
G	Padrão-ouro
n	Quantidade de imagens
PIO	Pressão intraocular
ERS	<i>Entropy rate superpixels segmentation</i>
LSC	<i>Linear spectral clustering</i>
SCOW	<i>Spatial constrained watershed</i>
SLIC	<i>Simple linear iterative clustering</i>
SLIC0	<i>Simple linear iterative clustering slic zero parameter version</i>
SP	Quantidade de <i>superpixels</i>
MLP	<i>Multilayer Perceptron</i>
SVM	<i>Support Vector Machine</i>

Sumário

1	INTRODUÇÃO	1
1.1	Olho humano	2
1.2	Glaucoma	3
1.3	Superpixel	4
1.4	Motivação	5
1.5	Objetivos	5
1.5.1	Objetivo Geral	5
1.5.2	Objetivos Específicos	6
1.6	Estrutura do Documento	6
2	ESTADO DA ARTE	7
2.1	Principais Estratégias de Diagnóstico do Glaucoma	7
2.2	Diagnóstico do Glaucoma Utilizando Superpixel	8
2.3	Considerações finais	11
3	MATERIAIS E MÉTODOS	13
3.1	Base de Imagens	13
3.2	Algoritmos de Geração de Superpixels Avaliados	14
3.2.1	Entropy Rate Superpixel Segmentation - ERS	16
3.2.2	Simple Linear Iterative Clustering - SLIC	16
3.2.3	Simple Linear Iterative Clustering (zero parameter version) - SLIC0	16
3.2.4	Java Simple Linear Iterative Clustering - JSLIC	17
3.2.5	Spatial-Constrained Watershed - SCOW	17
3.2.6	Linear Spectral Clustering - LSC	18
3.3	Extração e Seleção de Atributos	18
3.3.1	Grey-Level Co-occurrence Matrix - GLCM	18
3.3.2	Padrão Binário Local - LBP	20
3.3.3	Histograma de Gradientes Orientados - HOG	20
3.3.4	Grey Level Run Length Matrix - GLRLM	21
3.3.5	Seleção de Atributos	22
3.4	Classificadores Avaliados	23
3.4.1	Perceptron de Múltiplas Camadas - MLP	23
3.4.2	Máquina de Vetor de Suporte - SVM	24
3.5	Considerações finais	24
4	RESULTADOS E DISCUSSÃO	25

4.1	Avaliação dos Algoritmos de Superpixels	25
4.1.1	Metodologia de Avaliação da Segmentação por Superpixels	25
4.1.2	Resultados da Segmentação por Superpixels	26
4.2	Avaliação da Classificação dos Superpixels	29
4.2.1	Metodologia de Avaliação da Classificação dos Superpixels	29
4.2.2	Resultados da Classificação do Método de Fase Única	33
4.2.3	Resultados da Classificação do Método de Fase Única Com Pré-Processamento	38
4.2.4	Resultados da Classificação do Método de Duas Fases	43
5	CONCLUSÕES E TRABALHOS FUTUROS	47
	REFERÊNCIAS	49
	APÊNDICES	53
	APÊNDICE A – RESULTADOS DA SEGMENTAÇÃO POR SUPER-PIXELS	55
A.1	Resultados da Segmentação por Superpixels com 100% dos Atributos Extraídos Método de Fase Única	55
A.2	Resultados da Segmentação por Superpixels com 100% dos Atributos Extraídos no Método de Fase única com Pré-Processamento nas Imagens	60
A.3	Resultados da Segmentação por Superpixels com 100% dos Atributos Extraídos no Método de Duas Fases com Adição do Centroide .	61
A.4	Resultados da Segmentação por Superpixels com 30% dos Atributos Extraídos no Método Fase Única	63
A.5	Resultados da Segmentação por Superpixels com 30% dos Atributos Extraídos no Método Fase Única com Pré-Processamento nas Imagens	67
A.6	Resultados da Segmentação por Superpixels com 30% dos Atributos Extraídos no Método de Duas Fases com Adição do Centroide .	69

1 Introdução

O processo de globalização contribuiu significativamente para avanços no campo da ciência, principalmente na área tecnológica. Recentes avanços na aquisição de imagens e no poder computacional dos dispositivos tornaram possível utilizar informações presentes em imagens médicas de várias formas. Isso ocasionou um considerável interesse no desenvolvimento de sistemas automáticos de diagnóstico médico. Esses sistemas são chamados de sistemas de Diagnóstico Auxiliado por Computador (CAD - *Computer Aided Diagnosis*).

Estudos sobre sistemas CAD comprovaram que eles podem auxiliar os médicos em diversas tarefas como: medir estruturas anatômicas, monitorar as mudanças pela comparação de imagens sequenciais, diagnosticar e planejar o tratamento. Eles também aliviam o trabalho repetitivo, prevenindo possíveis erros ocasionados por fadiga e aumentando a eficiência no trabalho. As aplicações de CAD mais estabelecidas em áreas médicas envolvem o uso de sistemas automatizados em mamografia, tomografia computadorizada de tórax e radiografia (GONZALEZ; WOODS, 2011).

No campo oftalmológico, esses avanços tornaram possível a prevenção e o tratamento de doenças que há pouco tempo eram consideradas incuráveis. A prevenção primária e a detecção precoce, bem como o acesso a terapêuticas cirúrgicas oftalmológicas, são determinantes para a redução da morbidade das doenças da visão (MOOKIAH et al., 2013).

Foram desenvolvidos um grande número de sistemas CAD para o diagnóstico de vários tipos de doenças oculares: doenças maculares (LUCULESCU; LACHE, 2008), retinopatia diabética (D'ANTONI; GIUSTI, 2007) e glaucoma (MURAMATSU et al., 2011; LIU et al., 2011). Esses sistemas têm potencial para fornecer uma solução alternativa aos programas de triagem em massa, que precisam examinar um grande número de imagens de fundo de olho, o mais rápido possível e de maneira correta.

Atualmente, a maioria dos sistemas CAD está em fase de investigação e não podem ser colocados em uso prático nas clínicas, devido a várias razões. Uma delas é a diversidade de imagens de retina que podem ter qualidades muito diferentes devido a vários tipos de lesões e artefatos. Por esse motivo, é muito difícil projetar um algoritmo de processamento de imagens que seja capaz de lidar com uma grande quantidade de imagens de retina com diversas características (ANITHA; VIJILA; HEMANTH, 2009).

1.1 Olho humano

O olho humano é responsável pela capacidade do homem de interagir visualmente com o meio ambiente que o rodeia. Rotineiramente, ele é comparado a uma câmera fotográfica, ambos usam lentes para focalizar a luz incidente. Enquanto a câmera utiliza o sensor óptico para registrar a imagem, o olho utiliza uma camada especializada de células chamada retina. Porém, as similaridades não se identificam quando se trata da capacidade do olho em focar uma grande variedade de objetos com diferentes tamanhos, luminosidades e contraste em alta velocidade (GONZALEZ; WOODS, 2011). A estrutura do olho humano é mostrada na Figura 1.

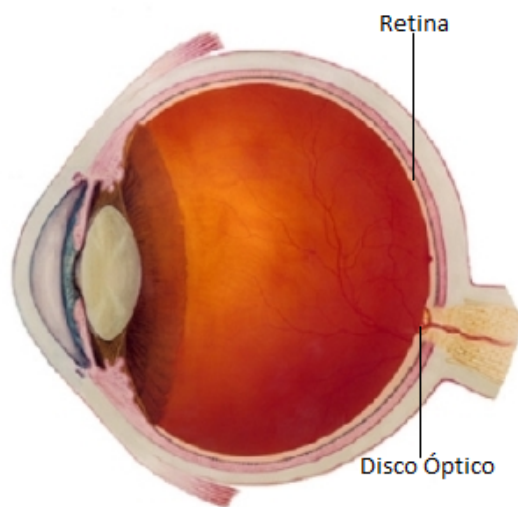


Figura 1 – Estrutura do olho humano. Adaptado de (JUNIOR; SASSON, 1989).

A retina constitui a membrana mais interna do olho, situando-se na sua parede posterior. Quando o olho focaliza uma cena, a imagem correspondente é projetada sobre a retina. A análise da retina pode prover informações sobre mudanças patológicas causadas por doenças oculares locais e sinais recentes de doenças sistêmicas (GONZALEZ; WOODS, 2011).

O disco óptico (DO) é a porção do nervo óptico vista no fundo dos olhos, formado pelo encontro de todos os axônios das células ganglionares da retina assim que penetram no nervo óptico. O DO é uma estrutura circular, que apresenta uma tonalidade rosa pálido ou esbranquiçada, e bordas bem definidas. Ele situa-se no lado nasal da retina e seu diâmetro físico médio é de cerca de 1,5mm (HOOVER; GOLDBAUM, 2003). A Figura 2 apresenta exemplos de imagens da retina centradas no DO, com a Figura 2a ilustra um exemplo de olho esquerdo e a Figura 2b o olho direito.

O DO não possui células sensíveis à luz. Dessa forma, corresponde ao ponto cego do campo de visão humano. Normalmente, a existência deste ponto cego não é perceptível ao ser humano, pois o cérebro interpreta a informação de cada olho e cobre o ponto cego

com informação do outro olho. Além disso, a verificação da relação entre o contorno do DO, e a parte mais interna, denominada escavação (do inglês *CUP*), é um importante indicador de glaucoma (NICOLELA; VIANNA, 2016).




Figura 2 – Exemplos de imagens da retina centradas no DO.

1.2 Glaucoma

O Glaucoma é uma doença assintomática neurodegenerativa, crônica e irreversível em que o nervo óptico é progressivamente danificado. Ela é considerada a segunda principal causa de cegueira no mundo, ficando atrás apenas da catarata, cerca de 60 milhões de casos em 2010, e uma estimativa que em 2020, cerca de 80 milhões de pessoas terão essa doença (QUIGLEY; BROMAN, 2006).


As três principais técnicas de diagnóstico do glaucoma são:

- avaliação da pressão intraocular (PIO);
- avaliação do campo visual; e
- avaliação do nervo óptico.


A PIO é medida através de um aparelho chamado tonômetro, que não é sensível o suficiente para ser uma ferramenta de triagem eficaz, porque o glaucoma pode estar presente com ou sem aumento da PIO. (CHENG et al., 2013). A avaliação do campo visual é feita através da perda de visão, que requer equipamentos especiais presentes nos hospitais (QUIGLEY; BROMAN, 2006).

A avaliação do nervo óptico é mais sensível, e superior que a medição da PIO ou teste do campo visual para detecção do glaucoma. Essa avaliação é manual, subjetiva,

demorada e cara (CHENG et al., 2013). Entre várias anormalidades da retina. Ela envolve uma degeneração progressiva das fibras do nervo óptico. Essas mudanças levam a um alargamento maior da escavação parte mais interna da região do disco óptico, se comparado ao alargamento do disco óptico, uma outra forma de detectar o glaucoma é usando a relação do diâmetro da escavação e do disco (CDR - *cup-to-disc ratio*). Um elevado valor do CDR indica a presença de glaucoma no paciente. A Figura 3 mostra as marcações do contorno do DO e da escavação feitas por um oftalmologista. É possível visualizar a diferença das marcações do contorno do DO e da escavação em um olho saudável (Figura 3a) e com glaucoma (Figura 3b).



(a) Disco Óptico saudável.



(b) Disco Óptico com glaucoma.

Figura 3 – Exemplos de marcação do contorno do disco óptico (verde) e escavação (vermelho) feita por um especialista.

1.3 Superpixel

Superpixels é uma técnica de segmentação de imagens baseada em regiões que tem por objetivo representar imagens com um número limitado de grupos de *pixels*. (REN; MALIK, 2003). Um *superpixel* é constituído por conjunto de pixels com características semelhantes, capaz de representar a imagem em regiões mais naturais e significante. Esta

técnica pode ser usada como uma pré-segmentação para reduzir a quantidade de *pixels* da imagem ou como segmentação final.

1.4 Motivação

No estado da arte existem vários métodos de segmentação, Por exemplo, há estudos que visam o agrupamento, outros estão voltado para contorno ativo, existem trabalho que utilizam morfologia matemática e artigos relatando a utilização de *superpixel*. Os autores que utilizam *superpixels* defendem que o *superpixel* capturam a redundância nas imagens para calcular características das imagens. A vantagem de utilizar *superpixel* para segmentar a região do disco óptico, é que o *superpixel* impõe uma suavidade na área da imagem onde os *pixels* foram agrupados e fornecem características mais acessíveis da região diferentes dos outros métodos de segmentação.

Com base nessa revisão de literatura, um aspecto identificado foi a necessidade de fazer uma avaliação de algoritmos de *superpixels* e descritores de textura para segmentação das regiões do disco óptico. Com consequência fornecer o melhor algoritmo de *superpixel* e descritor de textura. Algumas abordagens recentes apresentadas nos trabalhos de Cheng et al. (2013), Alghmdid et al. (2015), Indira, Vinodhini e Sneha (2015), Thorat e Raut (2015), Tan et al. (2015) utilizaram estratégias de solução baseadas no fluxograma apresentado na Figura 4, com a finalidade de segmentar as regiões de escavação e DO. Esses trabalhos utilizaram algoritmos de geração de *superpixels* e uma posterior classificação, para segmentação das regiões da escavação e DO.

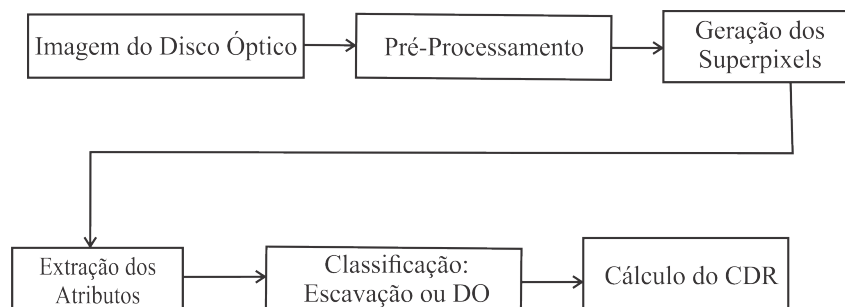


Figura 4 – Fluxograma com a sequência de passos com uso de *superpixel* na detecção do glaucoma.

1.5 Objetivos

1.5.1 Objetivo Geral

O objetivo desta dissertação é identificar o uso ou não um pré-processamento nas imagens, comparar os principais algoritmos de *superpixels* e identificar o melhor algoritmo

de geração de *superpixel*, que classificador a ser usado na classificação das regiões do disco óptico, discernir qual descritor de textura a ser usando na segmentação das regiões do disco óptico e avaliação do método de fase única e duas fases.

1.5.2 Objetivos Específicos

Durante a pesquisa foram estabelecidos os seguintes objetivos:

- a utilização ou não do pré-processamento nas imagens;
- implementar e comparar os principais algoritmos de *superpixels*;
- a avaliação dos classificadores; e
- a avaliação entre o método de fase única e de duas fases.

1.6 Estrutura do Documento

Esta dissertação está dividida em cinco capítulos. Este capítulo apresentou os fatos que motivaram a realização deste trabalho e os objetivos propostos. A seguir, apresentaremos uma descrição sucinta dos próximos capítulos.

Capítulo 2: introduz o estado da arte, com as principais estratégias de diagnósticos do glaucoma utilizando *superpixels*.

Capítulo 3: descreve a base de imagens, detalha os algoritmos de *superpixels* estudados e apresenta os classificadores avaliados, assim como os principais descritores de textura.

Capítulo 4: discute os resultados obtidos nos testes realizados.

Capítulo 5: contém as considerações finais relativas ao trabalho desenvolvido e aponta direções futuras.

2 Estado da Arte

Neste capítulo serão apresentados alguns trabalhos relacionados à detecção das estruturas abordadas nessa dissertação. A Seção 2.1 apresenta o estado da arte nas principais estratégias de diagnóstico do glaucoma, e a Seção 2.2 apresenta os trabalhos relacionados à estratégias que utilizam *superpixels*.

2.1 Principais Estratégias de Diagnóstico do Glaucoma

Nesta seção serão apresentadas as principais técnicas de segmentação das regiões do disco óptico (DO) e da escavação para o auxílio ao diagnóstico do glaucoma. Segundo Muramatsu et al. (MURAMATSU et al., 2011), os três principais métodos utilizados para segmentação do DO são modelos de contorno ativos, algoritmos de agrupamento e morfologia matemática.

Muramatsu et al. (2011) desenvolveram um método automatizado para segmentar o disco óptico e calcular a relação CDR em imagens digitais de fundo de retina. O método foi desenvolvido utilizando 80 imagens incluindo 25 glaucomatosas e 55 não glaucomatosas, obtidas na própria instituição em que a pesquisa foi desenvolvida. A região do DO foi segmentada utilizando o método de contorno ativo com as informações de brilho e borda. A segmentação da região de escavação utilizando um mapa de profundidade do disco óptico. Neste trabalho o resultado não foi disponibilizado.

No trabalho de Kumar et al. (2012), os autores propuseram um algoritmo para a detecção de glaucoma em imagens de biomicroscopia ultrassônica (UBM). Neste algoritmo, os processos de segmentação e extração de características das imagens foram utilizando um método baseado em contorno ativo. Em seguida, é utilizada a morfologia matemática para determinar o ponto inicial da característica de interesse. A dilatação e erosão são operações morfológicas particularmente úteis para o processamento de imagens binárias, com o propósito de detectar bordas, retirar ruídos e segmentar. Neste trabalho, os autores utilizaram a erosão para realizar a determinação do ponto inicial. A partir deste ponto, uma máscara de 50×50 pixels é criada. Finalmente, o cálculo do ângulo aberto da câmara anterior é realizado. A partir desta, a imagem é cortada na região de interesse e assim é feito o cálculo do ângulo de abertura. Através dos resultados obtidos pelos autores, observa-se que quanto menor o ângulo de abertura, maior a probabilidade de o olho ser glaucomatoso. Neste trabalho o resultado não foi disponibilizado.

Lotankar, Noronha e Koti (2015) propuseram um sistema automático para a detecção do glaucoma por meio da extração de diversas características, tais como o *Cup*

to Disc Ratio (CDR), Horizontal to Vertical CDR (H-V CDR), Cup to Disc Area Ratio (CDAR) e Rim to Disc Area Ratio (RDAR). O disco óptico é segmentado utilizando modelo de contorno ativo e a região de escavação é detectada, usando a informação de cor da banda M do modelo de cor $CMYK$. A avaliação do desempenho da técnica proposta foi realizada utilizando 150 imagens como entrada, compreendendo 75 imagens normais e 75 imagens glaucomatosas, utilizando um conjunto de classificadores supervisionados, nomeadamente *Naive Bayes*, *Support Vector Machine* (SVM) e *k-Nearest Neighbor* (KNN). A maior acurácia obtida foi de 99,22% utilizando o classificador KNN.

Jose e Balakrishnan (2015) propuseram um método para detecção automática do glaucoma a partir de imagens digitais do fundo de olho. A metodologia utiliza a segmentação das regiões da escavação e do disco óptico. O DO é segmentado utilizando operações morfológicas. A região de escavação é segmentada primeiro para detectar os vasos sanguíneos utilizando o classificador SVM para que, os pontos de flexão nos vasos circulares sejam removidos. Por fim o cálculo da relação entre a escavação e o disco (CDR) é utilizado para a detecção do glaucoma. Um valor de CDR superior a 0,5 indica presença de glaucoma. O resultado não foi disponibilizado.

Mittapalli e Kande (2016) apresentaram um sistema que segmenta a região de escavação com baseado em um algoritmo de limiarização, enquanto o DO é segmentado utilizando contorno ativo. Os vasos foram detectados a partir de um filtro *Gaussian Hermite Kernel* combinado e utilizando a mediana das intensidades dos *pixels* vizinhos que não são pertencentes aos vasos, seguido do filtro da mediana. Foi utilizada a combinação de ponderação espacial, *Fuzzy K-means* e técnicas de operações morfológicas, para segmentar a região de escavação. Na segmentação do DO, foi utilizado um modelo de contorno ativo, baseado na região implícita encontrada a partir dos pontos de interesse detectados. O sistema proposto foi avaliado em 59 imagens de retina (17 normais e 42 com glaucoma). O método obteve um *F-Measure* de 97.5% e 89% na segmentação da região de escavação e do DO, respectivamente. Um erro estimado de 0.13 no cálculo do CDR, 0,12 no cálculo do HCDR (*Horizontal Cup to disc ratio*) e 0,15 no CDAR (*Cup to disc area ratio*) foi obtido.

2.2 Diagnóstico do Glaucoma Utilizando Superpixel

Nos últimos anos, diversos trabalhos relacionados a algoritmos de geração de *superpixels* foram utilizados para segmentar as regiões do disco óptico.

Uma vantagem ao utilizar *superpixel* é a sua eficiência computacional. Quando é necessário calcular uma propriedade que permanece aproximadamente constante pelo objeto, a representação de *superpixel* é mais eficiente, uma vez que o número total de possibilidades é reduzido. Além disso o *superpixel* captura redundância da imagem, que são repetições de padrões de *pixels* para calcular características da imagem, e reduzir

grandemente a complexidade das tarefas de processamento de imagem subsequentes (ACHANTA et al., 2012).

Cheng et al. (2013) propuseram uma segmentação da região de escavação e disco óptico utilizando a classificação de *superpixel*. Com a aquisição de imagens de retina, aplica-se o algoritmo de *superpixels* nas imagens. O algoritmo utilizado na geração de *superpixel* foi o algoritmo SLIC, que realiza uma extração de característica utilizando histograma e cálculo estatístico do centro (*Center Surround Statistics* - CSS). Logo após a extração das características cada *superpixel* é classificado pertencente a região do disco ou não. O classificador utilizado nesse trabalho foi o SVM. Os métodos de segmentação propostos foram avaliados em duas bases de dados com um total de 2326 imagens, com limites de disco óptico e escavação marcados manualmente por especialistas. Os resultados experimentais mostram um erro de sobreposição médio de 9,5% e 24,1% na segmentação do disco óptico e da escavação, respectivamente. Os resultados também mostram um aumento no erro de sobreposição à medida que a pontuação de confiabilidade é reduzida, o que justifica a eficácia da auto avaliação. As regiões do disco óptico e da escavação são utilizadas no cálculo do CDR para o rastreamento do glaucoma. O método proposto resultou nas áreas sob curva de 0,800 e 0,822 em dois conjuntos de dados. As etapas mencionadas previamente podem ser observadas no diagrama na Figura 5.

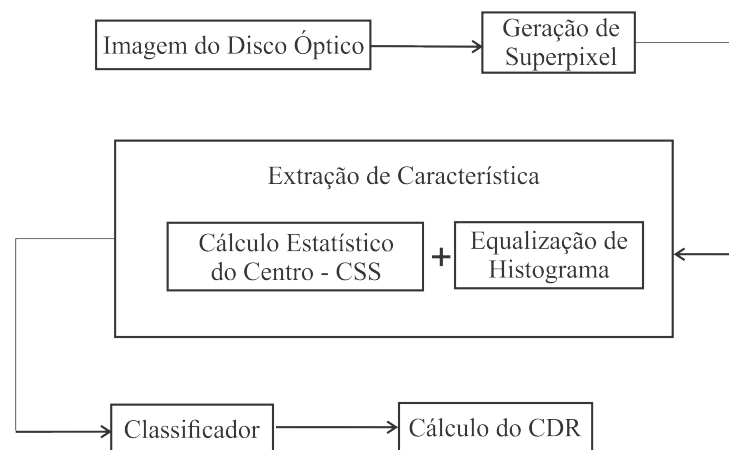


Figura 5 – Sistema proposto no formato de diagrama, Adaptado Cheng et al. (2013).

Alghmdi et al. (2015) propuseram a desenvolver uma abordagem automática de detecção do glaucoma, utilizando a relação CDR. Neste trabalho, o algoritmo de agrupamento de *superpixel* utilizado foi *Simple Linear Iterative Clustering* - SLIC. Foram utilizados dois classificadores, o primeiro linear e o segundo não-linear. O classificador linear é utilizado para classificar uma região como sendo do disco ou não, e o classificador não-linear é utilizado para classificar a região como sendo escavação ou não-escavação. Em seguida, foram aplicadas operações morfológicas, na segmentação da região de escavação e disco óptico. Por último o cálculo do CDR é realizado com base nos resultados obtidos pela segmentação. Os resultados demonstraram sua eficácia com 92% de Sensibilidade e

88% de Especificidade. Podemos verificar os passos que foram seguidos neste trabalho na Figura 6.




Figura 6 – Fluxograma do modelo proposto por Alghmdi et al. (2015).

Indira, Vinodhini e Sneha (2015) propuseram uma segmentação da região da escavação e do disco óptico com uso de *superpixel*. Primeiro é realizado um pré-processamento nas imagens, para depois aplicar o algoritmo de geração de *superpixel*, que é algoritmo *Simple Linear Iterative Clustering* - SLIC para classificá-la utilizando textura. O algoritmo de agrupamento *K-means* e o filtro de *Gabor* são utilizados para delimitar as bordas das regiões. Após essa etapa da segmentação do DO, é realizada uma segmentação da região de escavação. Por fim, a relação CDR é avaliada para a detecção de glaucoma. Neste trabalho o resultado não foi disponibilizado. Na Figura 7 podemos observar os passos que foram executados nesse trabalho.

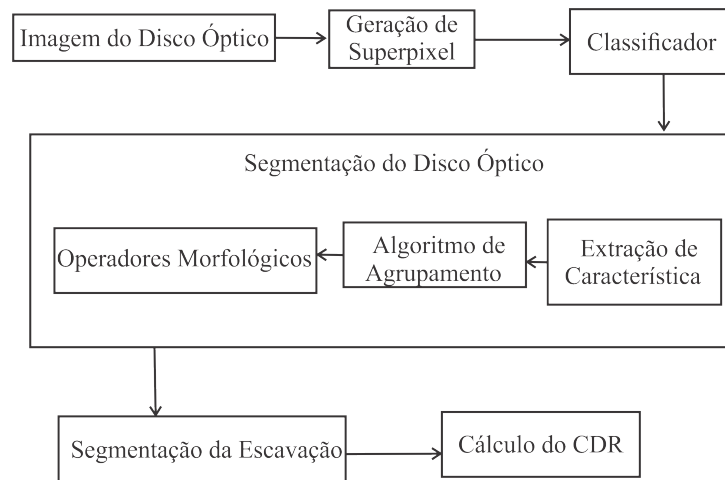


Figura 7 – Sistema proposto em fluxograma adaptado de Indira, Vinodhini e Sneha (2015).

Thorat e Raut (2015) propuseram uma segmentação a região do disco óptico e a região de escavação utilizando *superpixel* na detecção do glaucoma. Inicialmente é realizado um pré-processamento nas imagens. Aplica-se o algoritmo SLIC. Em seguida, a extração de características para cada *superpixel* foram extraídas utilizando equalização de histograma e cálculo estatístico do centro (CSS). A classificação dos superpixels como disco ou não-disco é feita com o classificador SVM. Após esta etapa aplica-se o algoritmo *K-means* e o filtro de Gabor, que foram utilizados para detectar as bordas da região. Por fim, o CDR é calculado baseado na segmentação da região do disco e da região de escavação. Os experimentos foram realizados em 2.326 imagens, mas não expõem os resultados. Na Figura 8 podemos observar os passos executados nesse trabalho.

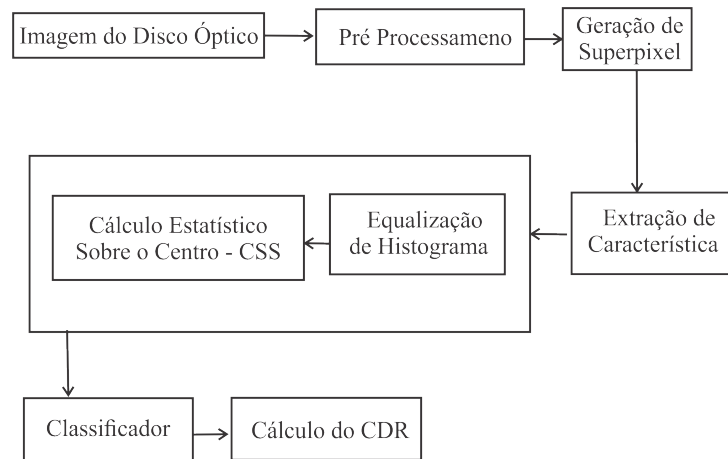


Figura 8 – Fluxograma adaptado ao sistema proposto de [Thorat e Raut \(2015\)](#).

[Tan et al. \(2015\)](#) propuseram uma segmentação da região de escavação para detecção do glaucoma usando *superpixel*. Inicialmente é realizado um pré-processamento nas imagens que tem como objetivo extrair os vasos sanguíneos para que em seguida seja aplicada uma normalização de contraste nas imagens. Após essa etapa, é realizada uma segmentação com o uso do *superpixel* em multi-escala, onde essa segmentação é realizada pelo algoritmo SLIC. Logo após será efetuado a extração de características com uso de *superpixel*. Em seguida, é verificado se os vasos sanguíneos presentes na imagem foram removidos na região aplicada com *superpixel*. Após isso, é realizado um treinamento e teste, pelo classificador SVM, usando *cross validation*. Neste trabalho foram avaliados uma base de dados com um total de 650 imagens. O método obteve uma acurácia de 7,12% e 0,945 na área sob curva, na segmentação da região de escavação, respectivamente. Podemos verificar os passos mencionados anteriormente utilizados na Figura 9.

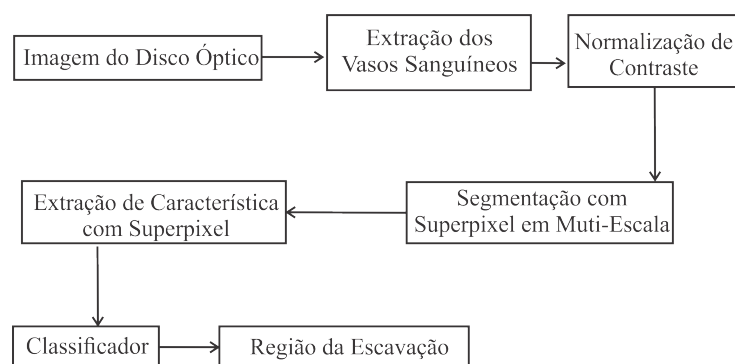


Figura 9 – Sistema proposto no formato de diagrama de [Tan et al. \(2015\)](#).

2.3 Considerações finais

Este capítulo apresentou trabalhos gerais que utilizam *superpixels* no diagnóstico do glaucoma. O conteúdo descrito é a base fundamental para a criação de formas automáticas

de detecção do glaucoma em imagens de retina com uso de *superpixel*. Os trabalhos que usam *superpixels* no diagnóstico do glaucoma, executam um pré-processamento nas imagens, utilizam o mesmo algoritmo de geração de *superpixel*, fazem uma extração de características e utilizam um classificador em comum para classificar as regiões de interesse.

No meu trabalho farei um levantamento da existência de outros algoritmos de geração de *superpixel* e comparar com o algoritmo proposto em todos os trabalhos que utilizam *superpixel* no diagnóstico do glaucoma. Farei um estudo de como extrair essas características e comparar o classificador com um outro. O próximo capítulo tratará da base de imagens utilizadas, sobre os algoritmos de *superpixels* estudados, os classificadores utilizados nos testes e os descritores de textura avaliados.

3 Materiais e Métodos

Nesta seção são apresentados os materiais utilizados para a avaliação de algoritmos de *superpixels*, de modo a esclarecer os recursos utilizados para alcançar o resultado demonstrado a Seção 4 deste trabalho.

3.1 Base de Imagens

A maioria das metodologias de segmentação do disco óptico e da região de escavação que foram apresentadas nesta dissertação, foram testadas em uma base de imagens. A seguir, uma breve descrição da base de imagens utilizada na avaliação dos algoritmos de *superpixels* e descritores de textura para segmentação das regiões do disco óptico.

As imagens da base DRISHTI-GS, foram previamente analisadas por quatro especialistas para a segmentação das regiões do DO e da região de escavação. A base é composta por 101 imagens de retina. Todas foram tiradas com centro no DO, com um “campo de visão” de 30° e dimensões 2896×1944 *pixels* em formato PNG. Entretanto, apenas 50 imagens desse total foram utilizadas nos testes, pois somente estas possuem informações sobre seu padrão ouro (SIVASWAMY et al., 2014).

A marcação dos especialistas é denominada na literatura de padrão ouro, que é a marcação referente a região de escavação e disco óptico. A Figura 10a é a imagem original e a Figura 10b representa a imagem com marcação do padrão ouro.




Figura 10 – Exemplos de Imagens na base DRISHTI-GS.

3.2 Algoritmos de Geração de Superpixels Avaliados

Os algoritmos de *superpixels* fornecem uma primitiva conveniente para calcular características locais da imagem. Eles capturam redundância na imagem e reduzem muito a complexidade das tarefas de processamento de imagens subsequentes. Eles provaram ser cada vez mais úteis para aplicações como estimativa de profundidade e na segmentação de imagens (REN; MALIK, 2003). Existem vários trabalhos na literatura que tratam sobre a utilização de *superpixels* (ACHANTA et al., 2012; NAN; MU, 2014; LI; CHEN, 2015; HU; ZOU; LI, 2015).

Neste trabalho, avaliamos seis métodos de geração de *superpixels* para cálculo do CDR. Recentemente, Achanta et al. (2012) realizaram um estudo do estado da arte e identificaram as principais técnicas de *superpixels*. Os autores fizeram uma classificação das técnicas de *superpixels* caracterizando em: técnicas que empregam algoritmos baseados em grafos, agrupamento e morfologia matemática. Na técnica baseada em grafos, onde cada nó do grafo representa um *pixel* da imagem, os pesos das arestas são computados de acordo com uma função de similaridade. Algumas limitações destes métodos são o alto tempo de processamento e consumo excessivo de memória, como por exemplos: *Fezenszwalb e Huttenlocher - FH* (FELZENSZWALB; HUTTENLOCHER, 2004), *Superpixel Lattice - SL* (MOORE et al., 2008), *Normalized Cuts - NC* (SHI; MALIK, 2000). Para a nossa avaliação escolhemos o algoritmo *Entropy Rate Superpixel Segmentation - ERS* (LIU et al., 2011), por ser o trabalho mais recente em técnicas de algoritmos baseados em grafos.

A técnica de agrupamento é estruturado sobre o algoritmo *K-means*, os *pixels* são obtidos a partir de um agrupamento *pixels*, onde iterativamente estes agrupamentos são refinados até atingir algum critério de convergência, por exemplos: *Simple Linear Iterative Clustering* (ACHANTA et al., 2012), *Simple Linear Iterative Clustering (version with 0 parameter)* (NAN; MU, 2014), *Java Simple Linear Iterative Clustering* (BOROVEC; KYBIC, 2014) e *Linear Spectral Clustering* (LI; CHEN, 2015), e por último o algoritmo *Spatial-Constrained Watershed* (HU; ZOU; LI, 2015) cuja geração de *superpixels* baseia-se em morfologia matemática.

Os algoritmos avaliados foram disponibilizados nos trabalhos citados anteriormente. Cinco deles foram implementados na linguagem Matlab e um em Java. A Figura 11 apresenta a segmentação com 200 *superpixels* dos seis algoritmos avaliados, podemos observar que cada algoritmo de *superpixels* produz diferentes regiões. Na sequência apresentaremos as principais características dos algoritmos avaliados.

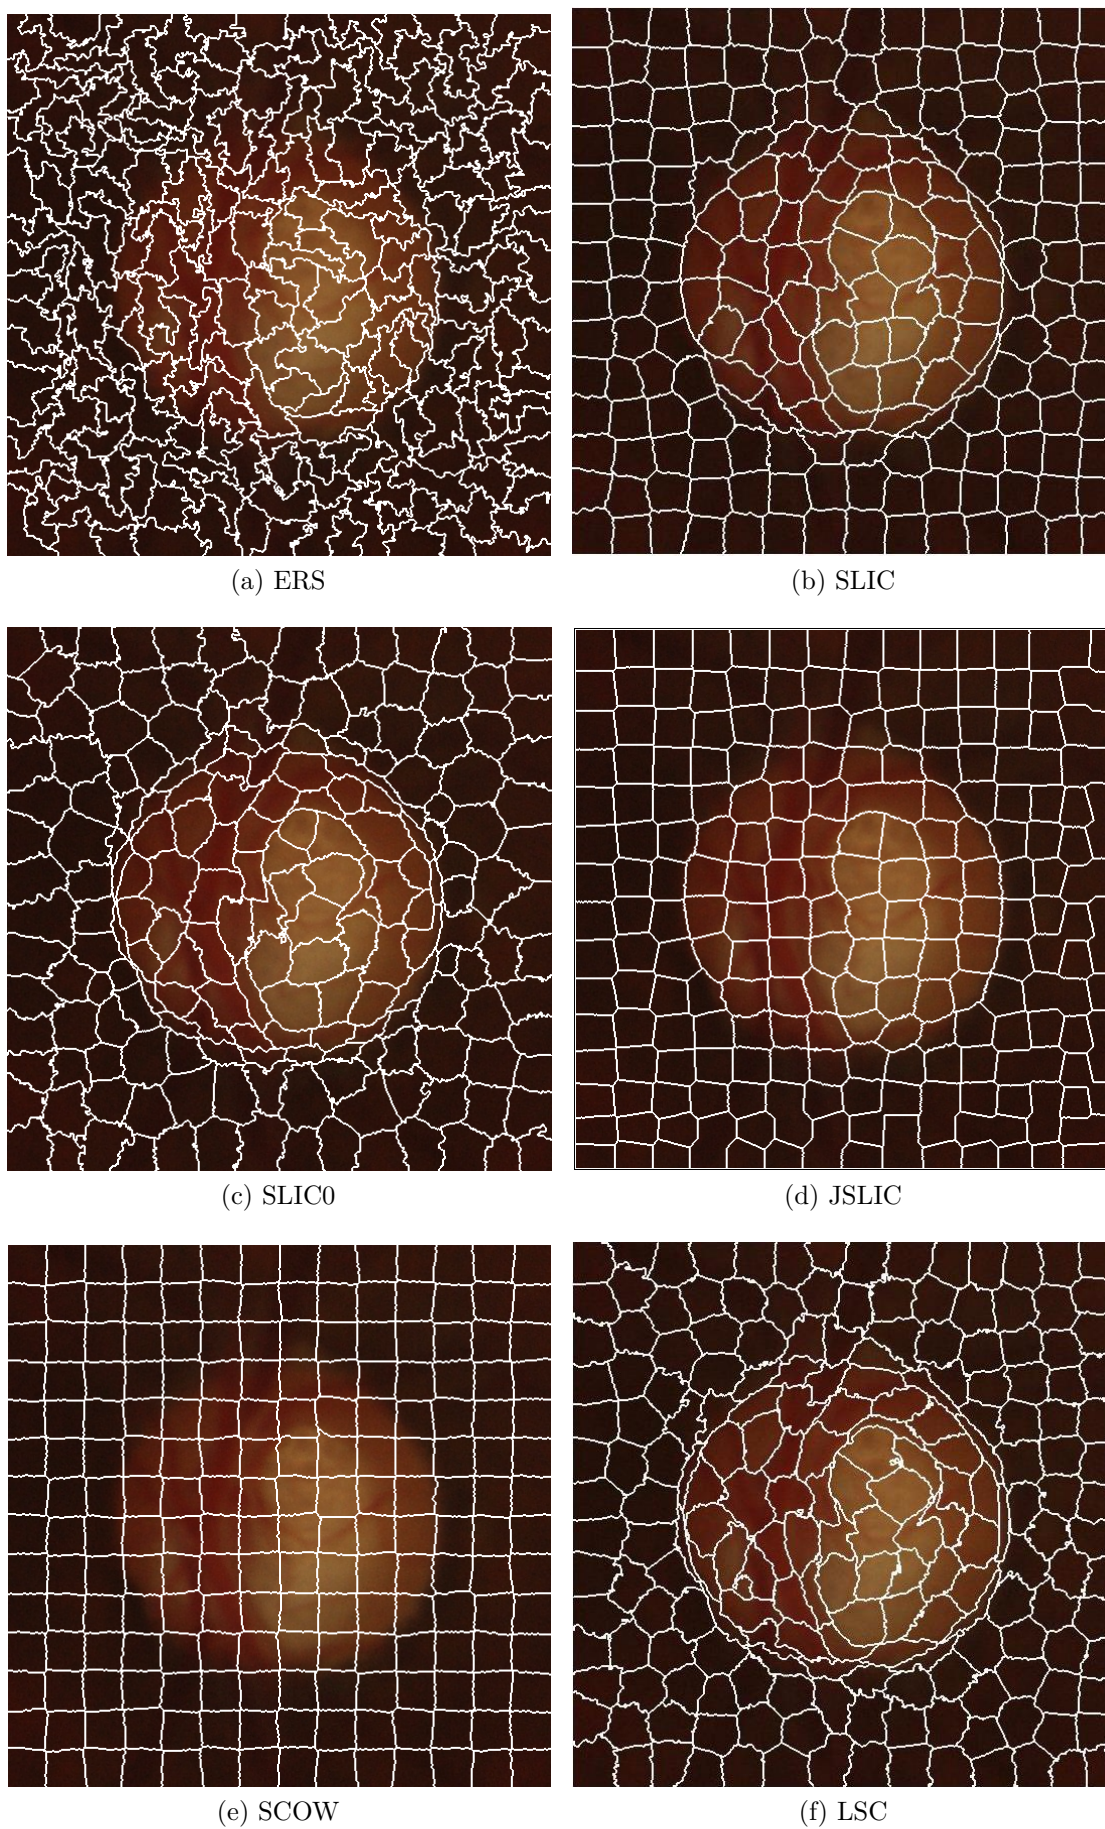


Figura 11 – Resultados da segmentação com 200 *superpixels* dos algoritmos avaliados na geração de *superpixel*.

3.2.1 Entropy Rate Superpixel Segmentation - ERS

Liu et al. (2011) propuseram uma função objetivo de agrupamento que consiste na taxa de entropia de uma forma aleatória que incentive a geração de *superpixels* com tamanhos semelhantes. Assim, o algoritmo ERS preserva os limites de objetos irregulares, que são passíveis de serem suavizados por outros algoritmos. No entanto, a forma irregular gerada pelo algoritmo ERS pode se tornar um possível problema na extração de características (ACHANTA et al., 2012).

O algoritmo ERS gera *superpixels* de tamanho similar que seguem atentamente o gradiente da imagem e com o aumento do número de *superpixels*, o resultado da segmentação vai melhorando. Além disso, o ERS possui resultados equilibrados nas propriedades de segmentação, qualidade e robustez. O algoritmo ERS tem um melhor desempenho em imagens de pequena resolução (LIU et al., 2011).

3.2.2 Simple Linear Iterative Clustering - SLIC

Achanta et al. (2012) propuseram o algoritmo SLIC para extração de *superpixels* mediante o agrupamento de *pixels* baseado na similaridade de cor e proximidade na imagem. Isso é feito no espaço $labxy$, no qual lab é a cor do *pixel* no espaço CIELAB, o que é considerado percentualmente uniforme para distâncias pequenas de cor, e xy é a posição do *pixel*. O algoritmo SLIC tem dois parâmetros, o primeiro é o tamanho nominal das regiões de *superpixels*, e o segundo é tamanho da intensidade espacial (JACOB; R. VENKATESH, 2014). Essa abordagem é estruturada sobre o algoritmo *K-means*, mas emprega um espaço de busca mais eficiente, visto que seu tamanho é limitado, reduzindo o custo computacional.

3.2.3 Simple Linear Iterative Clustering (zero parameter version) - SLIC0

O algoritmo *Simple Linear Iterative Clustering (version with 0 parameter)* - SLIC0 (NAN; MU, 2014) escolhe de forma adaptativa os parâmetros de compacidade para cada *superpixel* diferente. O parâmetro de compacidade é a razão $\frac{m}{S}$, onde m é número de *superpixel* e S é área da aplicação de *superpixel*. Essa razão é responsável pela normalização que permite o controle da compacidade dos *superpixels*. Quando m é pequeno, os *superpixels* tem a maior aderência à bordas e fronteiras, porem têm tamanho e forma menos regular.

Isso gera *superpixel* de forma regular nas regiões lisas, e texturizadas de formas não iguais. Mesmo SLIC0 escolhendo os parâmetros de compacidade de forma adaptativa, não há nenhuma melhoria em termo de eficiência computacional. Isso não impede que o algoritmo SLIC0 seja tão rápido quanto o algoritmo SLIC (ACHANTA et al., 2012).

O algoritmo SLIC0 considera apenas cor, brilho e características espaciais, e não concebe nenhum recurso de textura. O *superpixel* segmentado com o algoritmo SLIC0 não

coincide com os limites locais ou contornos sobre os objetos. Enquanto no processo de segmentação, a estratégia de pesquisa do SLIC0 é testar os *pixels* vizinhos em torno do pixel mais otimizado (NAN; MU, 2014).

3.2.4 Java Simple Linear Iterative Clustering - JSLIC

O JSLIC é uma implementação *open source* baseada em Java. O JSLIC faz o agrupamento de *superpixel* melhor que o algoritmo SLIC. Borovec e Kybic (2014) propuseram um parâmetro de regularização diferente, que influencia a compacidade de *superpixels* resultantes.

O algoritmo JSLIC é uma aceleração do método de agrupamento original SLIC (ACHANTA et al., 2012), transformando o parâmetro de compacidade em um valor independente quando aplicado na imagem. Assim é realizada uma nova etapa de pós-processamento (após agrupamento). Com *superpixels*, os resultados ficam mais homogêneos. O JSLIC é um *plug-in* que é usado no *ImageJ/Fiji* que é comumente usado como uma plataforma de pesquisa e desenvolvimento na biologia e imagiologia médica (BOROVEC; KYBIC, 2014).

3.2.5 Spatial-Constrained Watershed - SCOW

O algoritmo proposto por (HU; ZOU; LI, 2015) introduz limitações espaciais e marcadores uniformes para se obter *superpixels* compactos e distribuídos uniformemente que ao mesmo tempo produz *superpixels* de formas e tamanhos irregulares. Além disso, um esquema de preservação da borda é utilizado para alinhar os limites de *superpixels* nas bordas da imagem, resultando em um equilíbrio entre a homogeneidade e compacidade (HU; ZOU; LI, 2015).

A ideia básica do algoritmo SCOW é que a prioridade não depende de seu valor do gradiente, mas também sobre o padrão espacial. O pressuposto básico é que, sobre condições semelhantes, os *pixels* mais próximos de seus marcadores correspondentes devem ser processados com prioridades mais altas. Por outro lado, quando as distâncias entre os marcadores são próximas, com valores de *pixels* de menor gradiente, devem ser dado prioridades (HU; ZOU; LI, 2015). Em seguida, é definida a prioridade do *pixel* na equação que segue:

$$p'(x, y) = p_g(x, y) + \lambda p_s(x, y), \quad (3.1)$$

em que $p_g(x, y)$, indica a prioridade do *pixel* derivado do gradiente, e $p_s(x, y)$ indica a prioridade do *pixel* derivado da restrição espacial, λ , que é o parâmetro de entrada do usuário que o equilibra entre as duas medições.

3.2.6 Linear Spectral Clustering - LSC

O algoritmo *Linear Spectral Clustering* (LSC) (LI; CHEN, 2015) é proposto com base na investigação da relação entre as funções objetivas de cortes normalizados e agrupamento do *K-means*, que não só captura de forma perceptiva as propriedades importantes da imagem, mas também executa em complexidade linear com alta eficiência de memória, evitando assim um grande cálculo sobre a matriz do *kernel*. No algoritmo LSC, é feito um mapeamento em cada *pixel* da imagem a um ponto dimensional de dez características, que é aplicado sobre a segmentação do algoritmo *K-means*. A otimização destas duas funções objetivas, é equivalente se a semelhança entre dois pontos no espaço de entrada é igual ao produto interno ponderado entre os dois vetores correspondentes sobre o espaço de características dimensionais (LI; CHEN, 2015).

3.3 Extração e Seleção de Atributos

O objetivo da extração de atributos é caracterizar medidas associadas com o objeto que se deseja extrair de forma que as medidas sejam similares para objetos similares e diferentes para objetos distintos (DUTRA, 1999). O processo de extração de atributos é fundamental para a obtenção de bons resultados na classificação, pois nesta fase é criado o conjunto de características utilizado para a realização de treinamento e classificação.

A seleção de atributos pode ser vista como um processo de busca onde o algoritmo usado deve encontrar o menor subconjunto de atributos com a melhor acurácia de classificação (PAPPA; FREITAS; KAESTNER, 2002). Uma grande dimensionalidade do espaço de atributos pode causar degradação na classificação e um alto custo de processamento. Uma descrição mais detalhada dos métodos de extração e seleção de atributos é apresentada nas subseções seguintes.

3.3.1 Grey-Level Co-occurrence Matrix - GLCM

A GLCM (*Grey-Level Co-occurrence Matrix*) é uma técnica responsável pela análise do atributo de textura em imagens. A GLCM armazena a probabilidade de que dois valores de intensidade de cinza estejam envolvidos por uma determinada relação espacial. A partir desta matriz de probabilidades, diferentes medidas estatísticas são extraídas a fim de caracterizar a textura presente na imagem (HARALICK; SHANMUGAM et al., 1973).

Uma orientação Θ (tetha) é uma distância conhecida como *pixel pair spacing*, são utilizadas para o cálculo das probabilidades de co-ocorrências entre dois níveis de cinza i e j . Essa orientação pode assumir os valores de 0° , 45° , 90° e 135° (BARALDI; PARMIGGIANI, 1995). Existe uma matriz de co-ocorrência para cada relacionamento espacial possível (distância e orientação). Assim, todas as informações sobre a textura de

uma imagem estarão contidas nessa matriz.

A partir da matriz de co-ocorrência, pode-se extrair várias medidas relacionadas a características de uma textura (HARALICK; SHANMUGAM et al., 1973). O descritor aqui relatado nos retornam 14 características originalmente apresentadas por (HARALICK; SHANMUGAM et al., 1973). Dessas 14 apenas 5 foram utilizados, que são: contraste, correlação, energia, homogeneidade e entropia.

Nas equações abaixo a quantidade de níveis de cinza na imagem é representada por G . A entrada da matriz GLCM é representada: linha i e coluna j por C_{ij} . A média e o desvio padrão são representados, respectivamente, por (μ_x, μ_y) e (σ_x, σ_y) para a linha i e coluna j da matriz. Em seguida será descritos sobre essas características utilizadas.

Contraste – corresponde à diferença entre os valores mais altos e mais baixos de um conjunto de *pixels* contíguos. Elevados valores de contraste correspondem a imagens compostas por valores digitais de grande amplitude, ou seja, com textura rugosa, mostrada na Equação 3.2.

$$\text{Contraste} = \sum_{i,j=1}^G C_{ij}(i-j)^2 \quad (3.2)$$

Correlação - retorna uma medida de quão correlacionado está um *pixel* com o seu vizinho. A comparação é feita em todos os *pixels* da imagem. A correlação é 1 para uma imagem totalmente correlacionada, mostrado na Equação 3.3.

$$\text{Correlação} = \sum_{i,j=1}^G \frac{(i-\mu_x)(j-\mu_y)C_{ij}}{(\sigma_x)(\sigma_y)} \quad (3.3)$$

Energia – mede a uniformidade da textura, ou seja, a quantidade de repetição de pares de *pixels*. Valores elevados significam que a distribuição do valor digital é constante, isto é, ocorre grande repetição na variação dos valores digitais. Para uma matriz normalizada, os valores são positivos, menor ou igual a 1, mostrado na Equação 3.4.

$$\text{Energia} = \sum_{i,j=1}^G (C_{ij})^2 \quad (3.4)$$

Homogeneidade – mede a homogeneidade da imagem. Valores elevados correspondem a pequenas diferenças tonais entre os *pixels* vizinhos. Este parâmetro é inversamente proporcional ao contraste e à energia. Como é apresentada a Equação 3.5.

$$\text{Homogeneidade} = \sum_{i,j=1}^G \frac{C_{ij}}{1+|i-j|} \quad (3.5)$$

Entropia - é uma medida estatística que pode ser utilizada para caracterizar a textura da imagem de entrada, mostrada na Equação 3.6.

$$Entropia = - \sum_{i,j=1}^G C_{ij} \log C_{ij} \quad (3.6)$$

3.3.2 Padrão Binário Local - LBP

O descritor Padrão Binário Local (*Local Binary Pattern* - LBP) possui um bom desempenho em diversas aplicações, incluindo a classificação e segmentação de textura, recuperação de imagens, e inspeção de superfície (GUO; ZHANG; ZHANG, 2010; SURULLIANDI; MEENA; ROSE, 2012; ZHAO et al., 2012).

O descritor LBP original (OJALA; PIETIKÄINEN; HARWOOD, 1996) rotula os *pixels* de uma imagem em tons de cinza por limiarização. O valor do limiar é o *pixel* central da janela de vizinhança 3×3 . Cada *pixel* é comparado com o *pixel* central e o resultado final é considerado um número binário. Esse procedimento é feito para todas as janelas escolhidas da imagem. Após todas as janelas serem computadas, o vetor de características é montado com a junção dos valores obtidos.

Após a limiarização, um histograma da célula é calculado, ou seja, as quantidades de “0” e “1” são calculadas. As características mais relevantes do descritor LBP são a sua tolerância a mudanças de iluminação e sua simplicidade computacional.

3.3.3 Histograma de Gradientes Orientados - HOG

O algoritmo Histograma de Gradientes Orientados (*Histograms of Oriented Gradients* - HOG) (DALAL; TRIGGS, 2005) é um descritor que calcula o histograma da orientação dos gradientes na imagem. O descritor final é um vetor de histogramas extraídos da imagem.

O algoritmo se baseia na ideia de que a forma e aparência de um objeto podem ser descritas muitas vezes pela intensidade dos gradientes ou a direção das bordas, sem um conhecimento prévio da posição de tais bordas.

O primeiro passo do método consiste em converter a imagem para tons de cinzas e normalizá-la de acordo com a iluminação. O próximo passo é a computação dos gradientes. Uma técnica que é aplicada sobre o operador de Sobel (SAID; ATRI; TOURKI, 2011). Dada uma imagem I são calculados os gradientes G_x e G_y , assim como a magnitude e sua orientação.

Em seguida é feita uma divisão da imagem em pequenas regiões espaciais chamadas células. Para cada célula é calculado um histograma local 1- D das orientações sobre os

pixels da célula (SAID; ATRI; TOURKI, 2011). As células podem ter forma retangular ou radial. Após os histogramas serem computados, eles são normalizados.

A normalização é feita por um acúmulo de histogramas locais em regiões espaciais um pouco maiores chamadas de blocos. Os histogramas acumulados então são utilizados para normalizar todas as células naquele bloco. Após a normalização, é coletada uma janela de detecção sobre os histogramas gerados, que consiste na saída do descritor HOG.

3.3.4 Grey Level Run Length Matrix - GLRLM

O método de extração de características por *Grey Level Run Length Matrix - GLRLM*, descreve as características da textura a partir de matrizes auxiliares, computadas a partir da imagem digital original (em níveis de cinza). Tais matrizes são denominadas de GLRLM (FU; GONZALES; LEE, 1987).

Uma GLRLM é construída pela contagem de sequências retilíneas de *pixels* da região analisada que possuem a mesma tonalidade, sendo que cada linha da matriz corresponde a uma tonalidade e cada coluna, a um comprimento. Em uma textura áspera, espera-se que sejam relativamente longas, enquanto em texturas finas ocorram mais curtas, devido a presença de bordas, responsáveis por variações rápidas e acentuadas nos níveis de cinza dos *pixels* pertencentes a uma determinada linha da imagem (CAZES et al., 1997).

Para a criação da matriz GLRLM, define-se que um conjunto composto de *pixels* consecutivos, apresentando o mesmo nível de cinza e sendo colineares em uma dada orientação, representa uma matriz de cinza; o número de *pixels* contidos nesse conjunto denota o tamanho da matriz. Dessa maneira, cada elemento da matriz, representado pela medidas, G e R que representam o valor do nível de cinza, o $p(i, j|\theta)$, contém o número da coluna com tamanho j , tendo i como o nível de cinza de seus *pixels*, em que o parâmetro θ indica a orientação do segmento de reta formado pelos *pixels*, que podemos observar nas Equações 3.7 a 3.17, que correspondem à orientação 0° , 45° , 90° e 135° , respectivamente.

$$\sum_{i=1}^G \sum_{j=1}^R \frac{p(i, j|\theta)}{j^2} \quad (3.7)$$

$$\sum_{i=1}^G \sum_{j=1}^R j^2 p(i, j|\theta) \quad (3.8)$$

$$\sum_{i=1}^G \left(\sum_{j=1}^R p(i, j|\theta) \right)^2 \quad (3.9)$$

$$\sum_{j=1}^R \left(\sum_{i=1}^G p(i, j|\theta) \right)^2 \quad (3.10)$$

$$\frac{1}{N} \sum_{i=1}^G \sum_{j=1}^R p(i, j|\theta) \quad (3.11)$$

$$\sum_{i=1}^G \left(\sum_{j=1}^R \frac{p(i, j|\theta)}{i^2} \right) \quad (3.12)$$

$$\sum_{i=1}^G \left(\sum_{j=1}^R i^2 p(i, j|\theta) \right) \quad (3.13)$$

$$\sum_{i=1}^G \sum_{j=1}^R \frac{p(i, j|\theta)}{i^2 \cdot j^2} \quad (3.14)$$

$$\sum_{i=1}^G \sum_{j=1}^R \frac{i^2 \cdot p(i, j|\theta)}{j^2} \quad (3.15)$$

$$\sum_{i=1}^G \sum_{j=1}^R \frac{j^2 \cdot p(i, j|\theta)}{i^2} \quad (3.16)$$

$$\sum_{i=1}^G \sum_{j=1}^R i^2 \cdot j^2 \cdot p(i, j|\theta) \quad (3.17)$$

3.3.5 Seleção de Atributos

Após ser gerado o vetor de características, obtido através das equações na Seção 3.3, realizou-se uma seleção de atributos. Esta seleção tem como objetivo eliminar atributos desnecessários, e conseqüentemente, simplificar o modelo de predição e reduzir o custo computacional deste modelo, além de fornecer um melhor entendimento sobre os resultados encontrados. De acordo com [Guyon e Elisseeff \(2006\)](#), as técnicas de seleção de atributos são, a princípio, empregadas para identificar atributos relevantes e com informações essenciais.

Uma seleção ótima de atributos para problemas de classificação requer uma busca exaustiva de todos os possíveis subconjuntos de atributos ([REUNANEN, 2003](#)). Por esse motivo foram desenvolvidas diferentes técnicas de seleção de atributos, que utilizam critérios de seleção e algoritmos de busca distintos para avaliar, e encontrar de forma heurística o subconjunto de atributos mais adequado.

O algoritmo utilizado para seleção de atributos, foi a técnica razão de ganho de informação. Este algoritmo é um tipo de filtro que tende a superestimar a qualidade de atributos com muitos valores ([QUINLAN, 1986](#)).

Neste trabalho cada descritor de textura retornou uma quantidade de atributos. No descritor GLCM o vetor é formado por 85 atributos. Já o descritor LBP foram 1280

atributos. No descritor HOG é composto por 405 atributos. O descritor GLRLM resulta em um vetor formado por 220 atributos.

Os testes dos descritores foram realizados nos sistemas de cores RGB e HSV, nos canais de cores R, G, B, H e S. Esses canais de cores utilizados foram com base no trabalho proposto por (CHENG et al., 2013). Os descritores utilizados retornam uma grande quantidade de atributos que por muitas vezes dificultam a classificação dos objetos. As avaliações foram feitas com 100%, 30% e 10% das características extraídas de cada descritor de textura. Os atributos selecionados foram utilizados como entrada nos classificadores que serão apresentados na Seção 3.4.

3.4 Classificadores Avaliados

A classificação de imagens consiste em associar cada pixel ou região da imagem a uma classe que descreve um objeto real. A tarefa do classificador é usar o vetor fornecido pelo processo de extração e seleção de atributos para atribuir o objeto a esta classe (DUDA; HART; STORK, 2012). A obtenção de uma classificação ideal, que corresponda totalmente a realidade é quase impossível. Uma tarefa mais geral, seria estimar a probabilidade de que um padrão (objeto) pertença a uma determinada classe, baseando-se nos valores de alguns atributos ou em um conjunto de atributos. A classificação de região estima a variabilidade espacial de uma determinada região.

3.4.1 Perceptron de Múltiplas Camadas - MLP

Perceptron de múltiplas camada (MLP) é uma rede de unidades de processamento simples, dispostos em um modelo hierárquico de camadas (GALLAGHER, 2000). Essa rede é composta de várias camadas de neurônios, sendo uma camada de entrada, uma ou várias camadas intermediárias (ocultas) e uma camada de saída. Cada entrada de neurônio está ligada a saída da camada anterior, exceto a camada de entrada, que é alimentada com um vetor de características (LOTTE et al., 2007). As ligações possuem um valor de peso numérico associado a elas e o sinal transmitido, por meio de uma ligação, é multiplicado pelo valor do peso. Cada unidade calcula alguma função da soma de suas entradas ponderadas, e transmite o resultado por meio de suas conexões de saída (GALLAGHER, 2000).

Seja qual for a estrutura da rede, o fluxo de informação é realizado em uma única direção, começando na da entrada da rede e terminando ao final dela, sem ciclos ou conexões para nós anteriores (GALLAGHER, 2000). Redes neurais, assim como MLP, tem a capacidade de aproximar funções contínuas, adicionando o fato de que podem classificar qualquer número de classes. Isto faz de redes neurais classificadores muito flexíveis que podem se adaptar a uma grande variedade de problemas (LOTTE et al., 2007).

Para a realização do treinamento da rede é utilizado o algoritmo *backpropagation* (RUMELHART; MCCLELLAND, 1986). Esse algoritmo fornece um meio de ajustar os pesos na rede, dado um conjunto de dados de treinamento (GALLAGHER, 2000). O algoritmo funciona em duas etapas, na primeira etapa é apresentado um padrão à camada de entrada da rede e os resultados são propagados por meio da rede, camada por camada, até que a resposta seja produzida pela camada de saída. Na segunda etapa, a saída obtida é comparada com a saída desejada, se não estiver correto, o erro é calculado e propagado a partir da camada de saída até a camada de entrada. Os pesos das conexões das unidades das camadas internas são modificados conforme o erro é retropropagado. Essas etapas são repetidas até que o erro atinja um nível aceitável.

3.4.2 Máquina de Vetor de Suporte - SVM

Máquina de vetor de suporte (SVM) é uma técnica de classificação de padrões proposta por (VAPNIK; VAPNIK, 1998). Essa técnica constrói a partir de um conjunto de exemplos de treino contendo classes categorizadas, um modelo capaz de atribuir a novos exemplos uma das categorias contidas no conjunto de treinamento. Para isso o SVM utiliza funções lineares para distinção das classes, selecionando hiperplanos que maximizam as margens (LOTTE et al., 2007).

O SVM mapeia implicitamente os dados de entrada para um espaço de maior dimensionalidade, pois nessa dimensão é possível separar linearmente os conjuntos, sendo que a função responsável por esse mapeamento é denominada *kernel*. As funções de Kernel são aplicadas nos vetores de entrada de dimensão N , é obtido um novo vetor de dimensão X , onde X é maior que N . Após esse cálculo são obtidos os vetores de suporte. Com os vetores calculados é possível definir o hiperplano de separação ótimo.

3.5 Considerações finais

Este capítulo apresentou a base de imagens, os algoritmos de *superpixels* avaliados, os descritores de textura e os dois classificadores avaliados. No próximo capítulo apresentaremos os resultados e discussão.

4 Resultados e Discussão

Nesta seção será apresentado os resultados obtidos pelas técnicas de segmentação com utilização de *superpixels* avaliadas neste trabalho.

A classificação dos dados foi realizada com os classificadores, Máquina de Vetor de Suporte (SVM) e Perceptron de Múltiplas Camadas (MLP). Estes também estão implementados na ferramenta WEKA, onde os testes foram executados.

4.1 Avaliação dos Algoritmos de Superpixels

Nesse trabalho fizemos duas avaliações, sendo a avaliação da segmentação do *superpixel* e a avaliação da classificação dos *superpixels*. Inicialmente demonstraremos a metodologia de avaliação da segmentação do *superpixel* e o resultado da segmentação. Depois a metodologia da avaliação da classificação e os resultados.

4.1.1 Metodologia de Avaliação da Segmentação por Superpixels

Existem várias métricas de avaliação de segmentação de imagens. No trabalho proposto em [Neubert e Protzel \(2012\)](#) foi concluído que a supersegmentação e a subsegmentação são as principais métricas de avaliação a serem utilizadas na segmentação por *superpixels*. Para exemplificar o cálculo dessas métricas, a Figura 12 apresenta um exemplo de segmentação por *superpixels*.

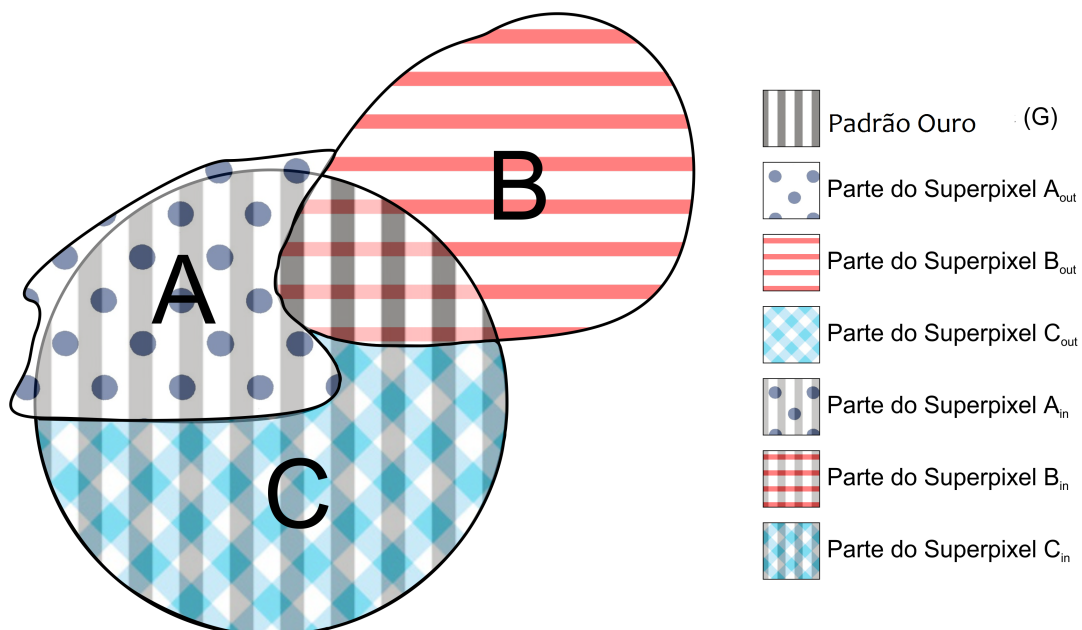


Figura 12 – Exemplo de segmentação com três superpixels.

A circunferência representa a área a ser segmentada. As regiões A, B e C representam três *superpixels*. O erro de supersegmentação ocorre quando os três *superpixels* forem classificados e pertencem a região circular C. O erro é calculado através da parte externa da região que sobrou em A e B, o C não entra no cálculo por delimitar a região corretamente. O erro de subsegmentação ocorre quando nenhuma dos três *superpixels* não foram classificados sobre a região circular C. O erro é calculado através da região interna de A, B mais área total da região C por completa.

O erro de supersegmentação $E_{SuperSG}$ é dado pela Equação 4.1. O erro de subsegmentação E_{SubSG} é dado pela Equação 4.2.


$$E_{SuperSG} = \frac{\sum_{SP:SP \cap G \neq \emptyset} |SP_{out}|}{|G|} \quad (4.1)$$

$$E_{SubSG} = \frac{\sum_{SP:SP \cap G \neq \emptyset \text{ e } SP \cup G \neq G} |SP_{in}|}{|G|} \quad (4.2)$$


O SP representa a quantidade de *superpixels*, G padrão ouro e SP_{out} é quantidade de *superpixels* da parte de fora da região segmentada e SP_{in} representa a quantidade de *superpixels* da parte de dentro da região segmentada.

4.1.2 Resultados da Segmentação por Superpixels

Foram analisados seis algoritmos de *superpixels*, com nove quantidades de *superpixels*: 50, 100, 200, 400, 600, 800, 1000, 1200 e 1400 *superpixels* por imagem. As Figuras 13a e 13b apresentam a média dos erros da supersegmentação da região de escavação e disco óptico (DO) da base *DRISHTI-GS*. As Figuras 14a e 14b apresentam a média dos erros da subsegmentação da região de escavação e DO.




(a)




(b)

Figura 13 – Resultado da supersegmentação: (a) região da escavação, (b) região do DO da base *DRISHTI-GS*.



(a)



(b)

Figura 14 – Resultado da subsegmentação: (a) região da escavação, (b) a região do DO da base *DRISHTI-GS*.

Considerando o erro de supersegmentação na região da escavação e DO, podemos observar que alguns dos algoritmos estudados apresentaram uma taxa de erro baixa. O algoritmo SCOW, apresentou um melhor resultado com a quantidade de 1400 *superpixel* na região de escavação. Na região DO, o melhor algoritmo foi SLIC0, com a quantidade de 1400 *superpixels*.

Considerando o resultado da subsegmentação na região de escavação, podemos observar que o algoritmo SLIC apresentou um melhor resultado com 1400 *superpixels*. Na região do DO, o melhor resultado foi no algoritmo SLIC0 com 1400 *superpixels*.

Podemos observar que a partir de 800 *superpixels*, o erro da supersegmentação e subsegmentação vai diminuindo, mas isso já é previsto na literatura. Quanto maior for a quantidade de *superpixel*, mais o erro irá diminuir. Porém, implica um maior tempo de processamento dos dados. Na utilização de uma pequena quantidade de *superpixel* teríamos dificuldade em classificar as regiões do disco óptico e com essa quantidade de *superpixels* teríamos que realizar um pré ou pós-processamento nas imagens para diminuir o erro de segmentação.

Com todos esses requisitos, avaliamos uma quantidade de *superpixel* que evitasse um pré ou pós-processamento nas imagens evitando grande processamento computacional. A nossa avaliação inicial foi realizada com 800 e 1000 *superpixels*. Como os resultados com 1000 *superpixels* foram melhores do que na quantidade de 800 *superpixels*. Essa quantidade de *superpixels* não requer um pré ou pós-processamento e ao mesmo tempo não comprometa o tempo de processamento computacional para a obtenção dos resultados.

4.2 Avaliação da Classificação dos Superpixels

Após a extração de características ainda não é possível prever se uma imagem indica ou não glaucoma, por isso fez-se necessário a etapa de classificação, onde os atributos calculados na etapa anterior formaram um vetor que servirá de entrada para os classificadores. Mostraremos a seguir avaliação da classificação dos *superpixels*.

4.2.1 Metodologia de Avaliação da Classificação dos Superpixels

Para avaliar o desempenho dos algoritmos foram utilizadas as métricas: Taxa Falso Positivo (*Falso Positivo Rate* - FPR), Precisão (P), *Recall* (R), *F-Measure* (FM) e Área sob a curva ROC. Todas essas métricas são calculadas com base nos valores: Verdadeiro Positivo (VP), Falso Positivo (FP), Falso Negativo (FN) e Verdadeiro Negativo (VN), são representados nas Equações de 4.3 a 4.7.

$$FPR = \frac{FP}{FP + VN} \quad (4.3)$$

$$Precisão = \frac{VP}{VP + FP} \quad (4.4)$$

$$Recall = \frac{VP}{VP + FN} \quad (4.5)$$

$$F-Measure = \frac{2 * R * P}{R + P} \quad (4.6)$$

$$AUC = \frac{VP}{VP + FN} \quad (4.7)$$

O VP refere-se aos *pixels* corretamente informados como positivos, FP refere-se aos *pixels* incorretamente informados como positivos, FN refere-se aos *pixels* incorretamente informados como negativos, e por fim VN corresponde aos *pixels* corretamente informados como negativos.

A taxa de falso positivo, refere-se à proporção do falso positivo em relação ao verdadeiro negativo. Usualmente refere-se à probabilidade de uma rejeição falsa com relação ao positivo. A precisão reflete a proporção de verdadeiros positivos em relação a todas as predições positivas. A precisão de uma classificação mostra a quantidade de objetos da classe X classificados corretamente em relação a todos os objetos classificados como sendo da classe X. *Recall* reflete a proporção de verdadeiros positivos em relação a suas predições positivas e as suas incorretas predições negativas. Essa medida mostra o comportamento dos objetos classificados como X, ou seja, de todos os objetos da classe X, quantos foram classificados como X. A *F-measure* só produz bons resultados quando as taxas de precisão e *recall* são equilibradas. Assim, essa é uma medida bastante significativa (CHIMIESKI; FAGUNDES, 2013). O resultado da *F-measure* varia entre 0 e 1. Logo, quanto mais próximo de 1 melhor é o resultado da classificação.

A curva ROC mostra as taxas de verdadeiros positivos em relação às taxas de falsos positivos. A curva é montada variando o limiar do classificador e observando os resultados gerados a partir dessa modificação. A curva ROC tem por objetivo avaliar a eficiência em termos de taxa de acertos dos algoritmos de aprendizado de máquina. A principal informação extraída de uma curva ROC é a área sob a curva (*Área Under Curve ROC - AUC*), quanto maior a área melhor o desempenho do classificador.

A técnica empregada para a avaliação do processo de classificação foi a técnica de validação cruzada que consiste em dividir a base de dados em k partes, usamos um $k=5$, dividindo a base em cinco conjunto de dados. Destas, $k - 1$ partes são utilizadas para o treinamento e uma serve como base de testes. O processo é repetido 5 vezes, de forma que cada parte seja usada uma vez como conjunto de teste. No final, a correção total é calculada pela média dos resultados obtidos em cada etapa, obtendo-se assim uma

estimativa da qualidade do modelo de conhecimento gerado e permitindo assim análises (SANTOS et al., 2009).

Nas subseções 4.2.2 e 4.2.4 mostraremos os resultados da classificação. Esses resultados foram divididos em método de fase única e duas fases. Os testes iniciais foram realizados sobre as imagens sem nenhum pré-processamento, em seguida testes com pré-processamento nas imagens. Dessa forma, foi possível comparar os resultados. Nos trabalhos citados no estado da arte, todos os testes foram realizados fazendo uso de imagens pré processadas. O objetivo do pré-processamento é tentar deixar as regiões mais homogêneas.

No método de fase única classificamos três regiões de interesse, sendo azul a região do fundo, verde a região do disco óptico e em vermelho a região de escavação como mostra na Figura 15.




Figura 15 – Método de fase única.

No método de duas fases, foram feitos dois testes. O primeiro identificamos a região do disco óptico como um todo representado pela Figura 16 . Segundo teste tentamos diferenciar a região de escavação do disco óptico como mostra a Figura 17.




Figura 16 – Método de duas fases primeiro teste.




Figura 17 – Método de duas fases segundo teste.

4.2.2 Resultados da Classificação do Método de Fase Única

No resultado da classificação do método de fase única foram feitos testes sem a utilização de pré-processamento e com o pré-processamento sobre características de textura extraídas pelos descritores: *Grey-Level Co-Occurrence Matrix* - GLCM, *Local Binary Pattern* - LBP, *Histograms of Oriented Gradients* - HOG e *Grey Level Run Length Matrix* - GLRLM.

Testes foram realizados com 100%, 30% e 10% dos atributos mais relevantes dos descritores de textura. Apresentaremos nesta seção os resultados obtidos pelos classificadores, apenas com 10% dos atributos mais relevantes extraídos pelos descritores de textura. Os demais resultados serão apresentados no apêndice.

Nas tabelas relatamos os valores referentes a Média, Máximo (Máx), Mínimo (Min) e Desvio padrão (σ). A Tabela 1, apresenta os resultados do descritor de textura GLCM, destacando em negrito a melhor média de cada métrica avaliada, nos dois classificadores. O classificador MLP obteve uma melhor média e todas as métricas de avaliação em comparação a SVM.

Tabela 1 – Resultado da classificação do descritor de textura GLCM nos classificadores MLP e SVM.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,25	0,64	0,02	0,15	0,32	0,76	0,02	0,18
Precisão	0,74	0,97	0,47	0,08	0,67	0,89	0,47	0,09
<i>Recall</i>	0,72	0,93	0,38	0,12	0,71	0,92	0,31	0,10
<i>F-Measure</i>	0,69	0,94	0,40	0,11	0,65	0,91	0,39	0,12
<i>AUC</i>	0,95	0,99	0,62	0,06	0,91	0,99	0,52	0,05

A seguir apresentaremos o resultado da segmentação dos classificadores MLP e SVM. Para analisar o resultado da segmentação da região de interesse, representados as imagens em quatro cores: a cor azul representa a região do fundo da imagem, a cor vermelha diz respeito a região da escavação e a cor verde representa a região do DO e na cor preta a marcação feita por um especialista delimitando a região de escavação e DO. Os melhores e piores resultados em cada classificador é com base na métrica *Recall*. A Figura 18 apresenta o resultado aos classificadores MLP e SVM.

Na Tabela 2 é mostrado o resultado da classificação do descritor de textura LBP. Com a análise dos resultados o classificador MLP sobressaiu em relação ao classificador SVM.

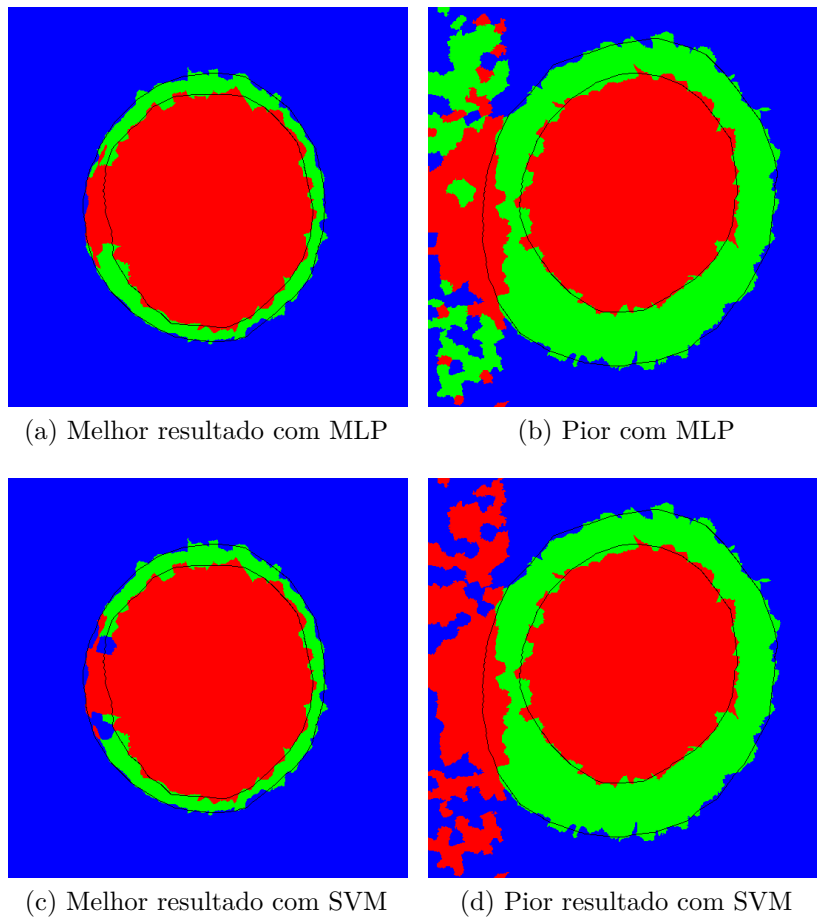


Figura 18 – Resultado da segmentação nos classificadores MLP e SVM, no descritor de textura GLCM.

Tabela 2 – Resultado da classificação do descritor de textura LBP nos classificadores MLP e SVM.

Métricas	MLP				SVM			
	Média	Máx	Mín	σ	Média	Máx	Mín	σ
FPR	0,42	0,84	0,26	0,13	0,57	0,94	0,25	0,21
Precisão	0,60	0,89	0,26	0,27	0,36	0,88	0,06	0,23
<i>Recall</i>	0,54	0,86	0,29	0,14	0,57	0,94	0,25	0,20
<i>F-Measure</i>	0,49	0,81	0,16	0,20	0,43	0,91	0,10	0,23
<i>AUC</i>	0,64	0,77	0,57	0,05	0,65	0,59	0,53	0,24

Agora mostraremos o resultado da segmentação do descritor de textura LBP na Figura 19 mediante dos dois classificadores avaliados.

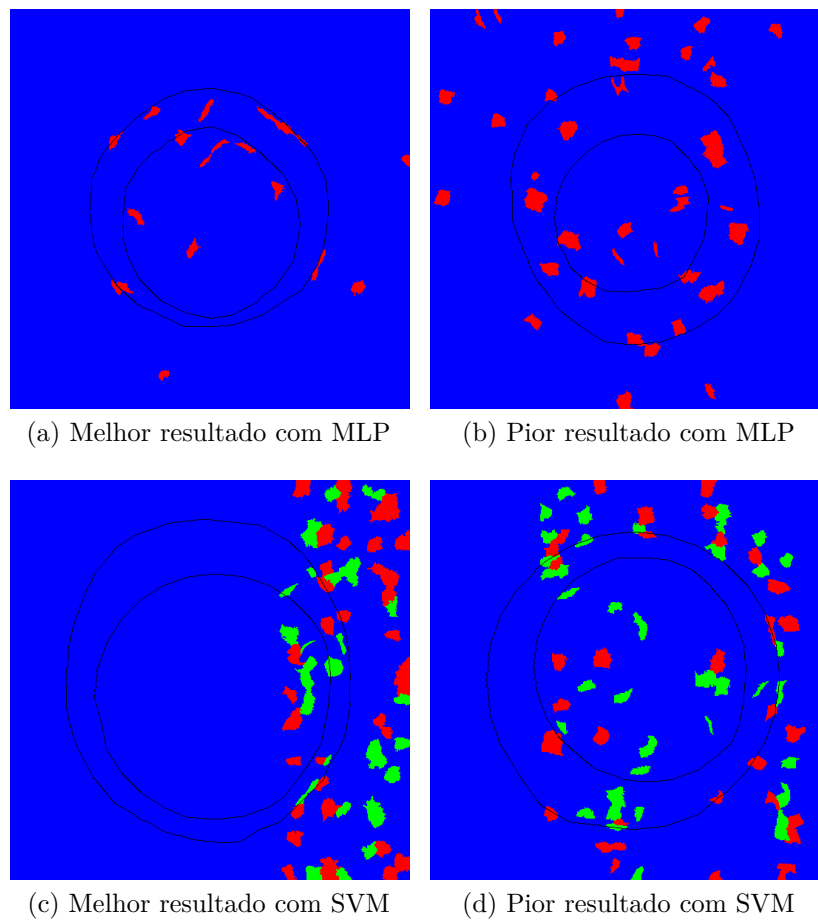


Figura 19 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura LBP.

A seguir, a Tabela 3 apresenta o resultado da classificação do descritor de textura HOG, destacando em negrito a melhor média de cada métrica avaliada, nos dois classificadores. Em comparação nos resultados obtidos, o classificador MLP sobressaiu com relação a SVM.

Tabela 3 – Resultado da classificação do descritor de textura HOG nos classificadores MLP e SVM.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,25	0,72	0,10	0,11	0,27	0,72	0,09	0,09
Precisão	0,68	0,77	0,53	0,05	0,66	0,85	0,53	0,07
<i>Recall</i>	0,71	0,81	0,40	0,07	0,72	0,86	0,60	0,06
<i>F-Measure</i>	0,66	0,77	0,45	0,08	0,67	0,83	0,56	0,06
<i>AUC</i>	0,87	0,96	0,74	0,06	0,73	0,88	0,50	0,06

A Figura 20 apresenta o resultado da segmentação no descritor de textura HOG alcançados nos classificadores MLP e SVM. Os classificadores identificaram vários pontos sendo da região de escavação.




Figura 20 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura HOG.

Considerando o resultado da classificação do descritor de textura GLRLM, podemos analisar o comportamento de cada classificador na Tabela 4, destacando-se em negrito a melhor média de cada métrica avaliada nos dois classificadores. Com os resultados apresentados, o classificador MLP obteve melhores média sobre as métricas.

Tabela 4 – Resultado da classificação no descritor de textura GLRLM nos classificadores MLP e SVM.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,23	0,70	0,02	0,12	0,27	0,72	0,08	0,10
Precisão	0,62	0,77	0,52	0,06	0,63	0,82	0,52	0,04
<i>Recall</i>	0,71	0,79	0,41	0,06	0,70	0,83	0,59	0,04
<i>F-Measure</i>	0,66	0,73	0,42	0,06	0,64	0,80	0,53	0,07
<i>AUC</i>	0,84	0,93	0,71	0,07	0,70	0,85	0,43	0,06

A Figura 21 apresenta os resultados da segmentação obtidos nos classificadores

MLP e SVM no descritor de textura GLRLM. A classificação da região de interesse se mostraram bastantes dispersos.

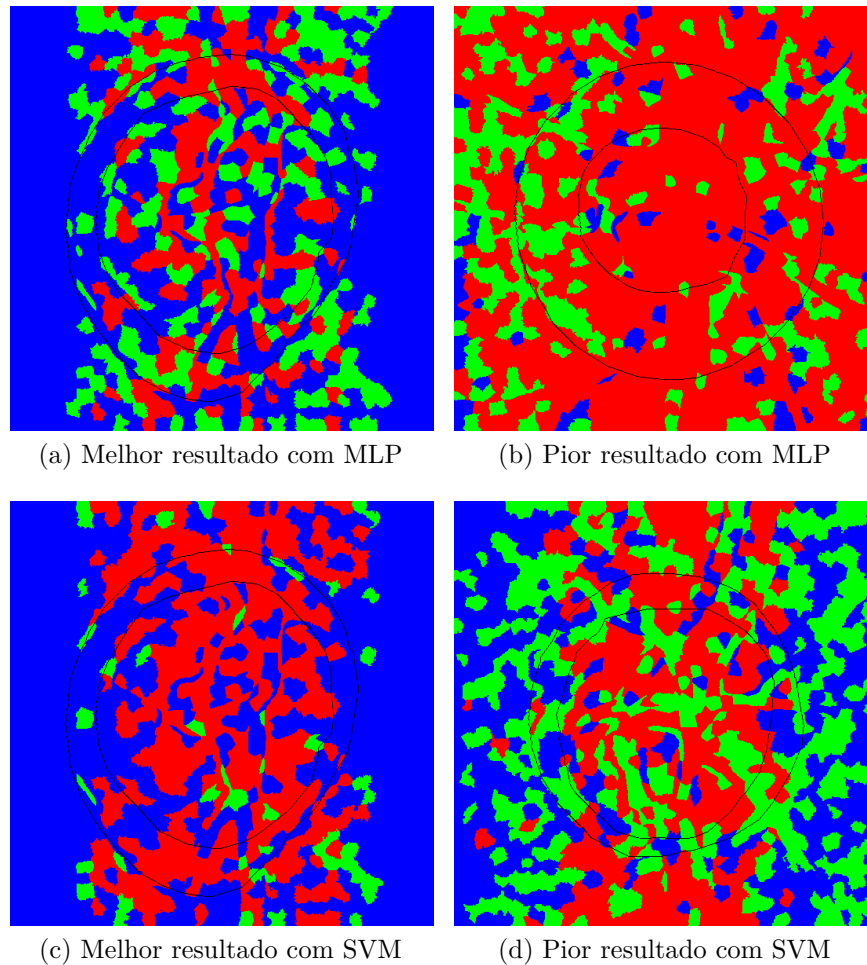


Figura 21 – Resultado da segmentação no classificador MLP e SVM no descritor de textura GLRLM.

Os descritores de textura GLCM e LBP foram os melhores com base na métrica do *Recall*, partindo dessa informação, nós tentamos unir os dois em um único vetor de atributos. Na Tabela 5 é o resultado dessa união.

Tabela 5 – Resultado da classificação dos descritores de textura GLCM e LBP nos classificadores MLP e SVM.

Métricas	MLP				SVM			
	Média	Máx	Mín	σ	Média	Máx	Mín	σ
FPR	0,27	0,48	0,03	0,13	0,36	0,57	0,08	0,15
Precisão	0,71	0,96	0,59	0,05	0,62	0,87	0,52	0,07
<i>Recall</i>	0,62	0,95	0,31	0,14	0,63	0,87	0,43	0,08
<i>F-Measure</i>	0,58	0,95	0,27	0,13	0,55	0,84	0,41	0,08
<i>AUC</i>	0,79	0,98	0,60	0,07	0,63	0,90	0,53	0,08

A Figura 22 apresenta os resultados da segmentação dos dois classificadores avalia-

dos. O melhor resultado do classificador MLP classificou a região do DO sobre a região de escavação, no pior resultado classificou a região do fundo sendo da região do DO. No melhor resultado do classificador SVM, ele classificou a região de escavação pertencente a região do DO, já no pior resultado classificou a imagem sendo da região de escavação.




Figura 22 – Resultado da segmentação nos classificadores MLP e SVM na união dos dois descritores de texturas.

4.2.3 Resultados da Classificação do Método de Fase Única Com Pré-Processamento

Os trabalhos citados no estado da arte, executam pré-processamento nas imagens antes de aplicar a geração de *superpixel*. O pré-processamento melhora contraste nas imagens. Com base nessas informações, resolvermos também fazer um teste aplicando pré-processamento nas imagens, a fim de compararmos com os resultados da subseção 4.2.2 sem o uso do pré-processamento nas imagens.

Na Tabela 6 apresentamos os resultados do descritor de textura GLCM, destacando em **negrito** a melhor média de cada métrica avaliada nos dois classificadores. Podemos observar que o classificador MLP obteve as melhores médias sobre as métricas avaliadas.

Tabela 6 – Resultado da classificação do descritor de textura GLCM com imagem com pré-processamento, nos classificadores MLP e SVM.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,22	0,62	0,11	0,09	0,23	0,62	0,05	0,09
Precisão	0,69	0,81	0,57	0,05	0,79	0,89	0,54	0,04
<i>Recall</i>	0,70	0,83	0,41	0,07	0,65	0,72	0,40	0,05
<i>F-Measure</i>	0,68	0,80	0,38	0,08	0,59	0,79	0,33	0,06
<i>AUC</i>	0,87	0,96	0,74	0,04	0,79	0,91	0,54	0,08

Na Figura 23 os classificadores não conseguiram identificar as regiões de interesse, classificando alguns pontos pertencente à região de escavação. Os piores resultados pontos dispersos das duas regiões.

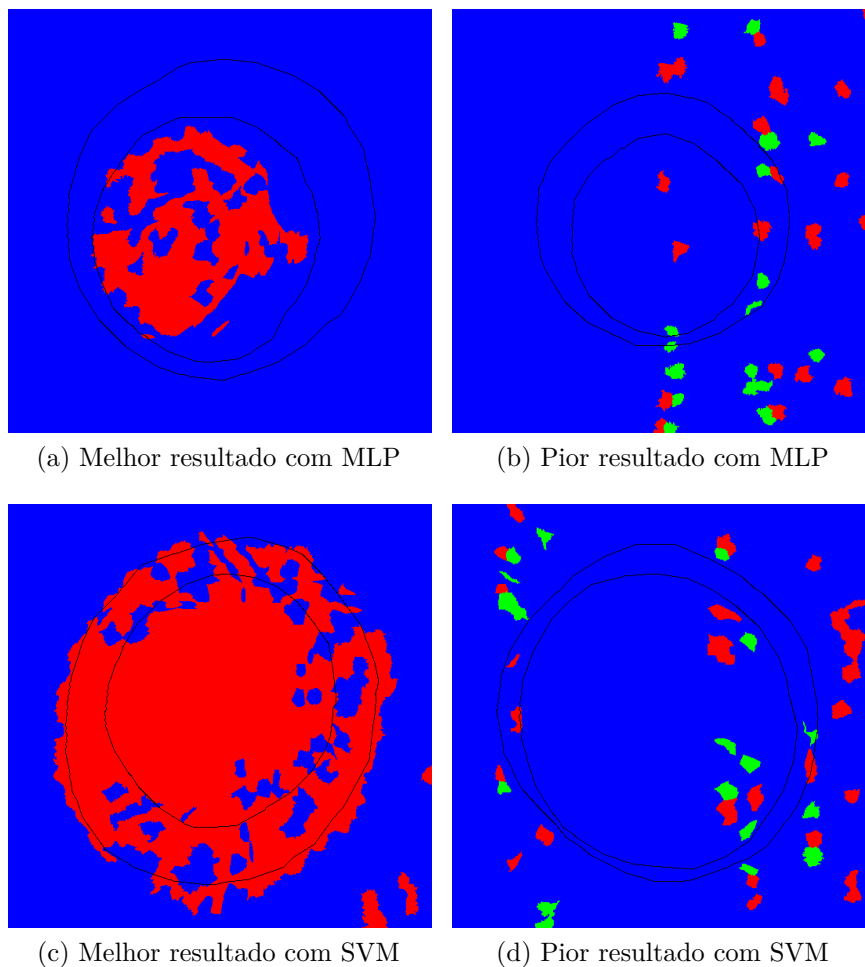


Figura 23 – Resultado da segmentação com pré-processamento na imagem, nos classificadores MLP e SVM no descritor de textura GLCM.

Na Tabela 7 apresentaremos os resultados do descritor de textura LBP. Em conformidade com resultados, o classificador MLP obteve um melhor desempenho e comparação com o classificador SVM.

Tabela 7 – Resultado da classificação do descritor de textura LBP com pré-processamento nas imagens, nos classificadores MLP e SVM.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,62	0,74	0,55	0,04	0,64	0,76	0,56	0,06
Precisão	0,50	0,64	0,32	0,06	0,40	0,58	0,32	0,05
<i>Recall</i>	0,63	0,75	0,56	0,04	0,62	0,76	0,56	0,07
<i>F-Measure</i>	0,50	0,66	0,42	0,06	0,49	0,67	0,41	0,06
<i>AUC</i>	0,59	0,65	0,55	0,02	0,69	0,55	0,45	0,01

Mostraremos o resultado da segmentação dos classificadores estudados. A Figura 24 apresentam os resultados da segmentação com um pré-processamento nas imagens, sobre o descritor de textura LBP.

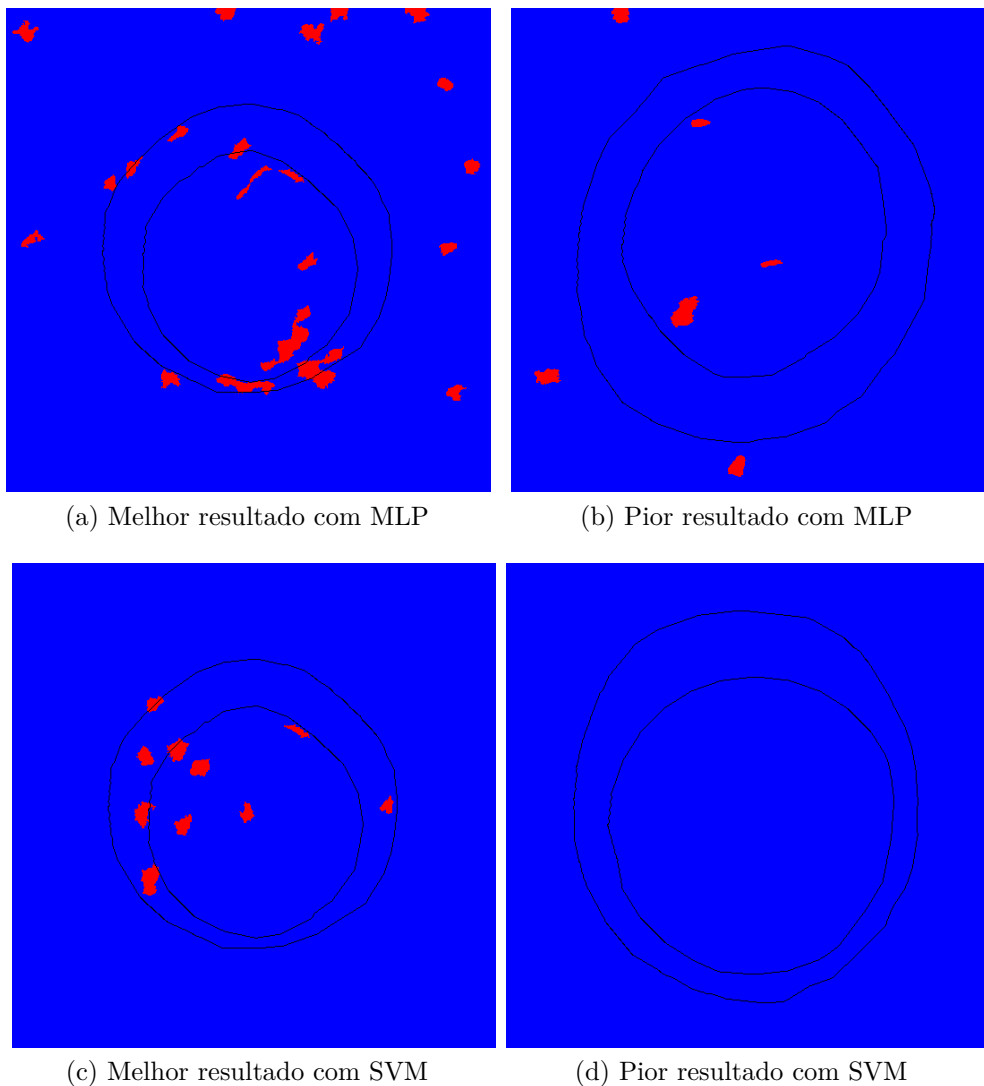


Figura 24 – Resultado da segmentação com pré-processamento na imagem, nos classificadores MLP e SVM, no descritor de textura LBP.

Na Tabela 8 apresentamos os resultados do descritor de textura HOG. Nesse

descritor o classificador MLP se sobressaiu com relação ao classificador SVM.

Tabela 8 – Resultado da classificação do descritor de textura HOG com um pré-processamento, nos classificadores MLP e SVM.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,22	0,64	0,07	0,09	0,23	0,65	0,08	0,09
Precisão	0,83	0,94	0,65	0,05	0,80	0,92	0,64	0,05
<i>Recall</i>	0,62	0,95	0,31	0,14	0,80	0,92	0,59	0,07
<i>F-Measure</i>	0,81	0,93	0,61	0,06	0,79	0,92	0,53	0,08
<i>AUC</i>	0,90	0,99	0,70	0,06	0,79	0,91	0,54	0,08

A Figura 25 os resultados da segmentação com pré-processamento nas imagens, obtido nos classificadores MLP e SVM, no descritor de textura HOG.




Figura 25 – Resultado da segmentação com pré-processamento na imagem, nos classificadores MLP e SVM, no descritor de textura HOG.

Na Tabela 9 mostramos os resultados do descritor de textura GLRLM, os resultados apresentados podemos notar que classificador SVM obteve um melhor desempenho em

comparação ao MLP.

Tabela 9 – Resultado da classificação do descritor de textura GLRLM com pré-processamento, nos classificadores MLP e SVM.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,64	0,76	0,57	0,04	0,63	0,76	0,56	0,04
Precisão	0,40	0,59	0,32	0,06	0,41	0,58	0,31	0,05
<i>Recall</i>	0,62	0,75	0,56	0,03	0,63	0,76	0,57	0,07
<i>F-Measure</i>	0,50	0,66	0,41	0,05	0,49	0,67	0,40	0,06
<i>AUC</i>	0,49	0,53	0,48	0,02	0,50	0,54	0,47	0,03

A Figura 26 apresentam os resultados da segmentação com um pré-processamento nas imagens, nos classificadores MLP e SVM. A segmentação das regiões os classificadores identificaram alguns pontos sendo da região de escavação.

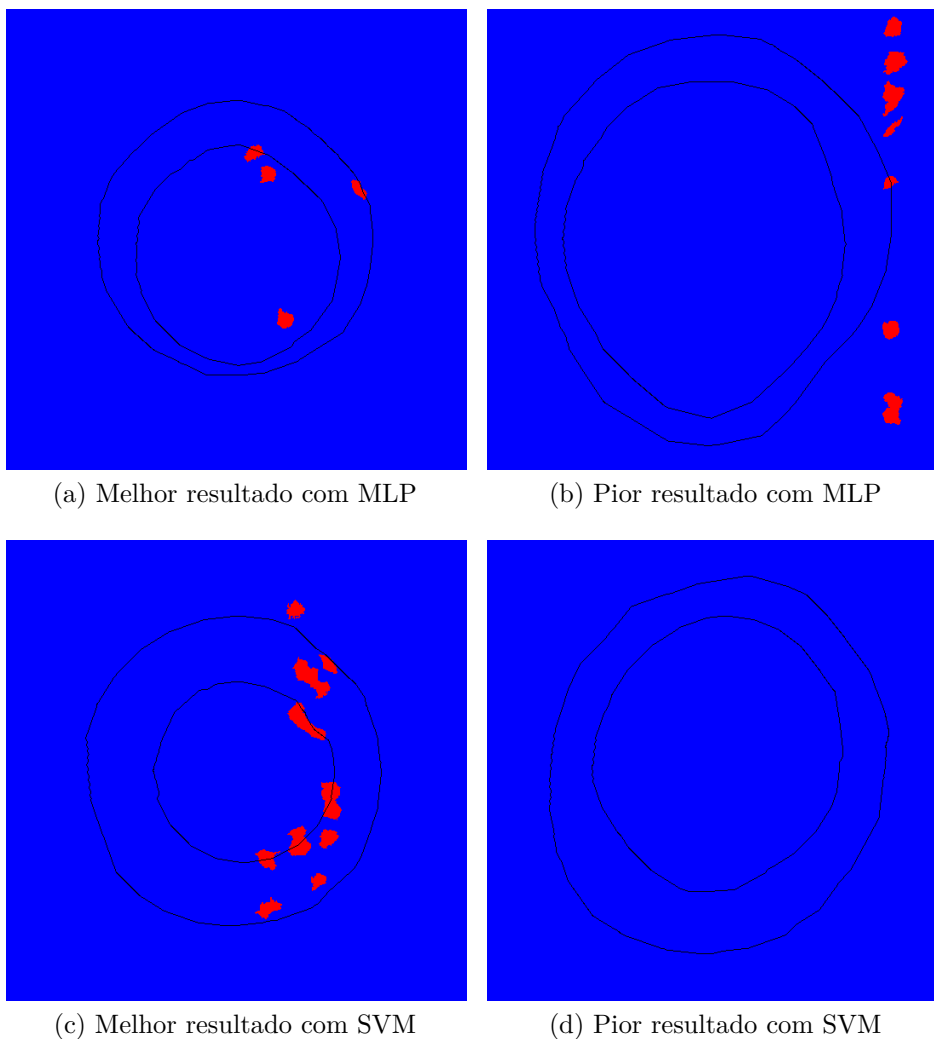


Figura 26 – Resultado da segmentação com pré-processamento na imagem, nos classificadores MLP e SVM, no descritor de textura GLRLM.

Os resultados obtidos aplicando um pré-processamento nas imagens antes da geração *superpixels*, não foram muito bons na segmentação das regiões do disco óptico.

4.2.4 Resultados da Classificação do Método de Duas Fases

Com o objetivo de aprimorar os resultados, fizemos testes utilizando um método de duas fases. Os testes foram realizados no descritor de textura GLCM que apresentou o melhor desempenho em relação aos outros descritores estudados. Nesse método foram executados dois testes: o primeiro teste tentamos identificar a região do disco óptico como um todo e o segundo teste com adição da distância do centroide do centro da imagem, que no estado da arte os trabalhos utilizaram essa distância melhora a identificação das regiões de interesse.

Na Tabela 10 são apresentados os resultados do descritor de textura GLCM, com método de duas fases sobre os dois classificadores estudados, destacando em negrito a melhor média de cada métrica avaliada, nos dois classificadores. O classificador MLP obteve um melhor resultado em comparação a classificador SVM.

Tabela 10 – Resultado da classificação do descritor de textura GLCM com método de duas fases, nos classificadores MLP e SVM.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,21	0,60	0,03	0,13	0,25	0,64	0,02	0,15
Precisão	0,87	0,96	0,67	0,06	0,74	0,97	0,47	0,08
<i>Recall</i>	0,72	0,96	0,38	0,13	0,81	0,93	0,38	0,10
<i>F-Measure</i>	0,80	0,96	0,26	0,17	0,69	0,94	0,40	0,11
<i>AUC</i>	0,95	0,99	0,62	0,06	0,92	0,96	0,63	0,05

Na Figura 27 apresenta os resultados da segmentação nos classificadores MLP e SVM. O melhor resultado de cada classificador foram muitos bons na identificação da região disco óptico como todo.

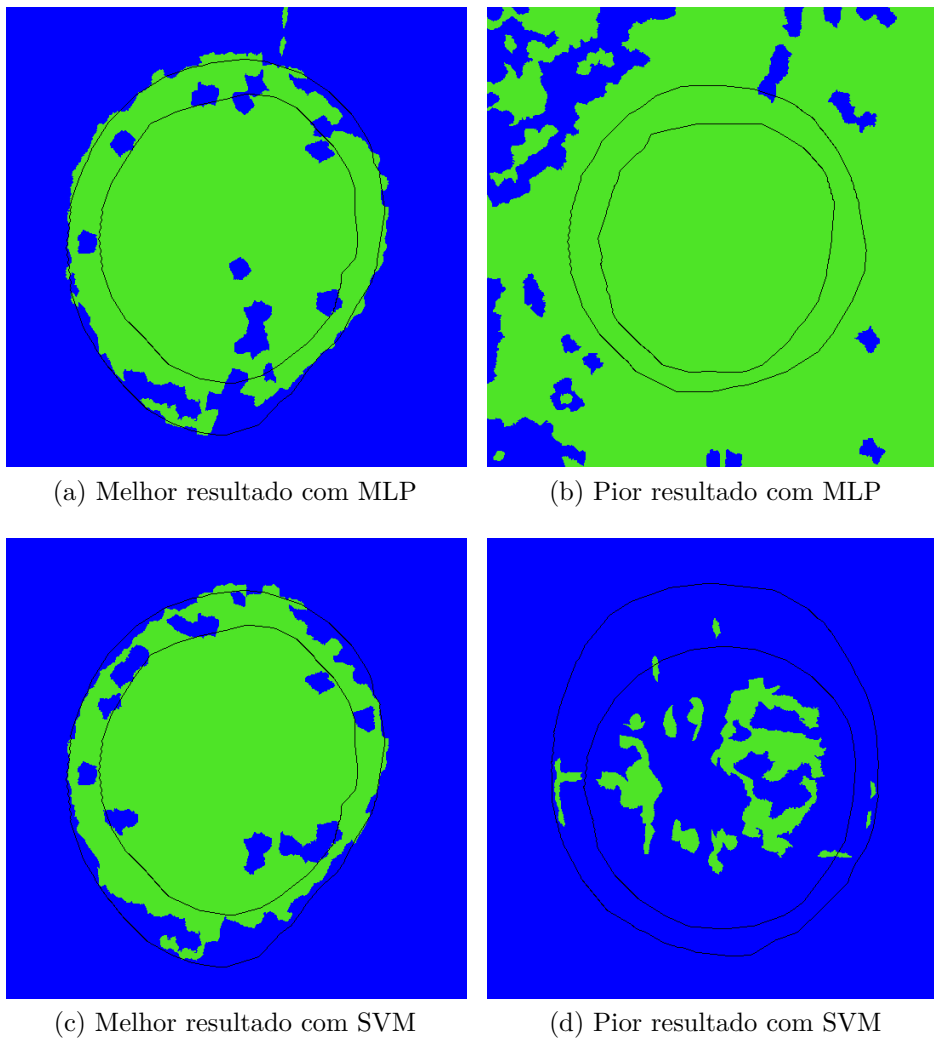


Figura 27 – Resultado da segmentação dos classificadores MLP e SVM, no descritor de textura GLCM no método de duas fases.

Na Tabela 11 o resultado da classificação do descritor de textura GLCM com adição da distância do centroide do centro da imagem. O classificador MLP apresenta um melhor resultado em comparação ao classificador SVM.

Tabela 11 – Resultado da classificação do descritor de textura GLCM com método de duas fases, com adição da distância do centroide do centro da imagem, nos classificadores MLP e SVM.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,22	0,64	0,07	0,09	0,23	0,65	0,08	0,09
Precisão	0,83	0,94	0,65	0,05	0,80	0,90	0,64	0,05
<i>Recall</i>	0,62	0,95	0,31	0,14	0,80	0,92	0,59	0,07
<i>F-Measure</i>	0,81	0,93	0,61	0,06	0,73	0,89	0,53	0,08
<i>AUC</i>	0,90	0,99	0,70	0,06	0,79	0,91	0,54	0,08

A Figura 28 apresenta os resultados da segmentação nos classificadores MLP e

SVM. Os resultados da segmentação com a adição da distância do centroide da imagem não foram bons, como pode ser observado que os classificadores não conseguiram classificar as regiões de interesse.




Figura 28 – Resultado da segmentação nos classificadores MLP e SVM, no descritor de textura GLCM no método duas fases, com adição da distância do centroide do centro da imagem.

Os resultados apresentados no método de duas fases, o primeiro teste na identificação do disco óptico como um todos apresentou bons resultados. No segundo teste com adição da distância do centroide da imagem os teste não foram bons em relação ao primeiro teste. A comparação entre o método de fase única e de duas fases, o método de fase única apresentou um melhor resultado de segmentação das regiões de interesse.

5 Conclusões e Trabalhos Futuros

O desenvolvimento desta dissertação possibilitou uma avaliação de algoritmos de *superpixels* e descritores de textura para segmentação das regiões do disco óptico. Além disso, também permitiu uma pesquisa sobre a importância dos algoritmos de *superpixels*, dos descritores de textura e dos classificadores para classificar as regiões do disco óptico.

O nosso objetivo é comparar os principais algoritmos de *superpixels* e descritores de textura para segmentação das regiões do disco óptico. Com a comparação dos resultados da segmentação com e sem pré-processamento nas imagens, foi analisado que não é recomendado a utilização do pré-processamento. Foram avaliados seis algoritmos de *superpixels*, quatro descritores de textura, e dois classificadores. Dentre dos seis algoritmos de *superpixels* avaliados o algoritmo SLIC0 demonstrou um melhor resultado sobre a região do disco óptico em comparação aos outros algoritmos, em relação as métricas proposto por (NEUBERT; PROTZEL, 2012).

Na avaliação dos quatro descritores de textura avaliados, o descritor GLCM apresentou melhor resultado na segmentação das regiões de interesse com base nos classificadores avaliados. Na classificação das regiões do disco óptico, dos dois classificadores avaliados. O classificador MLP apresentou melhor resultado sobre as métricas de avaliação da classificação dos *superpixels*. Já que na literatura todos os trabalhos utilizam o classificador SVM, sem nenhum indicativo da escolha de uso desse classificador. Os trabalhos na literatura usam uma quantidade de *superpixel* pequena, seja um indicativo que o classificador SVM seja melhor que o outros classificadores. Os dois métodos de classificação utilizados. O método de fase única obteve um melhor resultado na segmentação das regiões de interesse.

Para trabalhos futuros, pretende-se implementar o cálculo estatístico do centro (CSS) citado no trabalho (CHENG et al., 2013). Usar a remoção dos vasos sanguíneos, que é citado no trabalho (TAN et al., 2015). Com os resultados que cheguei não possibilitou o cálculo do CDR a relação escavação/disco. Executando essas duas etapas anteriores possibilite a fazer o cálculo do CDR que é comumente usada por oftalmologista para diagnóstico do glaucoma.

Referências

- ACHANTA, R. et al. Slic superpixels compared to state-of-the-art superpixel methods. *Transactions on Pattern Analysis and Machine Intelligence*, IEEE, v. 34, n. 11, p. 2274–2282, 2012. Citado 4 vezes nas páginas 9, 14, 16 e 17.
- ALGHMDI, H. et al. Measurement of optical cup-to-disc ratio in fundus images for glaucoma screening. In: IEEE. *International Workshop Computational Intelligence for Multimedia Understanding, 2015*. [S.l.], 2015. p. 1–5. Citado 4 vezes nas páginas 13, 5, 9 e 10.
- ANITHA, J.; VIJILA, C. K. S.; HEMANTH, D. J. An overview of computational intelligence techniques for retinal disease identification applications. *International Journal of Reviews in Computing*, Citeseer, v. 5, p. 29–46, 2009. Citado na página 1.
- BARALDI, A.; PARMIGGIANI, F. An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters. *Transactions on Geoscience and Remote Sensing*, IEEE, v. 33, n. 2, 1995. Citado na página 18.
- BOROVEC, J.; KYBIC, J. jslic: superpixels in imagej. Czech Society for Cybernetics and Informatics, 2014. Citado 2 vezes nas páginas 14 e 17.
- CAZES, P. et al. Extension de l'analyse en composantes principales á des donnés de type intervalle. *Revue de Statistique appliquée*, v. 45, n. 3, p. 5–24, 1997. Citado na página 21.
- CHENG, J. et al. Superpixel classification based optic disc and optic cup segmentation for glaucoma screening. *Transaction on Medical Imaging*, IEEE, v. 32, n. 6, p. 1019–1032, 2013. Citado 7 vezes nas páginas 13, 3, 4, 5, 9, 23 e 47.
- CHIMIESKI, B. F.; FAGUNDES, R. D. R. Association and classification data mining algorithms comparison over medical datasets. *Journal of health informatics*, v. 5, n. 2, 2013. Citado na página 30.
- DALAL, N.; TRIGGS, B. Histograms of oriented gradients for human detection. In: IEEE. *Computer Society Conference on Computer Vision and Pattern Recognition*. [S.l.], 2005. v. 1, p. 886–893. Citado na página 20.
- D'ANTONI, R.; GIUSTI, A. D. Model based retinal analysis for retinopathy detection. In: IEEE. *Engineering in Medicine and Biology Society*. [S.l.], 2007. p. 6731–6734. Citado na página 1.
- DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern classification*. [S.l.]: John Wiley & Sons, 2012. Citado na página 23.
- DUTRA, L. V. Feature extraction and selection for ers-1/2 insar classification. *International Journal of Remote Sensing*, Taylor & Francis, v. 20, n. 5, p. 993–1016, 1999. Citado na página 18.
- FELZENSZWALB, P. F.; HUTTENLOCHER, D. P. Efficient graph-based image segmentation. *International Journal of Computer Vision*, Springer, v. 59, n. 2, p. 167–181, 2004. Citado na página 14.

- FU, K.; GONZALES, R.; LEE, C. Robotics: Control, sensing, vision, and intelligence. mcgrawhill. *Inc., Singapore*, 1987. Citado na página 21.
- GALLAGHER, M. *Multi-layer perceptron error surfaces: visualization, structure and modelling*. Tese (Doutorado) — University of Queensland, 2000. Citado 2 vezes nas páginas 23 e 24.
- GONZALEZ, R. C.; WOODS, R. E. *Processamento de imagens digitais*. 3. ed. [S.l.]: Pearson Education, 2011. Citado 2 vezes nas páginas 1 e 2.
- GUO, Z.; ZHANG, L.; ZHANG, D. A completed modeling of local binary pattern operator for texture classification. *IEEE Transactions on Image Processing*, IEEE, v. 19, n. 6, p. 1657–1663, 2010. Citado na página 20.
- GUYON, I.; ELISSEEFF, A. An introduction to feature extraction. In: *Feature extraction*. [S.l.]: Springer, 2006. p. 1–25. Citado na página 22.
- HARALICK, R. M.; SHANMUGAM, K. et al. Textural features for image classification. *Transactions on systems, man, and cybernetics*, IEEE, n. 6, p. 610–621, 1973. Citado 2 vezes nas páginas 18 e 19.
- HOOVER, A.; GOLDBAUM, M. Locating the optic nerve in a retinal image using the fuzzy convergence of the blood vessels. *Transactions on Medical Imaging*, IEEE, v. 22, n. 8, p. 951–958, 2003. Citado na página 2.
- HU, Z.; ZOU, Q.; LI, Q. Watershed superpixel. In: IEEE. *International Conference on Image Processing*. [S.l.], 2015. p. 349–353. Citado 2 vezes nas páginas 14 e 17.
- INDIRA, K.; VINODHINI, J.; SNEHA, J. Optic disc and optic cup segmentation for glaucoma screening adopting superpixel classification. *International Journal Of Pharmacy e Technology*, IJPT, v. 7, n. 1, p. 8390–8400, 2015. Citado 3 vezes nas páginas 13, 5 e 10.
- JACOB, E.; R.VENKATESH. A method of segmentation for glaucoma screening using superpixel classification. *International Journal of Innovative Research in Computer and Communication Engineering*, IEEE, v. 2, n. 1, p. 2536–2543, 2014. Citado na página 16.
- JOSE, A. M.; BALAKRISHNAN, A. A. A novel method for glaucoma detection using optic disc and cup segmentation in digital retinal fundus images. In: IEEE. *International Conference on Circuit, Power and Computing Technologies*. [S.l.], 2015. p. 1–5. Citado na página 8.
- JUNIOR, C. da S.; SASSON, S. *Biologia*. [S.l.]: Atual, 1989. Citado 2 vezes nas páginas 13 e 2.
- KUMAR, N. A. et al. Active contours techniques for automatic detection of glaucoma. *International Journal of Recent Technology and Engineering*, Citeseer, v. 1, n. 4, p. 2277–3878, 2012. Citado na página 7.
- LI, Z.; CHEN, J. Superpixel segmentation using linear spectral clustering. *Computer Vision and Pattern Recognition*, p. 1356–1363, 2015. Citado 2 vezes nas páginas 14 e 18.
- LIU, M.-Y. et al. Entropy rate superpixel segmentation. In: *CVPR*. [S.l.: s.n.], 2011. p. 2097–2104. Citado 3 vezes nas páginas 1, 14 e 16.

- LOTANKAR, M.; NORONHA, K.; KOTI, J. Detection of optic disc and cup from color retinal images for automated diagnosis of glaucoma. In: INSTITUTE OF ELECTRICAL AND ELECTRONIC ENGINEERS. *UP Section Conference on Electrical Computer and Electronics*. [S.l.], 2015. p. 1–6. Citado na página 7.
- LOTTE, F. et al. A review of classification algorithms for eeg-based brain–computer interfaces. *Journal of neural engineering*, IOP Publishing, v. 4, n. 2, p. R1, 2007. Citado 2 vezes nas páginas 23 e 24.
- LUCULESCU, M. C.; LACHE, S. Computer-aided diagnosis system for retinal diseases in medical imaging. *Wseas Transactions on Systems*, World Scientific and Engineering Academy and Society, v. 7, n. 3, p. 264–276, 2008. Citado na página 1.
- MITTAPALLI, P. S.; KANDE, G. B. Segmentation of optic disk and optic cup from digital fundus images for the assessment of glaucoma. *Biomedical Signal Processing and Control*, Elsevier, v. 24, p. 34–46, 2016. Citado na página 8.
- MOOKIAH, M. R. K. et al. Computer-aided diagnosis of diabetic retinopathy: A review. *Computers in biology and medicine*, Elsevier, v. 43, n. 12, p. 2136–2155, 2013. Citado na página 1.
- MOORE, A. P. et al. Superpixel lattices. In: IEEE. *Computer Vision and Pattern Recognition*. [S.l.], 2008. p. 1–8. Citado na página 14.
- MURAMATSU, C. et al. Automated segmentation of optic disc region on retinal fundus photographs: Comparison of contour modeling and pixel classification method. *Computer Methods and Programs in Biomedicine*, v. 101, n. 1, p. 23–32, Janeiro 2011. Citado 2 vezes nas páginas 1 e 7.
- NAN, B.; MU, Z. Slic0-based superpixel segmentation method with texture fusion. *Chinese Journal of Scientific Instrument*, IEEE, v. 35, n. 3, p. 527–534, 2014. Citado 3 vezes nas páginas 14, 16 e 17.
- NEUBERT, P.; PROTZEL, P. Superpixel benchmark and comparison. In: *Proc. Forum Bildverarbeitung*. [S.l.: s.n.], 2012. p. 1–12. Citado 2 vezes nas páginas 25 e 47.
- NICOLELA, M. T.; VIANNA, J. R. Optic nerve: clinical examination. In: *Pearls of Glaucoma Management*. [S.l.]: Springer, 2016. p. 17–26. Citado na página 3.
- OJALA, T.; PIETIKÁINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, Elsevier, v. 29, n. 1, p. 51–59, 1996. Citado na página 20.
- PAPPA, G. L.; FREITAS, A. A.; KAESTNER, C. A. A multiobjective genetic algorithm for attribute selection. In: NOTTINGHAM TRENT UNIVERSITY. *Proc. 4th Int. Conf. on Recent Advances in Soft Computing (RASC-2002)*. [S.l.], 2002. p. 116–121. Citado na página 18.
- QUIGLEY, H. A.; BROMAN, A. T. The number of people with glaucoma worldwide in 2010 and 2020. *British journal of ophthalmology*, BMJ Publishing Group Ltd, v. 90, n. 3, p. 262–267, 2006. Citado na página 3.
- QUINLAN, J. R. Induction of decision trees. *Machine learning*, Springer, v. 1, n. 1, p. 81–106, 1986. Citado na página 22.

- REN, X.; MALIK, J. Learning a classification model for segmentation. In: IEEE. *Ninth Int'l Conf. Computer Vision*. [S.l.], 2003. p. 10–17. Citado 2 vezes nas páginas 4 e 14.
- REUNANEN, J. Overfitting in making comparisons between variable selection methods. *Journal of Machine Learning Research*, v. 3, n. Mar, p. 1371–1382, 2003. Citado na página 22.
- RUMELHART, D. E.; MCCLELLAND, J. L. The pdp research group: Parallel distributed processing: Explorations in the microstructure of cognition. *Foundations*, v. 1, 1986. Citado na página 24.
- SAID, Y.; ATRI, M.; TOURKI, R. Human detection based on integral histograms of oriented gradients and svm. In: IEEE. *International Conference on, Communications, Computing and Control Applications*. [S.l.], 2011. p. 1–5. Citado 2 vezes nas páginas 20 e 21.
- SANTOS, L. D. M. dos et al. Procedimentos de validação cruzada em mineração de dados para ambiente de computação paralela. A Escola Regional de Alto Desempenho, p. 233–236, 2009. Citado na página 31.
- SHI, J.; MALIK, J. Normalized cuts and image segmentation. *Transactions on pattern analysis and machine intelligence*, IEEE, v. 22, n. 8, p. 888–905, 2000. Citado na página 14.
- SIVASWAMY, J. et al. Drishti-gs: Retinal image dataset for optic nerve head (onh) segmentation. In: IEEE. *Biomedical Imaging*. [S.l.], 2014. p. 53–56. Citado na página 13.
- SURULIANDI, A.; MEENA, K.; ROSE, R. R. Local binary pattern and its derivatives for face recognition. *IET computer vision*, IET, v. 6, n. 5, p. 480–488, 2012. Citado na página 20.
- TAN, N.-M. et al. Robust multi-scale superpixel classification for optic cup localization. *Computerized Medical Imaging and Graphics*, Elsevier, v. 40, p. 182–193, 2015. Citado 4 vezes nas páginas 13, 5, 11 e 47.
- THORAT, S. G.; RAUT, S. Glaucoma screening based on super pixel classification. *International Journal of Engineering and Techniques*, v. 1, n. 3, 2015. Citado 4 vezes nas páginas 13, 5, 10 e 11.
- VAN, d. H. et al. Videotrace: rapid interactive scene modelling from video. In: ASSOCIATION FOR COMPUTING MACHINERY. *Transactions on Graphics*. [S.l.], 2007. v. 26, n. 3, p. 86. Nenhuma citação no texto.
- VAPNIK, V. N.; VAPNIK, V. *Statistical learning theory*. [S.l.]: Wiley New York, 1998. v. 1. Citado na página 24.
- ZHAO, G. et al. Rotation-invariant image and video description with local binary pattern features. *Transactions on Image Processing*, IEEE, v. 21, n. 4, p. 1465–1477, 2012. Citado na página 20.

Apêndices

APÊNDICE A – Resultados da Segmentação por Superpixels

A.1 Resultados da Segmentação por Superpixels com 100% dos Atributos Extraídos Método de Fase Única

Mostraremos aqui, resultados com 100% dos atributos extraídos pelos descritores estudados, e dos algoritmos SLIC0 com 1000 *superpixels*. Na Tabela 12 relatamos os valores referentes a Média, Máximo (Máx), Mínimo (Min) e Desvio padrão (σ). Na Tabela 1, apresentamos os resultados do descritor de textura GLCM, destacando em negrito a melhor média de cada métrica avaliada, nos dois classificadores.

Tabela 12 – Resultado da classificação no descritor de textura GLCM nos classificadores MLP e SVM com 100% dos atributos.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,257	0,644	0,026	0,155	0,313	0,759	0,016	0,185
Precisão	0,743	0,978	0,47	0,083	0,674	0,899	0,477	0,096
<i>Recall</i>	0,722	0,938	0,385	0,102	0,711	0,922	0,316	0,101
<i>F-Measure</i>	0,693	0,943	0,403	0,105	0,650	0,91	0,396	0,100
<i>AUC</i>	0,955	0,996	0,628	0,063	0,915	0,990	0,528	0,053

A seguir apresentaremos o resultado da segmentação dos classificadores MLP e SVM. As imagens são representadas por quatro cores: azul que representa o fundo, o vermelho a região de escavação e o verde região do DO, podemos observar duas bordas na cor preta que representam a marcação feita por um especialista delimitando a região pertencente à região de escavação e DO. As Figuras 29 mostra o melhor e pior resultado nos classificadores MLP e SVM.




Figura 29 – Resultado da segmentação nos classificadores MLP e SVM, no descritor de textura GLCM.

Na Tabela 13 o resultado da classificação do descritor de textura LBP, destacando em negrito a melhor média de cada métrica avaliada, nos dois classificadores.

Tabela 13 – Resultado da classificação no descritor de textura LBP nos classificadores MLP e SVM com 100% dos atributos.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,425	0,844	0,266	0,126	0,572	0,942	0,254	0,204
Precisão	0,607	0,895	0,265	0,27	0,368	0,888	0,065	0,232
<i>Recall</i>	0,549	0,862	0,294	0,148	0,572	0,942	0,254	0,204
<i>F-Measure</i>	0,490	0,815	0,167	0,200	0,438	0,915	0,103	0,237
<i>AUC</i>	0,644	0,777	0,571	0,046	0,60	0,59	0,55	0,05

Agora mostraremos o resultado da segmentação do descritor de textura LBP. A Figura 30 apresenta o melhor e pior resultado da segmentação nos classificadores MLP e

SVM.




Figura 30 – Resultado da segmentação nos classificadores MLP e SVM, no descritor de textura LBP.

Mostraremos o resultado da classificação do descritor de textura HOG, na Tabela 14 destacando em negrito a melhor média de cada métrica avaliada, nos dois classificadores.

Tabela 14 – Resultado da classificação do descritor de textura HOG, nos classificadores MLP e SVM com 100% dos atributos.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,252	0,719	0,099	0,101	0,273	0,728	0,094	0,098
Precisão	0,682	0,770	0,532	0,050	0,658	0,859	0,530	0,073
<i>Recall</i>	0,709	0,813	0,403	0,076	0,728	0,869	0,601	0,053
<i>F-Measure</i>	0,660	0,771	0,457	0,068	0,671	0,833	0,566	0,057
<i>AUC</i>	0,875	0,965	0,744	0,060	0,727	0,880	0,500	0,059

Após o resultado da Tabela 3, mostraremos o resultado da segmentação do descritor de textura HOG. A Figura 31 apresenta o melhor e pior resultado dos classificadores MLP e SVM.




Figura 31 – Resultado da segmentação nos classificadores MLP e SVM, no descritor de textura HOG.

Considerando o resultado da classificação do descritor de textura GLRLM, podemos analisar o comportamento de cada classificador na Tabela 15, destacando em negrito a melhor média de cada métrica avaliada, nos dois classificadores.

Tabela 15 – Resultado da classificação no descritor de textura GLRLM, nos classificadores MLP e SVM com 100% dos atributos.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,282	0,719	0,009	0,101	0,275	0,728	0,094	0,098
Precisão	0,682	0,770	0,532	0,050	0,658	0,859	0,530	0,073
<i>Recall</i>	0,739	0,803	0,460	0,076	0,718	0,859	0,603	0,051
<i>F-Measure</i>	0,664	0,770	0,457	0,068	0,631	0,833	0,566	0,057
<i>AUC</i>	0,879	0,975	0,744	0,060	0,738	0,889	0,500	0,059

As Figuras 32 apresenta o resultado da segmentação obtidos nos classificadores MLP E SVM. Sendo o melhor e pior resultado do descritor de textura GLRLM.




Figura 32 – Resultado da segmentação nos classificadores MLP e SVM, no descritor de textura GLRLM.

A.2 Resultados da Segmentação por Superpixels com 100% dos Atributos Extraídos no Método de Fase única com Pré-Processamento nas Imagens

Mostramos também o resultado apenas do descritor de textura GLCM com 100% dos atributos extraídos, fazendo um pré-processamento nas imagens antes de aplicar a geração de *superpixels*. Na Tabela 16 apresentamos os resultados do descritor de textura GLCM, sobre os dois classificadores estudados, destacando em negrito a melhor média de cada métrica avaliada, nos dois classificadores.

Tabela 16 – Resultado da classificação do descritor textura GLCM nos classificadores MLP e SVM com 100% dos atributos com pré-processamento da Imagem.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,47	0,74	0,29	0,08	0,42	0,70	0,33	0,05
Precisão	0,57	0,66	0,51	0,03	0,51	0,61	0,47	0,06
<i>Recall</i>	0,62	0,75	0,46	0,05	0,51	0,72	0,40	0,04
<i>F-Measure</i>	0,56	0,66	0,47	0,04	0,50	0,66	0,42	0,05
<i>AUC</i>	0,67	0,74	0,57	0,03	0,54	0,59	0,50	0,01

A Figura 33 apresenta o melhor e pior resultados da segmentação com um pré-processamento nas imagens nos classificadores MLP e SVM.




Figura 33 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura GLCM com 100% dos atributos com pré-processamento na imagem.

A.3 Resultados da Segmentação por Superpixels com 100% dos Atributos Extraídos no Método de Duas Fases com Adição do Centroide

Mostramos também o resultado do descritor de textura GLCM com 100% dos atributos extraídos com adição da distância do centroide do centro da imagem. Na tabela 17 resultados dos dois classificadores.

Tabela 17 – Resultado da classificação do descritor textura GLCM com adição do centroide nos classificadores MLP e SVM com 100% dos atributos.

Métricas	MLP				SVM			
	Média	Máx	Mín	σ	Média	Máx	Mín	σ
FPR	0,39	0,65	0,09	0,19	0,29	0,76	0,07	0,26
Precisão	0,73	0,88	0,45	0,09	0,62	0,88	0,44	0,10
<i>Recall</i>	0,69	0,78	0,34	0,13	0,70	0,72	0,30	0,11
<i>F-Measure</i>	0,63	0,90	0,39	0,10	0,61	0,89	0,29	0,05
<i>AUC</i>	0,56	0,72	0,60	0,09	0,53	0,51	0,45	0,02

Mostraremos o resultado da segmentação dos classificadores estudados. As Figuras 34 apresentam o melhor e pior resultados da segmentação com adição da distância centroide no centro da imagem, nos classificadores MLP e SVM.




Figura 34 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura GLCM com 100% dos atributos com adição do centroide.

A.4 Resultados da Segmentação por Superpixels com 30% dos Atributos Extraídos no Método Fase Única

Na Tabela 18 o resultado da classificação do descritor de textura GLCM com 30% dos atributos extraídos, destacando em negrito a melhor média de cada métrica avaliada, nos dois classificadores.

Tabela 18 – Resultado da classificação no descritor GLCM, nos classificadores MLP e SVM com 30% dos atributos.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,278	0,480	0,030	0,126	0,355	0,576	0,086	0,156
Precisão	0,706	0,959	0,589	0,054	0,620	0,869	0,519	0,071
<i>Recall</i>	0,629	0,952	0,311	0,136	0,621	0,872	0,403	0,088
<i>F-Measure</i>	0,587	0,953	0,272	0,134	0,554	0,849	0,405	0,089
<i>AUC</i>	0,788	0,987	0,609	0,074	0,632	0,893	0,529	0,082

Nas Figuras 35 apresenta o melhor e pior resultado sobre os classificadores avaliados.

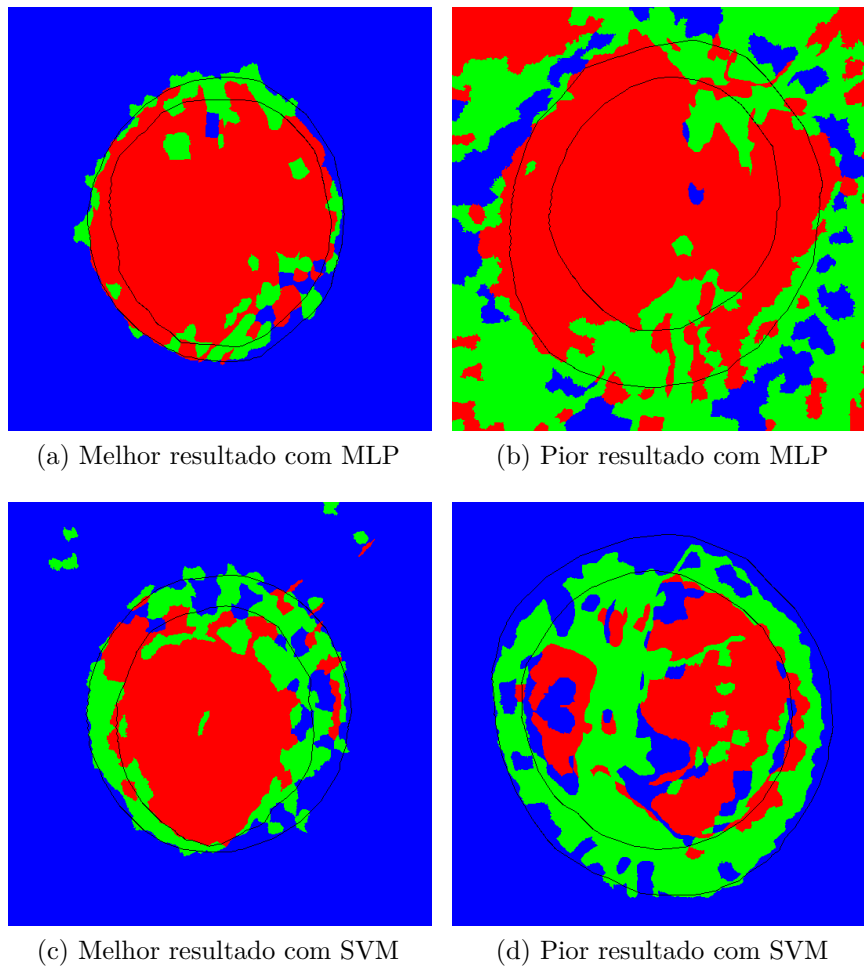


Figura 35 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura GLCM com 30% dos atributos.

Considerando o resultado da classificação do descritor de textura LBP, podemos analisar o comportamento de cada classificador na Tabela 19, destacando em negrito a melhor média de cada métrica avaliada, nos dois classificadores.

Tabela 19 – Resultado da classificação do descritor de textura LBP, nos classificadores MLP e SVM com 30% dos atributos.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,257	0,644	0,026	0,155	0,313	0,759	0,016	0,185
Precisão	0,743	0,978	0,47	0,083	0,674	0,899	0,477	0,096
Recall	0,722	0,938	0,385	0,102	0,711	0,922	0,316	0,101
<i>F-Measure</i>	0,683	0,943	0,403	0,105	0,690	0,91	0,396	0,100
<i>AUC</i>	0,955	0,996	0,628	0,063	0,915	0,990	0,528	0,053

Agora mostraremos o resultado da segmentação do descritor de textura LBP com 30% dos atributos extraídos. A Figura 36 mediante dos dois classificadores avaliados.




Figura 36 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura LBP com 30% dos atributos.

Na Tabela 20 o resultado da classificação do descritor de textura GLCM com 30% dos atributos extraídos.

Tabela 20 – Resultado da classificação do descritor de textura HOG nos classificadores MLP e SVM com 30% dos atributos.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,357	0,624	0,023	0,154	0,247	0,719	0,015	0,175
Precisão	0,733	0,958	0,57	0,080	0,644	0,879	0,467	0,091
<i>Recall</i>	0,732	0,948	0,395	0,109	0,721	0,912	0,310	0,104
<i>F-Measure</i>	0,683	0,913	0,413	0,106	0,690	0,97	0,399	0,109
<i>AUC</i>	0,975	0,970	0,628	0,063	0,945	0,969	0,518	0,052

O resultado da segmentação do descritor de textura HOG com 30% dos atributos extraídos. A Figura 37 apresenta o resultado da segmentação no descritor de textura

alcançados nos classificadores MLP e SVM.




Figura 37 – Resultado da segmentação nos classificadores MLP e SVM, no descritor de textura HOG com 30% dos atributos.

Na Tabela 21 o resultado da classificação do descritor de textura GLRLM com 30% dos atributos extraídos, destacando em negrito a melhor média de cada métrica avaliada, nos dois classificadores.

Tabela 21 – Resultado da classificação do descritor textura GLRLM nos classificadores MLP e SVM com 30% dos atributos.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,32	0,69	0,05	0,20	0,33	0,79	0,02	0,19
Precisão	0,77	0,98	0,47	0,10	0,64	0,90	0,477	0,096
<i>Recall</i>	0,73	0,94	0,39	0,13	0,71	0,92	0,32	0,11
<i>F-Measure</i>	0,63	0,95	0,40	0,10	0,65	0,91	0,39	0,10
<i>AUC</i>	0,96	0,99	0,63	0,06	0,91	0,99	0,53	0,05

Agora mostraremos o resultado da segmentação do descritor de textura GLRLM com 30% dos atributos extraídos. A Figura 38 apresenta o melhor e pior resultados dos classificadores MLP e SVM.




Figura 38 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura GLRLM com 30% dos atributos.

A.5 Resultados da Segmentação por Superpixels com 30% dos Atributos Extraídos no Método Fase Única com Pré-Processamento nas Imagens

Na Tabela 22 o resultado da classificação do descritor de textura GLCM com 30% dos atributos extraídos, destacando em **negrito** a melhor média de cada métrica avaliada, nos dois classificadores.

Tabela 22 – Resultado da classificação no descritor GLCM, nos classificadores MLP e SVM com 30% dos atributos.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,395	0,470	0,039	0,129	0,305	0,574	0,081	0,150
Precisão	0,716	0,919	0,534	0,051	0,679	0,833	0,529	0,069
Recall	0,649	0,973	0,321	0,133	0,631	0,862	0,443	0,083
<i>F-Measure</i>	0,587	0,953	0,272	0,134	0,554	0,835	0,425	0,087
<i>AUC</i>	0,792	0,990	0,620	0,072	0,652	0,887	0,529	0,082

Na Figura 39 apresenta o resultado de segmentação dos dois classificadores avaliados.

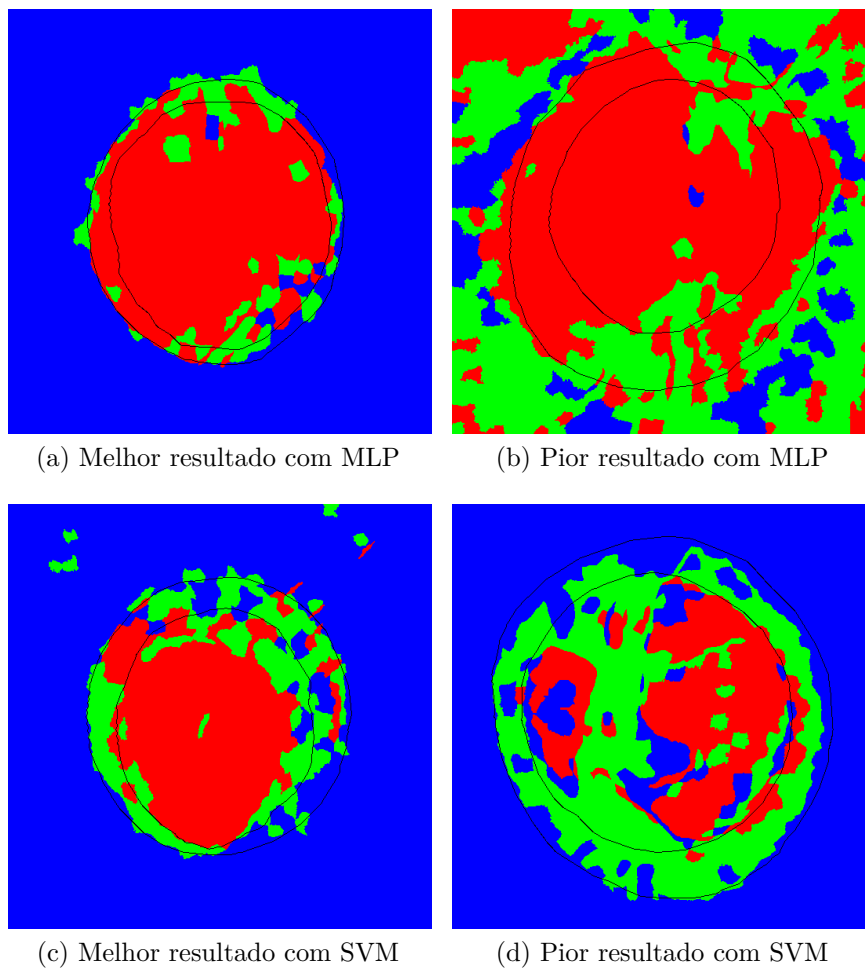


Figura 39 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura GLCM com 30% dos atributos.

A.6 Resultados da Segmentação por Superpixels com 30% dos Atributos Extraídos no Método de Duas Fases com Adição do Centroide

Mostramos também o resultado do descritor de textura GLCM com 30% dos atributos extraídos com adição de centroide. Na tabela 23 resultados dos dois classificadores.

Tabela 23 – Resultado da classificação do descritor textura GLCM com adição do centroide nos classificadores MLP e SVM com 30% dos atributos.

Métricas	MLP				SVM			
	Média	Máx	Min	σ	Média	Máx	Mín	σ
FPR	0,49	0,55	0,07	0,20	0,35	0,79	0,10	0,31
Precisão	0,70	0,82	0,35	0,05	0,65	0,78	0,32	0,04
<i>Recall</i>	0,74	0,68	0,32	0,12	0,70	0,63	0,29	0,10
<i>F-Measure</i>	0,59	0,89	0,30	0,04	0,62	0,79	0,25	0,03
<i>AUC</i>	0,79	0,69	0,65	0,02	0,69	0,53	0,55	0,01

Mostraremos o resultado da segmentação dos classificadores estudados. A Figura 40 apresenta o melhor e pior resultados da segmentação com um pré-processamento nas imagens, nos dois classificadores.




Figura 40 – Resultado da segmentação nos classificadores MLP e SVM no descritor de textura GLCM com 30% dos atributos com adição do centroide.