



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA BIOMÉDICA



Trabalho de Conclusão de Curso

TÉCNICAS DE LIMIAÇÃO EM IMAGENS DE RETINOGRAFIA

Júlio César da Costa Moura

Natal/RN

2018

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

**TÉCNICAS DE LIMIARIZAÇÃO EM IMAGENS DE
RETINOGRAFIA**

Trabalho de conclusão de curso apresentado
ao Departamento de Engenharia Biomédica
da Universidade Federal do Rio Grande do
Norte para obtenção do título de Graduado
em Engenharia Biomédica.

Graduando: Júlio César da Costa Moura

Orientador: Prof. Dr. Ricardo Alessandro
de Medeiros Valentim

Natal/RN
2018

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

**TÉCNICAS DE LIMIAZIZAÇÃO EM IMAGENS DE
RETINOGRRAFIA**

Banca Examinadora do Trabalho de Conclusão de Curso:

Prof. Dr. Ricardo Alexsandro de Medeiros _____
Valentim

UFRN - Orientador

Prof. Daniele Montenegro da Silva Barros _____

UFRN – Avaliadora Interno

Prof. Dr. Giovani Ângelo Silva da _____
Nóbrega

LAIS – Avaliador Externo

Natal/RN

2018

DEDICATÓRIA

Este Trabalho de Conclusão de Curso é dedicado a Salomão Pedro da Costa meu avô materno e pai de coração, que mesmo tendo falecido há 10 anos permanece vivo na minha memória. E são nessas memórias que eu busco conselhos e ensinamentos para continuar seguindo.

De onde você estiver, se você estiver, receba esse trabalho como um presente que eu não tive tempo de lhe dar.

AGRADECIMENTOS

Agradeço a minha avó e ao meu pai, por todo o amor e carinho durante toda a minha vida. Obrigado pela dedicação em tudo que eu pedi e por me darem o máximo que podiam. Estendo esse agradecimento a toda minha família, principalmente minha mãe, tios e tias.

Ao meu orientador Prof. Dr. Ricardo Alessandro de Medeiros e Prof. Msc. Daniele Montenegro da Silva Barros pela orientação dada neste trabalho.

Ao Dr. Giovani Ângelo Silva da Nóbrega, por aceitar o convite para participar da banca avaliadora e por tudo que me ensinou nesse período.

Aos meus colegas do laboratório de Informática em Saúde do Laboratório de Inovação Tecnológica em Saúde, pelo convívio diário.

Aos meus confrades, Amarildo, Luiz Otávio e Vinicius por todo o apoio e parceria durante esse tempo.

SUMÁRIO

DEDICATÓRIA	4
AGRADECIMENTO.....	5
SUMÁRIO.....	6
LISTA DE FIGURAS.....	8
LISTA DE EQUAÇÕES.....	10
LISTA DE TABELAS.....	11
LISTA DE ABREVIACÕES.....	12
RESUMO.....	14
ABSTRACT.....	15
1. INTRODUÇÃO.....	16
1.1 LIMARIZAÇÃO GLOBAL.....	16
1.2 LIMARIZAÇÃO ADAPATATIVA.....	17
2. OBJETIVOS.....	18
2.1 GERAL.....	18
2.2 ESPECÍFICOS.....	18
3. REVISÃO BIBLIOGRÁFICA.....	19
3,1 O OLHO HUMANO.....	19
3.2 O RETINOGRAFO E A RETINOGRAFIA.....	21
3.3 PRINCÍPAIS DOENÇAS DIAGNÓSTICADAS.....	22
3.3.1 GLAUCOMA.....	22
3.3.2 RETINOPATIA DIABÉTICA.....	22
3.4 ESTADO DA ARTE.....	23
4. METODOLOGIA.....	38
4.1 LIMARIZAÇÃO DE OTSU.....	38
4.2 LIMARIZAÇÃO ISODATA.....	40
4.2.1 ALGORITMO 1 – ISODATA BÁSICO.....	40
4.2.2 ALGORITMO 2 – ISODATA DE UMA DIMENSÃO.....	41
4.3 LIMARIZAÇÃO MINIMA.....	41
4.4 LIMARIZAÇÃO MÉDIA.....	41
4.5 LIMARIZAÇÃO TRIANGLE.....	42
4.6 LIMARIZAÇÃO MEDIANA.....	42
4.7 LIMARIZAÇÃO GLOBAL SIMPLES.....	43

4.8 LIMIA R I Z A Ç Ã O A D A P T A T I V A.....	43
4.8.1 LIMIA R I Z A Ç Ã O A D A P T A T I V A M É D I A.....	43
4.8.2 LIMIA R I Z A Ç Ã O A D A P T A T I V A G A U S S I A N A.....	43
4.9 B A N C O D E D A D O S.....	43
4.10 M É T R I C A S D E A V A L I A Ç Ã O.....	44
4.10.1 E R R O Q U A D R Á T I C O M É D I O (M S E).....	45
4.10.2 Í N D I C E D E M E D I D A D E S I M I L A R I D A D E E S T R U T U R A L (S S I M).....	46
4.10.3 – A C U R Á C I A.....	47
5. R E S U L T A D O S E D I S C U S S Õ E S.....	48
6. C O N C L U S Õ E S.....	60
7. R E F E R Ê N C I A S.....	61

LISTA DE FIGURAS:

Figura 1: Principais estruturas identificadas na retinografia.....	20
Figura 2: Primeira imagem do banco de dados DRIVE.....	44
Figura 3 – Histograma da escala de cinza da primeira imagem do banco de dados DRIVE.....	48
Figura 4: Histograma do canal verde da primeira imagem do banco de dados DRIVE.....	48
Figura 5: Limiarização adaptativa gaussiana na escala de cinza da primeira imagem do banco de dados DRIVE.....	49
Figura. 6: Limiarização adaptativa média na escala de cinza da primeira imagem do banco de dados DRIVE.....	49
Figura 7: Limiarização adaptativa gaussiana no canal verde da primeira imagem do banco de dados DRIVE.....	50
Figura 8: Limiarização adaptativa média no canal verde da primeira imagem do banco de dados DRIVE.....	50
Figura 9: Limiarização global na escala de cinza da décima nona imagem do banco de dados DRIVE.....	51
Figura 10: Limiarização global no canal verde da quinta imagem do banco de dados DRIVE.....	52
Figura 11: Limiarização Isodata na escala de cinza da sexta imagem do banco de dados DRIVE.....	53
Figura 12: Limiarização Isodata no canal verde da sexta imagem do banco de dados DRIVE.....	53
Figura 13: Limiarização média na escala de cinza da terceira imagem do banco de dados DRIVE.....	54
Figura 14: Limiarização média no canal verde da terceira imagem do banco de dados DRIVE.....	54
Figura 15: Limiarização mediana na escala de cinza da primeira imagem do banco de dados DRIVE.....	55
Figura 16: Limiarização mediana no canal verde da primeira imagem do banco de dados DRIVE.....	56
Figura 17: Limiarização Otsu na escala de cinza da sexta nona imagem do banco de dados DRIVE.....	57

Figura 18: Limiarização de Otsu no canal verde da sexta imagem do banco de dados

DRIVE.....58

LISTA DE EQUAÇÕES

Equação 1 – Escolha do novo valor de limiar.....	16
Equação 2 – Método de Otsu.....	39
Equação 3 – Método Isodata de uma dimensão.....	41
Equação 4 – Método da média.....	41
Equação 5 – Função Gaussiana.....	43
Equação 6 – MSE.....	45
Equação 7 – PSNR.....	45
Equação 8 – SSIM.....	46
Equação 9 – Acurácia.....	47

LISTA DE TABELAS

Tabela 01: Valores Médios de Acurácia para a Limiarização adaptativa.....	51
Tabela 02: Valores médios de MSE e SSIM para as diferentes técnicas de Limiarização.....	58

LISTA DE ABREVIACÕES, SIGLAS E SÍMBOLOS.

Acc – *Acurácia*
ANN - *Artificial Neural Network*
ASM - *Active Shape Model*
AUC - *Area Under the Curve*
CNN - *Convolutional Neural Network*
CDR - *Cup-to-disc ratio*
DO - *Disco Óptico*
ELM - *Extreme Learning Machine*
GLCM - *Gray-Level Co-occurrence Matrix*
GCN - *Global Contrast Normalization*
GMM - *Gaussian Mixture Model*
HE – *Hemorrhages*
ITA – *Inferior Temporal Arcade*
kNN - *k-Nearest Neighbor*
MA - *Microaneurysm*
MRF - *Markov Random Filter*
MSE – *Mean Squared Error*
MSLD - *Multi-Scale Line Detection*
MTA – *Major Temporal Arcade*
MTVF - *Multi-Scale Tensor Voting Framework*
NPDR – *Nonproliferative Diabetic Retinopathy*
NPV - *Non-Predictive Value*
PCA - *Principal Component Analysis*
PDR – *Proliferative Diabetic Retinopathy*
PPV – *Positive Predictive Value*
PSNR – *Peak signal-to-noise ratio*
RD - *Retinopatia Diabética*
RDR - *Rim-to-Disc Ratio*
ROC - *Retinopathy Online Challenge*
Se - *Sensitividade*
SLIC - *Simple Linear Iterative Clustering*

SMOTE - *Synthetic Minority Oversampling Technique*

Spe – *Especificidade*

SSIM – *Structural Similarity Index Measure*

STA – *Superior Temporal Arcade*

SURF - *Speed and Robust Features*

SVD - *Singular Value Decomposition*

SVM - *Support Vector Machine*

TNR - *True Negative Rate*

TPR - *True Positive Rate*

UTHSC - *University of Tennessee Health Science Center*

ZCA - *Zero-phase component Analysis*

MOURA, Júlio César da. **TÉCNICAS DE LIMIAZIZAÇÃO EM IMAGENS DE RETINOGRAFIA**. Trabalho de Conclusão de Curso, Graduação em Engenharia Biomédica, Universidade Federal do Rio Grande do Norte, 65 p., 2018

RESUMO

Retinografia é uma modalidade de imagem médica bem estabelecida no diagnóstico de doenças como glaucoma e retinopatia diabética. Limiarização é uma das formas mais simples de segmentação de imagens e é usada no processo de binarização. Neste contexto o trabalho em evidência testa as técnicas de Limiarização: Otsu, Isodata, Mínima, Média, Triangle, Mediana, Global Simples, Adaptativa Média e Adaptativa Gaussiana, usando a linguagem *Python* para avaliar qual delas apresenta os melhores resultados e serem usados como técnica de pré-processamento. Os métodos foram testados no banco de dados *Digital Retinal Imaging for Vessel Extraction* e a avaliação dos resultados foi feito com *Mean Squared Error*, *Structural Similarity Index Measure* e acurácia. A partir dos resultados concluiu-se que a Limiarização adaptativa, global simples e mediana podem ser usadas como pré-processamento para identificar respectivamente: vasos sanguíneos, disco óptico e mácula.

Palavras-Chave: Retinografia. Limiarização global. Limiarização adaptativa. DRIVE.

MOURA, Júlio César da. **Thresholding Techniques in Fundus Imaging.** Conclusion Work Project, Biomedical Engineering Bachelor Degree, Federal University of Rio Grande do Norte, 65 p., 2018

ABSTRACT

Fundus Imaging is a well established modality to diagnose disease such as Glaucoma and Diabetic Retinopathy. Threshold is a one of the simplest method in imaging segmentation and is used to binarize the images. In this context, the current work try the following thresholding techniques: Otsu, Isodata, Minimum, Mean, Triangle, Median, Global Simple, Mean Adaptive and Gaussian Adaptive using Python to evaluate which of them show the best results to be used as a preprocessing technique. The methods were tested on the *Digital Retinal Imaging for Vessel Extraction* database and the results evaluation were performed with *Mean Squared Error*, *Structural Similarity Index Measure* and *Accuracy*. From the results, the Adaptive, Global Simple and Median thresholding may be used as a preprocessing technique to identify, respectively: blood vessels, optic disc and macula.

Keywords: Fundus Imaging. Global thresholding. Adaptive Thresholding.
DRIVE

1. INTRODUÇÃO

Limiarização é o método mais simples de segmentação de imagens e pode ser usado no processo de binarização (SHAPIRO & STOCKMAN 2000). Consiste na escolha de um ponto T , que é usado como limiar de modo que para dada imagem $I \geq T$, a nova imagem recebe valores branco, caso contrário recebe valores preto, ou vice e versa.

Quando a constante T é aplicável a uma imagem inteira, o processo dado nesta equação é conhecido como limiarização global. Quando o valor de T muda ao longo da imagem, usamos o termo limiarização variável, ou adaptativa.

A eficácia da limiarização está diretamente relacionada com a largura e profundidade do(s) vale(s) que separa(m) os modos do histograma. Na maioria dos casos, os principais fatores que afetam as propriedades do(s) vale(s) são:

- (1) A separação entre picos (quanto mais distantes forem os picos entre si, melhores as possibilidades de separação dos modos);
- (2) O índice de ruído da imagem (os modos ampliam com o aumento do ruído);
- (3) O tamanho relativo dos objetos e do fundo;
A uniformidade da fonte de iluminação; e
- (4) A uniformidade das propriedades de reflexão da imagem.

1.1 LIMIARIZAÇÃO GLOBAL

Um algoritmo usado normalmente para a Limiarização é o seguinte:

- (1) Selecionar uma estimativa inicial para o limiar global, T ;
- (2) Atribuir valores de 0 ou 255 para os pixels G_1 com valores de intensidade $> T$, e G_2 , composto de pixels com valores $\leq T$.
- (3) Calcular um novo valor de limiar:

$$T = \frac{1}{2}(m_1 + m_2) \quad (1)$$
- (4) Repetir as etapas 2 a 4 até que a diferença entre os valores de T em iterações sucessivas seja menor que o parâmetro predefinido ΔT .

1.2 LIMIAÇÃO ADAPTATIVA

Na seção 1 foi discutido que fatores como o ruído e a iluminação não uniforme possuem um papel importante no desempenho de um algoritmo de limiarização. É possível atenuar esses efeitos usando técnicas de suavização de bordas. No entanto, é frequente o caso em que este tipo de pré-processamento é impraticável ou simplesmente ineficiente em prover uma melhora da situação para fazer com que o problema possa ser resolvido. Nessas situações pode ser útil utilizar a Limiarização adaptativa

Uma das metodologias mais simples para a limiarização adaptativa é subdividir uma imagem em retângulos que se sobrepõem. Essa abordagem é utilizada para compensar a não uniformidade de iluminação e/ou a refletância. Os retângulos escolhidos são suficientemente pequenos para que a iluminação de cada um seja o mais uniforme possível. (GONZALES & WOODS 2010)

2. OBJETIVOS:

2.1 GERAIS

Testar diferentes técnicas de limiarização no canal verde e na escala de cinza das imagens de retinografia fornecidas pelo banco de dados *Digital Retinal Images for Vessel Extraction – DRIVE*. Em seguida avaliar os resultados obtidos com MSE e SSIM e acurácia, para verificar quais delas podem ser usadas como técnicas de pré-processamento na identificação de estruturas oculares e métodos de identificação de doenças.

2.2 ESPECÍFICOS

- Testar a limiarização de Otsu no canal verde da imagem;
- Testar a limiarização de Otsu na imagem em escala de cinza;
- Testar a limiarização Isodata no canal verde da imagem;
- Testar a limiarização Isodata na imagem em escala de cinza;
- Testar a limiarização Mínima no canal verde da imagem;
- Testar a limiarização Mínima na imagem em escala de cinza;
- Testar a limiarização Média no canal verde da imagem;
- Testar a limiarização Média na imagem em escala de cinza;
- Testar a limiarização Mediana no canal verde da imagem;
- Testar a limiarização Mediana na imagem em escala de cinza;
- Testar a limiarização Global Simples no canal verde da imagem;
- Testar a limiarização Global Simples na imagem em escala de cinza;
- Testar a limiarização Adaptativa Media no canal verde da imagem;
- Testar a limiarização Adaptativa Media na imagem em escala de cinza;
- Testar a limiarização Adaptativa Gaussiana no canal verde da imagem;
- Testar a limiarização Adaptativa Gaussiana na imagem em escala de cinza.

3. REVISÃO BIBLIOGRÁFICA

3.1 O OLHO HUMANO

O olho pode ser considerado uma esfera e tem um diâmetro médio de aproximadamente 20 mm. É revestido por 3 membranas: córnea e a cobertura externa da esclera; a coroide e a retina. A córnea é um tecido transparente e resistente que cobre a superfície anterior do olho e é seguida pela esclera, que reveste o restante do globo ocular.

A coroide fica situada diretamente abaixo da esclera. É uma membrana que contém uma rede de vasos sanguíneos e servem de principal fonte de nutrição para o olho. Ela se divide em corpo ciliar e íris. A íris exerce movimentos de contração expansão para controlar a quantidade de luz que entra no olho. A pupila, uma abertura central no centro da íris, varia em diâmetro em diâmetro de 2 a 8 mm (GONZALES & WOODS 2010)

O Cristalino é composto de camadas concêntricas de células fribosas e é suspenso por fibras que se ligam ao corpo ciliar. Contém entre 60 a 70% de água e cerca de 6% de gordura. Também tem mais proteína do que qualquer outro tecido do olho. Ele absorve aproximadamente 8% do espectro de luz visível, com absorção relativamente maior nos comprimentos de onda mais curtos.

A retina é a membrana mais interna do olho e se estende por toda a porção posterior da parede. A visão de padrões é obtida pela distribuição de receptores discretos de luz ao longo da superfície dessa estrutura. As duas classes de receptores são cones e bastonetes. No olho há cerca de 6 a 7 milhões de cones. Eles se localizam na região central, a fóvea, e são sensíveis à cor e é graças a ele que se pode distinguir pequenos detalhes. O número de bastonetes é muito maior, variando entre 75 e 150 milhões. Eles servem para dar uma imagem geral do campo de visão e são sensíveis a baixos níveis de iluminação. A retina é a estrutura mais importante da camada nervosa ocular e é responsável por receber a informação visual dos sinais neurais e transmiti-lo ao cérebro (OLOUMI ET AL. 2014). A transferência de sinal ao cérebro é realizada pelo disco óptico. Na retina ele aparece como um círculo brilhante e em adultos tem cerca de 1,6 mm (LALONDE ET AL. 2001). A região da mácula é cerca de duas vezes maior que o disco óptico e é situado temporal ao centro

dele. No centro da mácula há uma região avascular chamada de fóvea. Os vasos sanguíneos na retina de um adulto variam em espessura entre 50 μm e 200 μm (média 60 μm). Em imagens bi dimensionais, a espessura do vaso é definida como comprimento de ponta a ponta da imagem projetada do vaso. A maior ramificação venular é mais espessa do a ramificação de arteríola correspondente, tem um elevado contraste com o segundo plano e é chamada de maior arteríola temporal.

A Segmentação manual das estruturas de retina demanda tempo pois requer treinamento de um especialista. É aceitável entre a área médica que a quantificação automática dessas estruturas é um passo importante no desenvolvimento de um sistema de diagnóstico para doenças oftalmológicas e podem reduzir o tempo de trabalho do médico. Nos últimos anos a grande número de algoritmos têm sido desenvolvidos relacionados a segmentação dessas estruturas. O estado da arte é citado na seção 3.4.

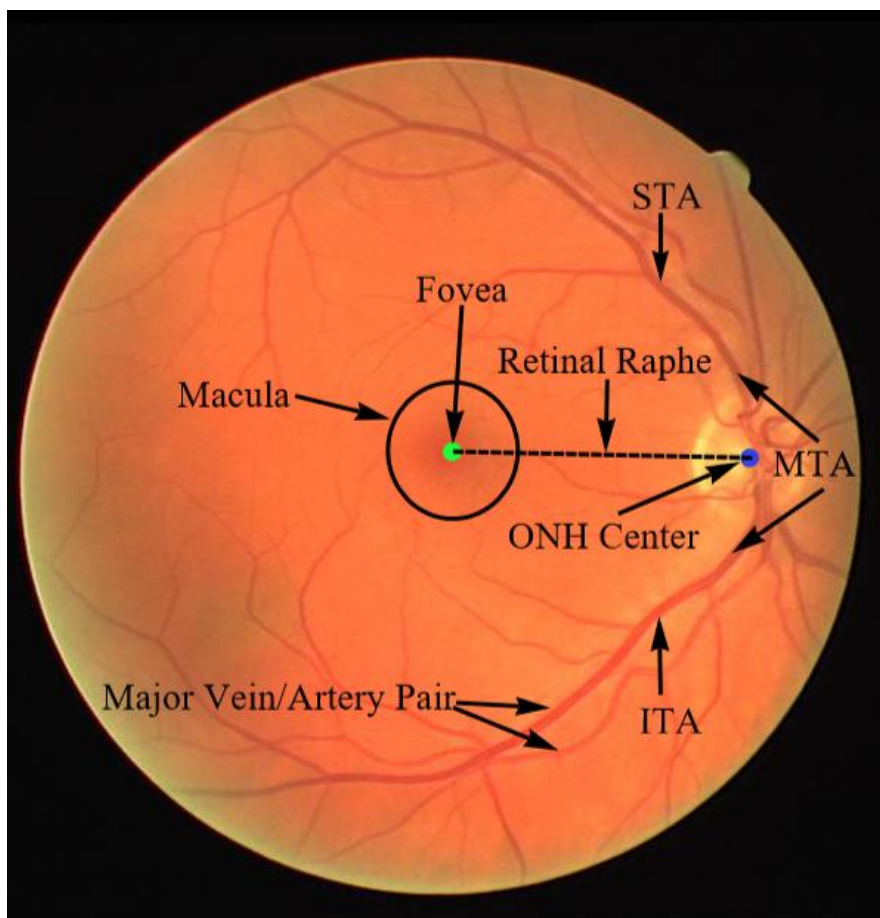


Figura 1 – Principais estruturas identificadas na retinografia. Disponível Em (Oloumi et al. 2014)

3.2 – O RETINOGRÁFO E A RETINOGRAFIA

Retinografia é um método introduzido na década de 1920 e desde os anos 1960 tem sido bem estabelecido para auxiliar o oftalmologista no diagnóstico de patologias durante atividades clínicas. Apesar de precisar de um sistema óptico complexo, a câmara do fundo do olho, ela necessita um microscópio de baixa potência, capaz de fazer a imagem da retina, disco óptico, mácula e polo posterior (OWEN & BARMAN 2012).

Primeiro o padrão fotográfico foi baseado em filmes de 35 mm e depois em fotografia digital. Técnicas adicionais como fotografia estérea e RNFL levaram a uma melhora substancial da fotografia de fundo de olho. Em analogia com o oftalmoscópio indireto, as lentes objetivas formam a imagem intermediária real do fundo do olho iluminado em frente a um pequeno espelho. Por trás desse pequeno espelho, uma segunda imagem intermediária é formada pelas lentes objetivas principais. Com lentes focais móveis, os raios são paralelizados permitindo o uso de câmeras de alta resolução. A resolução máxima dessas câmeras é de cerca de 6 μm , mas só pode ser obtida para pequenos campos de visão e se a pupila for dilatada. Para capturar imagens com elevado campo de visão, uma pequena abertura é necessária, de forma que normalmente reduz a resolução (para aproximadamente 10 μm em um campo de visão de 50°). Normalmente o campo de visão máximo para a câmera é 50°. Somente câmeras midriáticas especiais (para exames com dilatação da pupila), um campo maior que 60° pode ser feito. O campo varia normalmente entre 20° a 50°. Áreas periféricas da retina que ficam de fora do campo central podem ser registradas quando o paciente olha em direções diferentes, mudando a linha de visão. Imagens com grande campo de visão proporcionam imagens com resolução baixa e a incapacidade de detectar estruturas microscópicas, como vasos muito pequenos, cones e etc. Também não é fornecida informação para camadas de retina profundas.

O custo do exame permanece relativamente baixo do que novas técnicas baseadas na digitalização da retina. As principais vantagens são fácil interpretação, coloração total e melhor detecção de hemorragias de disco. As desvantagens incluem a necessidade de elevada qualidade de fotografia e

dificuldade na comparação em série devido a habilidade clínica para detectar mudanças sutis com a fotografia (Gramatikov 2014).

3.3 – PRINCIPAIS DOENÇAS DIAGNOSTICADAS

3.3.1 GLAUCOMA

Em 2010 havia cerca de 60 milhões de pessoas com Glaucoma em todo o mundo (QUIGLEY 2006). Sendo a doença líder nas causas de cegueira irreversível (THAM ET AL. 2014).

É uma doença neurodegenerativa caracterizada pela degeneração de todo o caminho visual (GUPTA ET AL. 2006). Nesta doença os canais de drenagem são bloqueados aumentando a pressão intraocular (YADAV ET AL. 2014). Assim a borda da neuroretina do nervo óptico torna-se progressivamente fina, aumentando a cavidade do nervo óptico (KWON ET AL. 2009). Os sintomas gerais da doença são visão nebulosa, náuseas e dores de cabeça e olho.

Glaucoma Primário de Ângulo aberto é a forma mais comum de Glaucoma, representando cerca de 90% de todos os casos de glaucoma, e é caracterizado pelo aumento da pressão intraocular de forma que fica estatisticamente maior que a faixa normal durante a progressão do glaucomatoso.

3.3.2 RETINOPATIA DIABÉTICA

A Retinopatia Diabética tem sido a causa líder de cegueira preventiva entre pessoas economicamente ativas nos países desenvolvidos (PATTON ET AL. 2006). É comumente dividida em duas categorias: Retinopatia Diabética não proliferativa (NPDR) e Retinopatia Diabética Proliferativa (PDR).

NPDR pode ser caracterizado em termos de vários tipos de lesões, como micro aneurismas, *cotton-wool spots*, hemorragias, drusas e exsudados. Pode ser diagnosticado pela presença de edema macular e pelas bordas viradas de veias (NOBLE & CHAUDHARY 2010; JELINEK & CREE 2010). A presença dessas características tem se mostrado correlatas com a severidade e progressão da NPDR (KLEIN ET AL. 2015).

Um dos sinais da presença de PDR é caracterizada por mudanças na arquitetura da Arcada Temporal Principal devido a proliferação de tecido fibrovascular na superfície da retina. A concentração da superfície retina, assim como a proliferação fibrovascular do tecido patológico próximo ao nervo óptico, faz com que a Arcada Temporal Principal seja puxada para a periferia da retina, resultando no distanciamento tradicional da retina e subsequente perda da visão. (MEIER & LEIPZIG 1997)

3.4 – ESTADO DA ARTE

(SALAZAR-GONZALEZ et al. 2014) extraiu a árvore vascular da retina usando a técnica de recorte de grafos. Esse tipo de informação é usada para estimar a localização do disco óptico. Essa tarefa foi feita usando *Markov Random Filter* (MRF). O filtro foi escolhido devido a robustez, embora demande elevado poder computacional. A imagem de entrada foi pré-processada usando melhoramento de contraste no canal verde da imagem e depois usando um equalizador de histograma adaptativo. Seguindo a equalização de imagem a técnica de corte de grafos foi usada para detectar o disco óptico e então o MRF foi aplicado para segmentar o DO, removendo vasos nessa região. Um método de fator de compensação foi usado para segmentar o DO usando conhecimento prévio da intensidade local dos vasos. O método foi testado em 3 bancos de dados diferentes. DRIVE e STARE para segmentação de vasos e DRIVE e DIARETDB1 para o disco óptico. No banco de dados DRIVE a acurácia alcançada foi 0.9412 para o DO No DIARETDB1 a acurácia para os indivíduos saudáveis for 0.9515 e 0.9369 para imagens com patologia.

Em (CARLA ET AL. 2015) detectou a vasculatura anormal no disco óptico usando decomposição multiescalar. A correção de iluminação não uniforme foi realizada usando correção de sombra, com o intuito de minimizar os efeitos no método de aprimoramento. A técnica de amplitude de modulação da frequência foi aplicada para decompor as imagens em termos de uma soma única de componentes de amplitudes e frequências. Os tamanhos da distribuição dos vasos segmentados foram descritos usando abertura de granulometria morfológica com o mesmo raio e a forma do elemento estruturante foi aplicadas nos negativos do canal verde para remover objetos com elevados valores de intensidade de acordo com o tamanho do elemento

estruturante. Por último as dimensões fractais foram computadas para medir a mudança vascular associada com a decomposição granulométrica multiescalar. Nesse sistema, o melhor parâmetro de performance alcançado foi usando SVM linear. A AUC foi 0.9335. As imagens usadas no estudo foram obtidas no *Retinal Institute of the South Texas (RITH)* e *University of Texas Health Science Data Center em Santo Antônio (UTHSC-SA)*.

Em (CHRISTODOULIDIS ET AL. 2016) propôs um método para segmentar pequenos vasos da retina e diagnosticar retinopatia diabética. A metodologia foi baseada na estrutura de votação de tensores multiescalar (MTVF) combinado com detecção multiescalar (MSLD) para reduzir as limitações na detecção de linhas durante manuseio dos pequenos vasos. Primeiro as imagens foram pré-processadas para corrigir iluminação não uniforme, para normalizar o contraste da imagem e reduzir o ruído do fundo. Então os vasos foram segmentados pela aplicação do MSLD. A limiarização adaptativa foi aplicada para extrair os vasos de tamanho grande e médio. Em seguida MTVF foi usado na imagem segmentada para identificar e reconectar os menores vasos. O passo seguinte, iniciando dos maiores vasos, o procedimento de acompanhamento local juntou as informações das escalas diferentes. Em paralelo os menores vasos foram reconstruídos em toda a sua extensão. Por último as imagens foram pós-processados usando remoção morfológica dos artefatos de segundo plano para suprimir o ruído presente nessas regiões. O modelo foi testado no banco de dados HRF e para vasos atingiu sensibilidade de 68%, especificidade de 96.54% e acurácia de 95.5%.

Em (ZHANG ET AL. 2015) propôs um método para segmentação de vasos da retina usando um modelo multiescalar derivado de pontos chaves. As características dos vasos foram extraídas usando filtro de Garbor. A seleção de parâmetro foi baseada nas propriedades morfológicas dos vasos e usa um parâmetro λ para controlar o desempenho. Em seguida, foi adotada uma abordagem multiescalar inspirada em SIFT para identificar pontos chaves. As respostas de filtro derivadas desses pontos chave inicializaram um algoritmo de agrupamento que determina os textos. O banco do filtro usa filtro de Garbor multi escalar caracterizado por um parâmetro livre que determina a escala dele. O sistema foi testado usando uma rede neural para rotular pixels como vasos e não-vasos. O banco de dados DRIVE foi escolhido para validar o modelo e

alcançou valores médios de sensibilidade, especificidade e acurácia de 78.12%, 96.68% e 95.05% respectivamente.

EM (MOGHIMIRAD ET AL. 2012) usou uma técnica multiescalar para segmentar os vasos da retina. Primeiro foi introduzida uma função média para 20 espaços e foram “pesadas” com uma função para reduzir o efeito de estruturas assimétricas. Em seguida, para melhorar esses valores para estruturaras em forma de vaso, a imagem resultante foi multiplicada por valores suavizados dos autovalores da matriz Hessiana em cada pixel da imagem. Depois, para eliminar o ruído originado do segundo plano da imagem, foi aplicada uma redução de ruído usando uma formula baseada na área e alongamento. Um passo de reconstrução foi aplicado para conectar vasos truncados baseados nas características estruturais dos vasos. Por último, os limites exatos dos vasos foram estimados usando autovalores e os resultados dos filtros médio. O sistema foi testado nos bancos de dados DRIVE e STARE para 8 escalas. A acurácia obtida para imagem 19 do DRIVE foi 97.60%. Para a sexta imagem do mesmo banco de dados a acurácia foi 95.85%.

Em (SRIVASTAVA ET AL. 2016) propôs um método para detectar micro aneurismas e hemorragias nas retinas e auxiliar no diagnóstico de retinopatia diabética, combinando modelos multiescalares, abordagem de núcleos múltiplos e Máquina do Vetor Suporte. Primeiro foi aplicado filtro Frangi para melhorar lesões ao contrário de vasos, o parâmetro diferente foi chamado de “*lesioness*”. Ambos “*vesselness*” e “*lesioness*” foram aplicados em diferentes fragmentos. O valor máximo para esse filtro de resposta foi usado como um vetor de característica com tamanho de rede “*m*”, com *m* variando 1, 2, 4, 8, 16 e 32. A aprendizagem de múltiplos núcleos foi aplicada para melhorar o desempenho da classificação. O núcleo resultado foi usado com SVM para classificação final. O classificador foi testado nos bancos de dados MESSIDOR e DIARETDB1. A AUC obtida foi 0.973 para detecção de MA e 0.919 de HE.

Em (AKRAM ET AL. 2015) propôs um método para detecção automática de exsudatos e mácula e assim classificar o edema macular diabético. O método consiste em 3 diferentes fases detecção dos exsudatos, detecção de mácula e classificação. No primeiro passo, a imagem de entrada é enviada ao sistema e fechamento morfológico é aplicado para remover os vasos sanguíneos. Depois melhoramento de contraste é realizado para melhorar o

contraste de imagens brilhosas nas superfícies da retina e um banco de filtros baseados no núcleo de Garbor é criado e convoluído com a imagem de contraste melhorado. Um mapa binário foi criado, contendo regiões candidatas a serem exsudatos é feita usando uma limiarização adaptativa com valor T que foi calculado usando algoritmo de Otsu. Em seguida, a extração de características baseadas em 8 descritores de características diferentes foi feito para selecionar todos os possíveis candidatos a exsudatos. O passo final nessa fase foi combinar *Gaussian Mixture Model* (GMM) e SVM para selecionar os verdadeiros exsudatos. O segundo passo começa com a extração de característica de cada região. Essas características incluem canal verde com melhoramento de contraste, área, coordenadas de disco óptico, pontuação de correlação cruzada normalizada, e pontuação de gradiente média. A classificação da mácula foi feita usando GMM, para fazer a decisão usando a regra bayesiana. A classificação do edema de mácula foi feita baseada na localização e distancia entre a mácula e os exsudatos. Desta forma a imagem é classificada em saudável, edema macular clinicamente insignificante e edema macular clinicamente significativa. O sistema foi testado nos bancos de dados HEI-MED e MESSIDOR. As melhores e piores acurácias médias para exsudatos no MESSIDOR foram respectivamente: 100%, 97.37% e 97.31%. No banco HEI-MED as mesmas médias atingiram os seguintes valores: 99.56%, 96.49% e 98.13%

Em (ADAL ET AL. 2013) apresentou um método semi-supervisionado para detecção automática de micro aneurismas. O problema é modelado ao encontrar regiões de interesse ou *blobs* a partir de imagens e seleção automática de escalas locais. Na fase de pré-processamento, a decomposição de valores singulares (SVD) foi aplicado para reduzir os efeitos de sombra e aumentar o contraste na imagem. Para detectar os MA foram encontrados os determinantes da matriz Hessiana em cada pixel no canal verde. A escala local de cada micro aneurisma candidato foi estimada após o cálculo dos máximos locais da reposta Hessiana normalizada entre diferentes escalas. As características foram extraídas usando métodos espacial-escalar (autovalores médios e máximos da matriz Hessiana assim como a norma Hessiana), *Speed and Robust Features* (SURF) e transformada de Radon (média e desvio padrão). O modelo foi testado nos bancos de dados *Retinopathy Online*

Challange e University of Tennessee Health Science Center. Quatro classificadores supervisionados foram escolhidos como classificadores subjacentes: *k-Nearest Neighborhood (k-NN)*, *Naïve Bayes*, *Random Forest* e Máquina de Vetor suporte. A sensibilidade alcançada no operador Hessiano foi 44.64%. No banco DIARETDB1, usando classificador k-NN, a AUC obtida foi 0.7228.

Em (BADSHA ET AL. 2013) desenvolveu um método usando ambas as abordagens de pré e pós-processamento para extrair vasos sanguíneos. O método começa com processo de melhoramento de bordas usando modelo de Kirsch para imagens coloridas. Em seguida, a borda melhorada é convertida para escala de cinza. Depois o histograma foi equalizado e a imagem de saída foi binarizada. O fechamento dos furos e áreas vazias dentro dos vasos, originados devido a modelagem prévia, foi feita através de dilatação e erosão. Para remover o disco óptico e sua borda, a erosão morfológica foi usada. O sistema foi testado no banco de dados DRIVE e atingiu respectivamente as seguintes sensibilidade, especificidade e acurácia: 0.9899, 0.86 e 0.9731.

Em (ZHU ET AL. 2017) propôs um método para segmentar os vasos em imagens coloridas. O primeiro passo foi extração de características. Nessa fase, foram extraídas 29 características locais. Em seguida, seis características morfológicas, uma congruência de fase, duas características de Hessiana e uma característica de divergência do campo de vetor. O segundo passo foi usar aprendizagem de máquina extrema. O vetor de característica foi obtido a partir de um grupo de treinamento dedicado, através de um classificador de treinamento usando ELM. Então as imagens na fase de teste foram usando o classificador citado. Depois foi obtida uma imagem de intensidade da segmentação de vasculatura de retina. O classificador foi testado no banco de dados DRIVE. O tempo médio necessário, sensibilidade, especificidade e acurácia foram respectivamente 12.1602 s, 0.7140, 0.9868 e 0.9607.

Em (BENDAOU DI ET AL. 2016) programou um filtro de combinação para segmentação de vasos sanguíneos oculares em imagens de alta resolução. Foi baseado em três propriedades principais propostas por Choudhuri. Baseado nessas propriedades, uma função gaussiana foi usada como modelo para ajustar as veias. Nesta abordagem, uma variável m , é definida para normalizar o filtro de resposta e obter um valor de média zero.

Depois, foram propostos dois sistemas diferentes de segmentação. O primeiro era uma arquitetura de hardware com gerador de descrição HDL automático. O segundo era um ASIP para detecção de vasos sanguíneos. A qualidade da detecção dos vasos foi testada do banco de dados DRIVE. A AUC média foi 0.9218 e a acurácia foi 0.9207.

Em (BAO ET AL. 2015) desenvolveu um classificador usando filtro de Cake para segmentação de vasos. O primeiro passo foi o melhoramento da imagem para ajustar o contraste. Segundo, a imagem foi segmentada usando filtro Cake e então a fusão da parte real da orientação de pontuação foi realizada. Finalmente a rede de vasos foi extraída por limiarização. O modelo foi testado no banco de dados STARE. A acurácia média e o taxa de positivos verdadeiros foram 0.9624 e 0.7812.

Em (RAJA & VASUKI 2015) propôs uma forma de detectar vasos sanguíneos em imagens de retina. O trabalho foi focado no diagnóstico de retinopatia diabética. Primeiro o canal verde da imagem foi extraído. Segundo o disco óptico foi segmentado usando um filtro de difusão anisotrópica. Por último uma máscara morfológica binária foi criada. O modelo foi testado nos bancos de dados DRIVE (normais) e STARE (anormais). A sensibilidade, especificidade e acurácia médias para o DRIVE foram 94.08%, 98.28% e 98.10%. As mesmas medidas para o STARE foram 93.91%, 98,47 e 98.07%, respectivamente.

Em (MAPAYI ET AL. 2015) combinou limiarização adaptativa em energia de matriz de coocorrência em níveis de cinza (GLCM) para identificar vasos em imagens de fundo do olho. Primeiro o a matriz de coocorrência em níveis de cinza foi computada usando a distancia relativa entre o par de pixels e a orientação relativa " φ ". Segundo uma característica de ASM escalar foi medida dentro da distancia variante "d" e a orientação relativa " φ ". Finalmente a limiarização adaptativa foi computada através do filtro da mediana com a convolução no melhoramento da imagem (filtro de nitidez) do resultado anterior, através do filtro da mediana com a imagem diferença. Uma combinação de abertura morfológica com filtragem da mediana foi feita na imagem limiarizada inversa para acabar com a falta de classificação restante. O método foi testado nos bancos de dados DRIVE e STARE. Para o DRIVE a

AUC obtida foi 0.9711 com limiar-ASM de 0.5 na intensidade de cinza. Para o STARE a melhor AUC obtida foi 0.9781 com limiar de ASM no canal verde.

Em (SEOUD ET AL. 2015) desenvolveu um método para detectar lesões em retinopatia diabética usando características dinâmicas de forma. Primeiro as imagens foram pré-processadas através de equalização da iluminação, *denoising*, equalização adaptativa de contraste normalização de cores. Depois o disco óptico foi removido numa abordagem baseada em entropia para estimar a localização do DO. O passo seguinte foi extrair os candidatos a lesões no canal verde da imagem. Em seguida, foram identificadas seis características dinâmicas de forma: área relativa, alongamento, excentricidade, circularidade, retangularidade e solidês. O processo de classificação foi feito usando um classificador *Radon Forest*. O método foi testado nos bancos de dados Messidor, HRF e CARA1006. Na classificação de imagem sem RD contra todas as imagens com RD o método obteve uma AUC de 0.899, Sensitividade de 93.9% e especificidade de 50%.

Em (ROYCHOWDHURY ET AL. 2014) segmentou os vasos em imagens de retinografia por meio de extração dos vasos maiores, classificando no mesmo trabalho as sub imagens. A etapa de pré-processamento foi feita de duas maneiras. Primeiro foi extraído um filtro passa-baixa de suavização de uma imagem melhorada *le*. A segunda estratégia consistiu na extração de lesões correspondendo aos pixels escuros a partir do negativo da imagem *le*. Na segunda parte, os pixels nas sub imagens foram classificados para formar a sub imagem *C*, e os pixels em *C* foram classificados usando um classificador GMM que classificou os pixels como vasos e não vasos. Para cada pixel (x,y) na sub imagem *C*, 57 características foram analisadas. No entanto somente 7 características foram definidas colocando os pixels desejados (x,z) como o pixel central numa janela quadrada do comprimento 5, na imagem *le*. Para seleccionar os pixels mais significantes o classificador GMM com 2 gaussianas foram usados. O sistema foi testado nos bancos de dados DRIVE, STARE e CHAVE_DB1. A AUC, acurácia, sensibilidade e especificidade para esses bancos de dados foram respectivamente 0.962, 0.9519, 0.7249, 0.983, 0.9688, 0.9515, 0.7719, 0.9726, 0.9532, 0.9530, 0.7201 e 0.9824.

Em (FIGUEIREDO ET AL. 2015) Propôs um método para detectar lesões em imagens de retinografia. Primeiro a imagem foi pré-processada e o

disco óptico foi identificado através de segmentação binária via limiarização do canal verde. Os micro aneurismas foram detectados baseados na detecção de blobs circulares de duas transformadas de Wavelet. As hemorragias foram identificadas de acordo com três critérios diferentes, incluindo limiarização, filtro *Wiener* e filtro Gaussiano. As lesões claras foram detectadas baseadas nos níveis de *Wavelet* e agrupamento. O modelo foi testado em três bancos de dados: *Dma*, *Dhem* e *Dbl*. A sensibilidade para cada lesão foi 93.45%, 86.34% e 89.61%. A especificidade foi 88.92%, 90.19% e 97.47%.

Em (GUPTA ET AL. 2017) propôs um método para identificar retinopatia diabética proliferativa usando caracterização local. O método necessita de definir fragmentos na imagem e calculando informação descritiva em cada fragmento. Os fragmentos foram caracterizados de acordo com a textura, características de vasos e características de vasos mapeados. A caracterização de fragmento por textura pode ser obtida a partir de multi escalas, representação AM FM, características de filtragem orientada de Garbor, características de estatística espacial e análise de espectro de potência. Características baseadas em vasos pode ser melhoramento de crista usando filtro de Garbor, cristas da análise dos autovalores da matriz Hessiana, coerência de pixels de vizinhança e difusão de coerência melhorada. O mapa de filtro de vasos são padrões binários locais, filtro de vizinhança local e análise planar das curvas dos vasos. A especificação da implementação foi: descritores de AM PM multi escalar, características obtidas do melhoramento de Garbor, estatísticas espaciais, análise de espectro de potência, características baseadas em vasos e distribuição através de várias faixas de comprimento. O sistema foi testado num banco de dados local, no MESSIDOR, STARE e HRF. A AUC, Sensibilidade e especificidade obtidas para os banco de dados combinados foram respectivamente 0.9755, 92.4% e 92.6%.

Em (MENG ET AL. 2015) desenvolveu uma estrutura para segmentação da vasculatura da retina baseada em filtros combinados. Primeiro as imagens foram segmentadas usando limiarização ponderada melhorada por filtro circular de Garbor, multi direcional e segunda derivação da Gaussiana multi escalar. Todos esses passos foram aplicados no canal verde da imagem. Depois as imagens foram segmentadas em direções diferentes de iluminação por um grupo de filtros de alongamento. Por último, na fase de pós-processamento as

regiões em forma de ponto e pixels que não eram vasos foram removidos. O modelo foi testado nos bancos de dados DRIVE e STARE e alcançaram sensibilidade, especificidade e acurácia de 0.7489, 0.9818, e 0.9529 para o DRIVE. Para o STARE as mesmas medidas foram 0.7413, 0.9825 e 0.9569.

Em (NGUYEN ET AL. 2013) automatizou um método para quantificação de vasos arteriais. A estrutura vascular foi extraído usando detecção multi-escalar de linhas. Depois o esqueleto vascular e as bordas foram extraídos da imagem segmentada usando operador morfológico binário. Então os vasos principais foram identificados através das seguintes características de pontos: cruzamento, bifurcação e ramificação. O esqueleto vascular foi dividido na parte de fundo em quatro seções. Para cada seção, o ponto de linha mais próximo a posição de escolha foi identificado, resultando em quatro pontos de linha. Os comprimentos dos vasos foram medidos usando o esqueleto do vaso e a imagem de borda extraída da etapa anterior. O passo final foi a para cada segmento venular foram 4 medidas automaticamente derivadas dos comprimentos de vasos de cada segmento. O sistema foi testado nos bancos de dados BMES e SiMES. As melhores especificidades e sensibilidades alcançadas foram 0.83 e 0.94.

Em (MORALES ET AL. 2015) usou diferentes operações baseadas em morfologia matemática para detectar o contorno do disco óptico. O primeiro processo foi pré-processar a imagem. *Principal Component Analysis* foi usado para criar uma nova imagem em nível de cinza. A imagem foi então melhorada usando uma transformação local de correção de sombra. Os vasos foram removidos da imagem melhorada através de uma técnica de *impainting*. A segmentação do DO foi propriamente feita transformação de bacias hidrográficas estocásticas. A técnica usa marcadores aleatórios para construir uma função de densidades de probabilidades dos contornos. Depois, a diferenciação entre regiões significantes e não significantes foi feita baseado na intensidade média da região. Para eliminar falsos contornos, a técnica de *impainting* foi aplicada novamente. A avaliação foi feita nos bancos de dados DRIONS, DIARETDB1, DRIVE, MESSIDOR e ONHSD. A acurácia obtida foi 0.9934 (DRIONS); 0.9957 (DIARETDB1); 0.9903 (DRIVE); 0.9949 (MESSIDOR) e 0.9941 (ONASD).

Em (ROYCHOWDHURY ET AL. 2015) desenvolveu um método supervisionado para segmentar o disco óptico e a origem dos vasos. Primeiro canal verde de cada imagem foi redimensionado e reconstruído usando um elemento estruturante circular. Segundo, as regiões claras foram classificadas como prováveis regiões de disco óptico ou não usando seis características baseadas em regiões e um modelo de classificador Gaussiano. Os melhores dois modelos eram indicativos de principais vasos sanguíneos na vizinhança da região clara e a estrutura compacta da região clara. No terceiro passo, as regiões prováveis de DO cujos centroides são os mais próximos ao regiões de DO mais bem consolidadas do que regiões de DO manualmente segmentadas, ou diâmetro de disco foram identificadas como candidatos restantes para DO em imagens obtidas por combinação de prováveis regiões DO. O classificador foi testado nos banco de dados DRIVE, DIARETDB0, DIARETDB1, CHASE-DB1, MESSIDOR e STARE. Para o DRIVE, DIARETDB1 e MESSIDOR a sensibilidade obtida foi, respectivamente: 0.88, 0.88 e 0.90.

Em (ZHANG ET AL. 2012) propôs um método para extrair o disco óptico de asiáticos. A detecção dos vasos próximos ao DO fora realizado através de filtragem Gaussiana multi escalar baseada em filtros de combinação. Depois, uma limiarização dupla foi aplicada para gerar uma imagem binária e os vasos foram detectados usando afinamento morfológico. Finalmente, os candidatos a vasos de DO fora combinados definindo um padrão 9x9. O sistema foi testado em um banco de dados referido como HIT e 399, de um total de 402, imagens foram detectados corretamente.

Em (RODRIGUES & MARENGONI 2017) segmentou o disco óptico e os vasos sanguíneos em imagens de retinas usando *Wavelets*, morfologia matemática e um filtragem multi escalar baseado na matriz Hessiana. Essas ferramentas matemáticas foram combinadas separadamente para conseguir a principal proposta. Para a segmentação de disco óptico a imagem foi processada no nível de cinza selecionado pela análise de histograma e encontrar a maior faixa de cor. Depois a melhor faixa é submetida a um melhoramento por "*White top hat*", usando um elemento estruturante circular com raio igual a 25 para melhorar a região clara d DO. Então essa imagem foi submetida a uma decomposição de *Wavelet* piramidal de Haar. O quinto nível com 37x36 pixels foi redimensionado e interpolado ao tamanho original da

imagem. Depois de testes empíricos sucessivos eles obtiveram a melhor detecção da região do disco óptico pela aplicação de limiarização com valores de pixels variando de 220 a 225. O método foi testado no banco de dados DRIVE. Os vasos foram segmentados usando uma abordagem baseada na matriz Hessiana, proposta por Frangi *et al.* E foi testado nos bancos de dados DRIVE e HRF. Para o DRIVE, alcançou sensibilidade de 0.7165, especificidade de 0.9801 e acurácia de 0.9465. Para o HRF, alcançou sensibilidade de 0.7223, especificidade de 0.9636 e acurácia de 0.9472.

Em (GEGUNDEZ-ARIAS ET AL. 2013) desenvolveu um método para segmentar o centro do disco óptico. Primeiramente as imagens foram redimensionadas para 540 pixels cada uma. Depois para remover a variação da iluminação de segundo plano, foi usada uma correção de sombra, filtragem da imagem com aplicação de um filtro de média aritmética de 69x69. Os principais vasos sanguíneos foram segmentados usando uma transformação morfológica do tipo *top-hat*. Para melhorar as regiões brilhosas, foi usado um processamento morfológico com abertura e fechamento para segmentar o disco óptico. Uma limiarização automática de 2 fases foi realizada. O primeiro passo tentava encontrar um pixel dentro ou próximo o suficiente do DO. O segundo passo objetivava descartar os valores mais escuros de uma janela de vizinhança centrada no DO. A região do DO foi finalmente obtida usando uma transformada Hough de círculos no grupo de candidatos na fronteira, gerados através da aplicação de detecção de bordas prewitt. O modelo foi testado no banco de dados MESSIDOR e não avaliaram o resultado de acordo com uma medida tradicional.

Em (CHENG ET AL. 2013) desenvolveu um método para triagem de glaucoma usando classificação de super-pixel para segmentar o disco óptico e a área central. A classificação de super-pixel foi combinada com um método baseado em modelo deformável. A geração dos super-pixels foi feita através de Agrupamento Iterativo Linearmente simples (SLIC). Na extração de características, primeiro foi feito um melhoramento no contraste do histograma. Segundo, uma estatística central foi realizada. Finalmente, os super-pixels foram determinados como o primeiro super pixel movendo o super-pixel atual horizontalmente à esquerda a partir do centro. Uma máquina de vetor suporte foi usada como classificador. O sistema foi testado nos bancos de dados

SiMES, SCES e MESSIDOR. A AUC para o SiMES foi 0.800 e para o SCES foi 0.822.

Em (SUN ET AL. 2015) segmentou o disco óptico usado *Balloon Snake* com textura a partir de imagens de retinografia colorida. *Template Matching* foi usado para estimar a região do disco. Uma transformada circular de Hough foi usada para corrigir o centro do disco e encontrar o raio estimado do disco. Essa transformada também foi aplicada para selecionar a região de interesse. No entanto foi necessário remover pequenos ruídos com um filtro Gaussiano e um núcleo Canny. Um método de *inpainting* foi usado para remover os vasos. Para segmentar o início do disco óptico, primeiro foi necessário encontrar características que podem distinguir regiões ópticas e os limites e somente depois desse passo usada o *Balloon Snake* para a segmentação do disco. O sistema foi testado no banco de dados HRF. A métrica escolhida para avaliação foi o coeficiente de disse que atingiu uma média de 0.9400 com erro médio igual a 0.0263.

Em (AKRAM ET AL. 2015) usou um grupo de métodos para diagnosticar glaucoma. Os classificadores escolhidos foram localização de disco óptico, características híbridas nas técnicas de classificação. A técnica de disco óptico considera que um DO normalmente tem intensidades claras e que vasos sanguíneos são originados do DO resultando na densidade mais alta no disco. Foram usadas Wavelet de Garbor Bidimensional seguido por limiarização baseada na segmentação de vasos. Para a extração de vasos foram usadas dez características: CDR, RDR, cinco características espaciais e 3 características espectrais. Esses modelos foram testados nos mesmos bancos de dados: (Se: 83.3%, Spe: 94.1%, PPV: 71.4%, Acc: 92.5%), DRIONS (Se: 84.2%, Spe: 87.1%, PPV:72.2%, Acc: 93.6%), HEI-MED (Se: 84.2%, Spe: 87.1%, PPV:80.0%, Acc: 86.7%), MESSIDOR (Se: 84.0%, Spe: 94.4%, PPV: 84.0%, Acc: 89.0%), HRF (Se: 93.3%, Spe: 90.0%, PPV: 82.3%, Acc: 91.1%) e GlaucomaDB (Se: 85.7%, Spe: 92.9%, PPV: 83.3%, Acc: 90.8%).

Em (DÍAZ-PERNIL ET AL. 2016) identificou o disco óptico em imagens de retinografia usando um método de segmentação completamente paralela. Na primeira etapa, a imagem de entrada foi comprimida e amostrada. A fase dois consistiu na segmentação usando um segmentador colorido AGP. Para controlar o efeito de borramento uma vizinhança 5x5 foi usada. Dada uma

imagem de n^2 pixels, foi definido um tecido P com divisão celular. O sistema de tecido consistia em 11 estágios: estágio de geração, escolha de um estágio de direção, estágio gradiente e resultado. A fase 3 foi realizada usando o algoritmo de Hamadani para binarizar a imagem. Para anular resultados errôneos, a fase 11 foi feita para iluminar a borda com detecção de máscara. Somente na fase 5 a transformada de Hough foi aplicada o usando o seu máximo e o conceito de nuvem para considerar todos os raios que superam a porcentagem de sucesso. Na ultima fase o procedimento de escolha de Hough realizado para criar o DO. O sistema foi testado nos bancos de dados DRIVE e DIARETDB1. Para o DRIVE as médias de sensibilidade, especificidade e acurácia foram respectivamente 89.9%, 99.8% e 99.6%. Para DIARETDB1 os mesmos resultados foram 91.8%, 99.7% e 99.6%.

Em (GEGUNDEZ-ARIAS ET AL. 2013) usou limiarização e características de extração para alocar o centro da fóvea. O pixel da fóvea foi obtido através da estimação de raphe, cuja origem foi colocada nas coordenadas do disco óptico, considerando que a fóvea tem 2.5 vezes o tamanho do diâmetro do DO. O pixel central da fóvea foi identificado gerando uma imagem de mapa de contorno e centroide fornecendo um valor médio mínimo na escala de cinza. O método foi testado no banco de dados MESSIDOR e a escala com melhor qualidade alcançou 97.83% para 2R.

Em (SINGH ET AL. 2015) usou características de Wavelet do disco óptico segmentado de imagens de retinografia para diagnosticar glaucoma. Primeiro o centro do disco óptico foi detectado usando uma janela de Kaiser. Em seguida o disco óptico foi segmentado e então os vasos foram removidos da imagem DO. O passo seguinte foi usado o filtro de Wavelet para extrair 18 características. Características proeminentes foram selecionadas usando seleção de atributos evolucionários e PCA. Para diagnosticar o glaucoma, alguns classificadores foram escolhidos: Radon Forest, Naïve Bayes, kNN, ANN e SVM. Não foi especificado em que banco de dados o método foi testado. Para redução de características, as melhores sensibilidades e NPVs foram adquiridas com SVM (100%). A especificidade e PPV foram obtidos com kNN. Para seleção de características proeminentes, 100% de sensibilidade foram obtidas com Naïve Bayes e ANN. A melhor especificidade foi com

Random-Forest (100%). Esse último classificador teve também o melhor PPV (100%). ANN foi o melhor NPV (100%).

Em (ZILLY ET AL. 2017) usou amostragem de entropia e montagem de grupos para segmentação automática de disco óptico e do centro e dessa forma a detecção de glaucoma. Na etapa de pré-processamento o disco óptico foi localizado aplicando transformada de Hough no canal verde da imagem. Depois uma entropia de primeira ordem foi calculada pela gravação de cada valor de nível de cinza na vizinhança N usando um histograma de 256 bins. Em seguida, gentle Adaboost foi usado para aprendizagem de diversos filtros sucessivamente numa forma supervisionada para minimizar a classificação de erros ponderados. As imagens convoluídas foram então pós-processadas para padroniza-las. As imagens foram convoluídas com cada uma delas para produzir um grupo de 34 características para treinar um classificador de regressão logística softmax. Um algoritmo supervisionado de corte de grafo foi aplicado no mapa probabilístico para obter uma segmentação inicial do disco. O método foi testado no banco de dados DRISHT1-GS. A F-Score alcançada para o disco óptico foi 97.3% e para o centro foi 87.1%.

Em (MORALES ET AL. 2015) usou um padrões binários locais para triagem de doenças de retina. As imagens foram redimensionadas para um tamanho padronizado para obter descritores de textura comparáveis. Depois, operações de padrões binários foram usados para caracterizar a textura do fundo da retina. Finalmente a classificação foi realizada com a técnica *Synthetic Minority Oversampling Technique* (SMOTE) e correlação cruzada. O modelo foi testado num banco de dados de diagnostico. Foi focado em retinopatia diabética e Doença da Mácula relacionada com a idade. O TPR e TNR para as duas doenças foram respectivamente: 1.000, 0.990, 0.856 e 0.987.

Em (MITTAPALLI & KANDE 2016) desenvolveu um sistema para segmentar o disco óptico para avaliação de glaucoma. Primeiro um núcleo de mistura Gaussian-Hermite foi usado para melhorar a estrutura do segmento de vasos sanguíneos. PCA foi usado para localizar a região do DO e extrair uma região de interesse para processamento posterior. A detecção de contorno de DO foi realizada inspirado modelo de contorno ativo pela interação da informação da imagem local em cada ponto de interesse consistindo de

características como intensidade, cor e textura a partir de múltiplos canais de imagem. Para segmentar o centro foi implementada uma técnica de limiarização baseada no algoritmo SWFCM. O modelo foi testado nos banco de dados RIMONE e DIARETDB1. A F-Score da segmentação do DO foi 0.975. A mesma métrica para a segmentação do centro do disco foi 0.89.

4. METODOLOGIA

O algoritmo foi desenvolvido na linguagem Python 2.7.13, com o auxílio das bibliotecas Scikit Image, versão 13 e OpenCV-Python, versão 2.4.13.2. As técnicas usadas foram escolhidas de acordo com a sua disponibilidade nas bibliotecas considerando que não haviam sido usadas por nem um método citado no estado da arte.

Todos os métodos de limiarização foram aplicados na conversão da imagem de RGB para escala de cinza e no canal verde da imagem. Essa escolha foi feita baseada no fato que a escala de cinza é o espaço de cores padrão quando se usa limiarização. Já o canal verde foi escolhido pelo fato de apresentar maior contraste entre vasos e não vasos sanguíneos, de forma que otimiza o processamento para a detecção dessas estruturas oculares.

4.1 - LIMIAÇÃO DE OTSU

A limiarização usando o método de Otsu é feita tentando-se tornar cada agrupamento o mais fino possível, dessa forma torna a superposição minimizada. Não é possível minimizar as distribuições, no entanto é possível ajustar onde pode ser feita a separação (o limiar). Esse ajustamento é feito aumentando o espalhamento de uma diminuindo o de outra. O objetivo então é selecionar o limiar que minimiza o espalhamento combinado (SMITH ET AL. 1979).

A variância interclasse pode ser definido como a soma ponderada das variâncias de cada cluster:

$$\sigma^2_{inter}(T) = nb(T)\sigma^2_b(T) + no(T)\sigma^2_o(T)$$

Em que:

$$nb(T) = \sum_{i=0}^{T-1} p(i)$$

$$no = \sum_{i=T}^{N-1} p(i)$$

$\sigma^2_b(T)$ = Variância dos pixels na parte externa (abaixo do limiar)

$\sigma^2_o(T)$ = Variância dos pixels na parte interna (acima do limiar)

[0, N-1] é a faixa dos níveis de intensidade

O cálculo da variância entre as classes para cada uma das duas classes em cada limiar possível envolve muito calculo, no entanto há um caminho mais simples.

Se subtrair a variância entre classes da variância total da distribuição combinada, obtém-se a variância entre classes:

$$\sigma^2_{entre}(T) = \sigma^2 - \sigma^2_{dentro}(T) = nb(T)[\mu_b(T) - \mu]^2 + no(T)[\mu_o(T) - \mu]^2$$

onde σ^2 é a variância e μ^2 é a média combinada. Percebe-se que a variância entre classes é simplesmente a variância ponderada dos agrupamentos de médias em si em volta da média geral. Substituindo: $\mu = nb(T)\mu_b(T) + no(T)\mu_o(T)$ e simplificando:

$$\sigma^2_{entre}(T) = nb(T)no(T)[\mu_b(t) - \mu_o(T)]^2$$

Então para cada limiar potencial:

1. Separam-se os pixels em dois agrupamentos de acordo com o limiar;
2. Encontra a média de cada cluster;
3. Calcula a raiz quadrada entre as médias;
4. Multiplica pelo número de pixels em um agrupamento e o número no outro;

Mesmo assim ainda há elevado calculo computacional, já que precisa-se fazer isso para cada limiar potencial, mas acontece que esses cálculos são independentes quando muda-se de um limiar pra outro. Pode-se atualizar $nb(T)$, $no(T)$ e as médias respectivas $\mu_b(T)$ e $\mu_o(T)$ quando os pixels movem-se entre os agrupamentos quando os valores de T aumentam. Usando relações de recorrência simples, a variância entre as classes é atualizada quando cada limiar é testado sucessivamente:

$$\begin{aligned} Nb(T+1) &= nb(T) + nT \\ No(T+1) &= no(T) + nT \\ \mu_b(T+1) &= \frac{\mu_b(T)nb(T) + nT}{nb(T+1)} \end{aligned} \quad (2)$$

$$\mu_O(T+1) = \frac{\mu_O(T)no(T)+ntT}{no(T+1)}$$

O método de Otsu exibe um desempenho relativamente bom se o histograma mostrar ser uma distribuição bimodal e possuir um vale profundo entre dois picos. Mas se a área do objeto for pequena comparada com a área do fundo, o histograma não vai demonstrar ser bimodal. Se as variâncias do objeto e as intensidades do fundo são elevadas comparadas com a diferença média, ou se a imagem for comprometida severamente por ruído aditivo, o vale afiado do histograma em níveis de cinza é degradado. Então o limiar possivelmente incorreto determinado pelo método de Otsu, resulta em um erro de segmentação (em que se define o tamanho do objeto sendo o raio da área do objeto em relação à área e a diferença média como sendo a média das intensidades do objeto e o fundo).

A partir de resultados experimentais, a performance das técnicas de limiarização global, incluindo o método de Otsu mostra-se limitado para objetos de pequeno tamanho, a pequena diferença média, largas variâncias do objeto e as intensidades do fundo, o elevado ruído adicionado (Morse 2000).

4.2 - LIMIAZIZAÇÃO USANDO ISODATA

Isodata é um procedimento para classificar um grupo de amostras de vetores $x = \{x_1, x_2, x_3, \dots, x_m\}$ em c s classes distintas (VELASCO 1980).

4.2.1 - ALGORITMO 1 – ISODATA BÁSICO

1. Escolhe-se alguns valores iniciais para as médias $\mu_1, \mu_2, \mu_3, \dots, \mu_c$
Laço:
2. Classifica as m amostras classificando-as as classes tendo a média mais próxima;
3. Recalcula as médias como médias das amostras em cada classe;
4. Se alguma média mudou de valor, retorna ao início do processo.
Se não, para.

No caso de imagens, cada ponto, tem um numero relacionado a um nível de cinza no intervalo $[0,L]$, sendo L o número de níveis. Cada amostra é então um ponto da imagem. A distribuição dos níveis de cinza é dado pelo

histograma da imagem. Nesse caso, assume-se [LO, UP] sendo os menores intervalos contendo todos os valores no histograma, diferentes de zero.

4.2.2 – ALGORITMO 2: ISODATA DE UMA DIMENSÃO

1. Escolhe-se valores iniciais para as médias $\mu_1, \mu_2, \mu_3, \dots, \mu_c$ sendo $LO \leq \mu_1 < \mu_1 < \mu_2 < \dots < \mu_c < UP$

Laço:

2. Calcula os limiares T_1, T_2, \dots, T_{c-1} pela formula: $T_i = \left[\frac{(\mu_i + \mu_{i+1})}{2} \right], 1 < i < c;$

3. Recalcula as médias: Para cada i , torna-se a média μ_i do próximo nível cinza em $\frac{(\sum_{j \in I} j \cdot h(j))}{(\sum_{j \in I} h(j))}, i \leq i \leq c. \quad (3)$

4. Se houver mudança em algum valor da média, volta ao laço. Caso contrário finaliza.

4.3 – LIMIAZIZAÇÃO MÍNIMA

Na limiarização Mínima T é escolhido como o valor de i em que y_i é minimizado no vale entre o máximo de y . O algoritmo assume um histograma bimodal, que na prática necessita que os valores de y sejam suavizados. Um método simples para conseguir isso é substituir y_i por $\frac{(y_{i-1} + y_i + y_{i+1})}{3}$ para $i=0, 1, \dots, n$ com $y_{-1} = y_{n+1} = 0$, e repetindo o processo até que os valores de y se tornem bimodais. Então se tem T na forma que $y_{t-1} > y_t \leq y_{t+1}$. Uma forma alternativa de de intermodas, encontra dois valores máximos, y_j e y_k e estabelece $t = (j+k)/2$. (PREWITT & MENDELSON N.D.; GLASBEY 1993).

4.4 – LIMIAZIZAÇÃO MÉDIA:

A média é a forma de análise estatística mais básica entre todas as medidas. Média normalmente é usada em geometria e análise (Kumar & Gupta 2012); Uma variedade de médias tem sido desenvolvida para essas propostas. Em se tratando de processamento de imagens, a média pode ser usada como filtragem espacial e normalmente apropriada redução de ruído. A média é definida como:

$$M = \frac{1}{mn} \sum_{(r,c)=0}^{m,n} f(r, c) \quad (4)$$

Em que:

M é a média;

m é o número de linhas da imagem;

n é o número de colunas da imagem;

f(r,c) é o valor do pixel na posição *(r,c)*.

4.5 – LIMIAZIZAÇÃO TRIANGLE:

Nessa limiarização é construída uma linha entre o valor máximo do histograma no valor de brilho máximo *bmax* e o valor mínimo, *bmin = (p=0)* na imagem. A distância *d* entre a linha e o histograma *h[b]* é calculada para todos os valores de *b*, a partir de *b=bmin* até *b=bmax*. O valor de brilho *b0* onde a distância entre *h[b0]* e a linha é máxima é o valor do limiar *T*. Esta técnica produz bons resultados quando os pixels do objeto produzem um pico fraco no histograma (ROGERS & ZACK 1977).

A limiarização do tipo triangle, um método geométrico, não diz se o dado está inclinado para um dos lados, mas assume um pico máximo (moda) próximo a um dos limites do histograma e vasculha o limite do outro limite. Isso causa problema no caso de ausência de informação do tipo de imagem a ser processada, ou quando o máximo não é próximo a um dos limites do histograma. Isso resulta em duas possíveis regiões de limiar entre os máximos e os extremos.

4.6 – LIMIAZIZAÇÃO MEDIANA:

Esse método escolhe como valor de limiar a mediana da distribuição. Isso é, o pixel que separa a metade maior e metade menor da distribuição de pixels.

4.7 – LIMIAÇÃO GLOBAL SIMPLES:

O banco de dados apresenta imagens com 8 bits por pixels, resultando em 255 tons de cinza diferentes. Nesse caso o valor escolhido foi 127 que é quase a metade número de tons de cinza.

4.8 – LIMIAÇÃO ADAPTATIVA

Em todos os casos anteriores foram usados valores globais como valores de limiar. No entanto esses métodos podem causar problemas quando a imagem tem problemas de iluminação em áreas diferentes. Neste caso, o melhor método é a limiarização adaptativa. Neste método, o algoritmo calcula o limiar para pequenas regiões do histograma da imagem. Sendo assim, se tem diferentes valores para diferentes regiões da mesma imagem fornecendo resultados melhores em imagens com problemas de iluminação.

4.8.1 – LIMIAÇÃO ADAPTATIVA MÉDIA

O valor de limiar escolhido é a média da vizinhança escolhida.

4.8.2 – LIMIAÇÃO ADAPTATIVA GAUSSIANA

O valor de limiar é uma soma ponderada dos valores da vizinhança em que os pesos são resultados de uma janela gaussiana.

Uma função gaussiana de duas variáveis tem a forma básica:

$$G(x, y) = e^{-\frac{x^2+y^2}{\sigma^2}} \quad (5)$$

Em que:

σ é o desvio padrão

x e y são as coordenadas da imagem e números inteiros.

A função Gaussiana bidimensional tem o formato de um sino e o desvio padrão controla o quanto ele é aberto.

4.9 – BANCO DE DADOS:

Todas as técnicas foram testadas no banco de dados *Digital Retinal Images for Vessel Extraction*, referido sempre como banco de dados DRIVE (STAAL ET AL. 2004), consiste de 40 imagens obtidas na forma digital de uma

câmera Canon CRS 3CCD com campo de visão de 45 graus. O tamanho da imagem é 768x584, 8 pixels por canal de cor e o FOV tem aproximadamente 340 pixels de diâmetro. As imagens foi segmentada por 3 observadores, sendo 1 deles um estudante de ciências da computação e outros 2 médicos experientes. Todas as imagens são divididas em grupo de treino e de teste cada uma com 20 imagens.



Figura 2 – Primeira imagem do banco de dados DRIVE

4.10 – MÉTRICAS DE AVALIAÇÃO:

Foram escolhidas as seguintes métricas para avaliar o uso das técnicas de limiarização.

4.10.1 – ERRO QUADRADO MÉDIO (MSE):

MSE é uma medida de fidelidade entre sinais. O objetivo de medir a fidelidade é comparar os sinais fornecendo uma medida quantitativa que descreve o grau de similaridade/fidelidade, reciprocamente, o nível de erro/distorção entre eles. Normalmente assume-se que um dos sinais é puro, enquanto o outro é distorcido ou contaminado por erros. Nesse trabalho os sinais puros considerados são as imagens do canal verde e em escala de cinza.

Supõe-se que: $x = \{x_i | i=1,2, \dots, N\}$ e $y = \{y_i | i=1,2, \dots, N\}$ dois sinais finitos e discretos, em que N é o número de amostras, no caso pixels, e x_i e y_i são valores da i -ésima amostra. O MSE entre as duas imagens é:

$$MSE(x, y) = \frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2 \quad (6)$$

Em MSE normalmente refere-se ao erro do sinal $e_i = x_i - y_i$, que é a diferença entre o sinal original e o distorcido. Na literatura do processamento de imagem, MSE é normalmente convertido em uma medida de razão entre o sinal e o ruído (PSNR):

$$PSNR = 10 \log_{10} \frac{L^2}{MSE} \quad (7)$$

Em que L é a faixa dinâmica das intensidades de pixel de imagem permitidas. Como o banco de dados possui 8 bits por pixel, $L=255$. O PSNR é útil se as imagens que estão sendo comparadas têm faixas dinâmicas diferentes. Caso contrário, essa medida não fornece nem uma informação nova (WANG & BOVIK 2009).

Entre as vantagens do MSE estão:

1. É um parâmetro simples e de cálculo fácil com complexidade de apenas uma multiplicação e duas adições por amostra. Também não requer uso de memória – o erro quadrado pode ser avaliado independentemente em cada amostra.
2. Todas as normas são distâncias de métricas válidas, que satisfazem as condições seguintes e permite condições de similaridade diretas e consistentes.
 - 2.1 Não negatividade: $dp(x,y) \geq 0$;
 - 2.2 Identidade: $dp(x,y) = 0$ se e somente se $x = y$;
 - 2.3 Simetria: $dp(x,y) = dp(y,x)$;

2.4 Desigualdade triangular: $dp(x, z) \leq dp(x, y) + dp(y, z)$;

3. Significado físico claro – É uma forma natural de definir a energia do sinal. Como uma medida de energia é preservada em caso de qualquer transformação unitária (ortogonal), por exemplo, a transformada de Fourier (Teorema de Parseval). Isso garante que a energia no domínio do sinal é igual a energia no domínio da transformação.

4. As propriedades do MSE fazem com que ela seja de bom uso em problemas de otimização. A minimização do MSE normalmente tem soluções analíticas simples e quando não são, procedimentos de otimização numérica são fáceis de formular, uma vez que o gradiente e matriz Hessiana do MSE são fáceis de calcular.

5. MSE também é uma medida desejável em problemas de estatística e estimação.

4.10.2 – ÍNDICE DE MEDIDA DE SIMILARIDADE ESTRUTURAL (SSIM)

Uma abordagem proposta de medida de fidelidade entre imagens, que tem provado ser altamente efetiva na comparação de sinais é o SSIM. Esse índice na verdade pode ter várias formas, dependendo se for implementado em uma única escala, múltiplas escalas ou no domínio da wavelets. O desenvolvimento dessa medida foi motivada através da observação de que o sistema visual humano é altamente adaptado para extrair informações estruturais de cenas visuais (WANG ET AL. 2004).

O SSIM mede a similaridade entre 3 elementos presentes na imagem: a similaridade $l(x,y)$ entre a iluminação das imagens (valores de brilho); a similaridade $c(x,y)$ entre os contrastes da imagem; e a similaridade $s(x,y)$ das imagens. Esses valores são expressos usando estatísticas simples e fácil de se computar, de forma combinada:

$$SSIM(x, y) = l(x, y).c(x, y).s(x, y)$$

$$SSIM(x, y) = \frac{(2\mu_x\mu_y+c_1)(2\sigma_{xz}+c_2)}{(\mu_x^2+\mu_y^2+c_1)(\sigma_x^2+\sigma_y^2+c_2)} \quad (8)$$

Em que:

- μ_x : Média de x;
- μ_y : Média de y;
- σ_x : Desvio padrao de x;
- σ_y : Desvio padrao de y;
- σ_{xy} : Covariância entre x e y;
- $C1 = (k1*L)^2$;
- $C2 = (k2*L)^2$;
- L = Níveis de Cinza
- K1 = 0.01 e K2=0.03

O valor de SSIM varia entre -1 e 1, em que 1 só é alcançável no caso de dois dados idênticos.

4.10.3 – Acurácia

Mede o nível de sucesso do classificador. Matematicamente é definida como:

$$Acc: \frac{TP+TN}{TP+FP+FN+TN} \quad (9)$$

Em que:

TP: O classificador detectou uma condição que estava presente;

TN: O classificador não identificou uma condição que não estava presente;

FP: O classificador detectou uma condição, no entanto a condição estava presente;

FN: O classificador não identificou uma condição que não estava presente.

5. RESULTADOS E DISCUSSÕES

Primeiro são mostrados os histogramas da escala de cinza e do canal verde das imagens eles ajudam entender os resultados.




Figura 3 – Histograma da escala de cinza da primeira imagem do banco de dados DRIVE




Figura 4 – Histograma do canal verde da primeira imagem do banco de dados DRIVE.

A seguir são apresentadas as imagens resultantes das diferentes técnicas de Limiarização.




Figura 5 – Limiarização adaptativa gaussiana na escala de cinza da primeira imagem do banco de dados DRIVE.




Figura 6 – Limiarização adaptativa média na escala de cinza da primeira imagem do banco de dados DRIVE.




Figura 7 – Limiarização adaptativa gaussiana no canal verde da primeira imagem do banco de dados DRIVE.

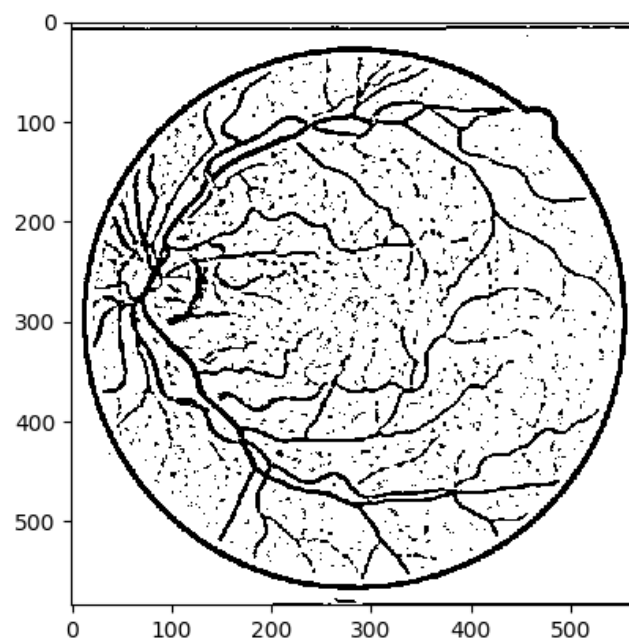


Figura 8 – Limiarização adaptativa média no canal verde da primeira imagem do banco de dados DRIVE.

A seguir é mostrada a tabela 01 com as acurácias obtidas pela comparação entre as limiarizações adaptativas média e gaussiana e o padrão ouro fornecido pelo banco de dados DRIVE.

Tabela 01: Valores Médios de Acurácia para a Limiarização adaptativa.

Técnica	Acc Média
MÉDIA VERDE	0,8368
GAUSS VERDE	0,8841
MÉDIA CINZA	0,8435
GAUSSVERDE	0,8811

Percebe-se nas imagens que a aplicação adaptativa mostrou-se eficaz na detecção de vasos sanguíneos. Como o banco de dados DRIVE fornece os vasos segmentados manualmente por dois indivíduos, eles foram usados como padrão ouro para se obter a acurácia entre o método de Limiarização e a imagem segmentada manualmente. Essas acurácias corroboram que o canal verde é melhor para a segmentação de vasos sanguíneos. Uma forma de melhorar o resultado da Limiarização adaptativa Gaussiana variando os valores de desvio padrão. O desvio padrão tem a capacidade de avaliar a variabilidade da imagem, de forma que quanto maior for esse valor, mais o dado está espalhado da média. O valor de desvio para essa imagem foi o padrão do OpenCV. Se aumentar esse valor, pode ser que a técnica encontre vasos de menor calibre, no entanto há a possibilidade de se encontrar estruturas que não são vasos. Uma forma de se corrigir esse problema seria o uso de técnicas de erosão após a Limiarização.




Figura 9 – Limiarização global na escala de cinza da décima nona imagem do banco de dados DRIVE.




Figura 10 – Limiarização global no canal verde da quinta imagem do banco de dados DRIVE.

A Limiarização global detectou regiões próximas a região que seria o disco óptico, isso se dá ao fato de que essa estrutura concentra muitos dos pixels mais claros da imagem. Ela pode ser combinada com técnicas matemáticas mais avançadas para aprimorar o resultado.




Figura 11 – Limiarização Isodata na escala de cinza da sexta imagem do banco de dados DRIVE.




Figura 12 – Limiarização Isodata no canal verde da sexta imagem do banco de dados DRIVE.

O método Isodata não se mostrou eficaz, como pode ser visto, pois os histogramas não são bimodais.




Figura 13 – Limiarização média na escala de cinza da terceira imagem do banco de dados DRIVE.




Figura 14 – Limiarização média no canal verde da terceira imagem do banco de dados DRIVE.

A Limiarização média só mostrou resultado significativo para identificar o MTA. Ela não teve um resultado mais eficaz porque as imagens possuem uma grande área de background no lado mais escuro do histograma. Isso faz com que a média da imagem geral possua um valor que tende a está mais relacionado com escuro do que se a imagem tivesse um background com menor área.




Figura 15 – Limiarização mediana na escala de cinza da primeira imagem do banco de dados DRIVE.




Figura 16 – Limiarização mediana no canal verde da primeira imagem do banco de dados DRIVE.

A Limiarização Mediana pode ser usada como pré-processamento para a detecção da mácula. As outras regiões além da mácula foram identificadas devido a problemas da iluminação (um dos grandes problemas da modalidade). Um operador morfológico logo após a técnica.




Figura 17 – Limiarização Otsu na escala de cinza da sexta nona imagem do banco de dados DRIVE.




Figura 18 – Limiarização de Otsu no canal verde da sexta imagem do banco de dados DRIVE.

O método de Otsu não apresentou nem um resultado satisfatório, pelo fato do histograma não apresentar dois picos separados por um vale. Na escala de cinza, se não houvesse pixels na faixa inicial do histograma (valores abaixo de 50), poderia apresentar melhores resultados. Da mesma forma, a equalização do histograma resultaria em um melhoramento significativo pois o resultado não resultaria em dois picos e um vale bem estruturado, pela ausência de pixels na faixa entre 50 e 100. Além disso, faria a imagem perder qualidade.

A Limiarização do tipo Triangle, bem como a Mínima, não apresentaram resultados visuais perceptíveis. A Mínima não foi eficaz pelo fato dos histogramas não serem bimodais.

O método do tipo Triangle não foi eficaz porque os histogramas das imagens mostram que os dois picos existentes, não estão nem no lado esquerdo, nem no lado direito da imagem.

A seguir está disponível a tabela 02 com valores médio de MSE e SSIM para as diferentes técnicas.

Tabela 02: Valores médios de MSE e SSIM para as diferentes técnicas de Limiarização

	NRMSE	SSIM
ADAPT GAUSS CINZA	15,2412	0,38793
ADAPT GAUSS VERDE	23,0834	0,31219
GLOBAL CINZA	0,9070	0,19716
GLOBAL VERDE	0,90697	0,0598
ADAPT MÉDIA CINZA	14,670185	0,22835
ADAPT MÉDIAVERDE	22,3839	0,17448
ISODATA CINZA	0,0529	0,7139
ISODATA VERDE	0,057745	0,7090
MÉDIA CINZA	0,081385	0,6860

MÉDIA VERDE	0,0932	0,7288
MINIMA VERDE	0,0932	0,6897
MINIMA CINZA	0,04566	0,7140
OTSU CINZA	0,0530	0,7087
OTSU VERDE	0,0889	0,7089
TRIANGLE CINZA	0,7088	0,7086
TRIANGLE VERDE	0,0889	0,7088
MEDIANA CINZA	0,4227	0,4283
MODIANA VERDE	0,4141	0,3964

Os valores elevados de MSE e SSIM para as técnicas adaptativas são explicados pelo fato delas modificarem a estrutura da imagem. Por outro lado, os métodos que mais apresentam maiores similaridades não apresentam bons resultados visuais. Assume-se que quanto mais resultados perceptíveis forem obtidos através da Limiarização, maior vai ser a mudança estrutural da imagem.

6. CONCLUSÃO

Os resultados obtidos após a aplicação das técnicas de Limiarização, mostram que entre as 9 técnicas testadas, os métodos: adaptativos; mediana e global mostraram bons resultados na detecção de partes do olho e podem ser utilizadas como pré-processamento de imagens de retinografia. Elas podem ser combinadas entre si e com métodos mais complexos para o desenvolvimento de um sistema robusto que auxilie na detecção das estruturas oculares.

7. REFERÊNCIAS

- Adal, K.M. et al., 2013. Automated detection of microaneurysms using scale-adapted blob analysis and semi-supervised learning. *Computer Methods and Programs in Biomedicine*, 114(1), pp.1–10. Available at: <http://dx.doi.org/10.1016/j.cmpb.2013.12.009>.
- Akram, M.U. et al., 2015. Glaucoma detection using novel optic disc localization , hybrid feature set and classification techniques. *Australasian Physical & Engineering Sciences in Medicine*.
- Badsha, S., Reza, A.W. & Tan, K.G., 2013. A New Blood Vessel Extraction Technique Using Edge Enhancement and Object Classification. *Journal of Digital Imaging*, pp.1107–1115.
- Bao, X. et al., 2015. Segmentation of Retinal Blood Vessels Based on Cake Filter. *Biomedical Research International*, 2015, pp.1–11.
- Bendaoudi, H. et al., 2016. Flexible architectures for retinal blood vessel segmentation in high-resolution fundus images. *Journal of Real-Time Image Processing*.
- Carla, A. et al., 2015. A Multiscale Decomposition Approach to Detect Abnormal Vasculature in the Optic Disc. *Computerized Medical Imaging and Graphics*. Available at: <http://dx.doi.org/10.1016/j.compmedimag.2015.01.001>.
- Cheng, J. et al., 2013. Superpixel Classification Based Optic Disc and Optic Cup Segmentation for Glaucoma Screening. *IEEE Transactions on Medical Imaging*, 32(6), pp.1019–1032.
- Christodoulidis, A. et al., 2016. A multi-scale tensor voting approach for small retinal vessel segmentation in high resolution fundus images. *Computerized Medical Imaging and Graphics*, 52, pp.28–43. Available at: <http://dx.doi.org/10.1016/j.compmedimag.2016.06.001>.
- Díaz-pernil, D. et al., 2016. Fully automatized parallel segmentation of the optic disc in retinal fundus images ☆. *Pattern Recognition Letters*, 83, pp.99–107. Available at: <http://dx.doi.org/10.1016/j.patrec.2016.04.025>.
- Figueiredo, I.N. et al., 2015. Automated lesion detectors in retinal fundus images. *Computers in Biology and Medicine*, 66, pp.47–65. Available at: <http://dx.doi.org/10.1016/j.combiomed.2015.08.008>.

- Gegundez-arias, M.E. et al., 2013. Locating the fovea center position in digital fundus images using thresholding and feature extraction techniques. *Computerized Medical Imaging and Graphics*, 37(5–6), pp.386–393. Available at: <http://dx.doi.org/10.1016/j.compmedimag.2013.06.002>.
- Glasbey, C., 1993. An Analysis of Histogram-Based Thresholding Algorithms. , pp.532–537.
- Gonzales, R.C. & Woods, R.E., 2010. *Processamento Digital de Imagens* 3rd ed., Pearson.
- Gramatikov, B.I., 2014. Modern technologies for retinal scanning and imaging : an introduction for the biomedical engineer Modern technologies for retinal scanning and imaging : an introduction for the biomedical engineer. *BioMedical Engineering OnLine*, p.34.
- Gupta, G. et al., 2017. Local characterization of neovascularization and identification of proliferative diabetic retinopathy in retinal fundus images. *Computerized Medical Imaging and Graphics*, 55, pp.124–132. Available at: <http://dx.doi.org/10.1016/j.compmedimag.2016.08.005>.
- Gupta, N. et al., 2006. Human glaucoma and neural degeneration in intracranial optic nerve, lateral geniculate nucleus, and visual cortex. *The British journal of ophthalmology*, 90(6), pp.674–678.
- Jelinek, H.F. & Cree, M.J., 2010. *Automated Image Detection of Retinal Pathology*, Boca Raton: CRC Press.
- Klein, R., Moss, S.E. & Klein, B.E.K., 2015. Retinal Microaneurysm Counts and 10-Year progression of Diabetic Retinopathy. *Archives of Ophthalmology*.
- Kumar, V. & Gupta, P., 2012. Importance of Statistical Measures in Digital Image Processing. *International Journal of Emerging Technology and Advanced Engineering*, 2(8), pp.56–62.
- Kwon, Y.H. et al., 2009. Primary Open-Angle Glaucoma. *The New England journal of medicine*, 360(11), pp.1113–1124. Available at: <http://www.ncbi.nlm.nih.gov/pmc/articles/PMC3700399/>.
- Lalonde, M., Beaulieu, M. & Gagnon, L., 2001. Fast and Robust Optic Disc Detection Using Pyramidal Decomposition and Hausdorff-Based Template Matching. *IEEE transactions on medical imaging*, 20(11), pp.922–929.
- Mapayi, T., Viriri, S. & Tapamo, J., 2015. Adaptive Thresholding Technique for Retinal Vessel Segmentation Based on GLCM-Energy Information.

- COMPUTATIONAL AND MATHEMATICAL METHODS IN MEDICINE*, 2015, pp.1–11.
- Meier, P. & Leipzig, D.-, 1997. Vitrectomy for traction macular detachment in diabetic retinopathy. *Clinical & Experimental Ophthalmology*, pp.569–574.
- Meng, X. et al., 2015. A framework for retinal vasculature segmentation based on matched filters. *BioMedical Engineering OnLine*, pp.1–20.
- Mittapalli, P.S. & Kande, G.B., 2016. Segmentation of optic disk and optic cup from digital fundus images for the assessment of glaucoma. *Biomedical Signal Processing and Control*, 24, pp.34–46. Available at: <http://dx.doi.org/10.1016/j.bspc.2015.09.003>.
- Moghimirad, E., Hamid, S. & Soltanian-zadeh, H., 2012. Retinal vessel segmentation using a multi-scale medialness function. *Computers in Biology and Medicine*, 42(1), pp.50–60. Available at: <http://dx.doi.org/10.1016/j.combiomed.2011.10.008>.
- Morales, S., Engan, K. & Naranjo, V., 2015. Retinal Disease Screening through Local Binary Patterns. *IEEE JOURNAL OF BIOMEDICAL AND HEALTH INFORMATICS*, 0(0), pp.1–8.
- Morse, B.S., 2000. Thresholding. , pp.1–5.
- Nguyen, U.T. V et al., 2013. An Automated Method for Retinal Arteriovenous Nicking Quantification From Color Fundus Images. *IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING*, 60(11), pp.3194–3203.
- Noble, J. & Chaudhary, V., 2010. Diabetic retinopathy. *Canadian Medical Association Journal*, 182(15), p.90536.
- Oloumi, F., Ragayyan, R.M. & Ells, A.L., 2014. *Digital Image Processing for Ophthalmology - Detection and Modeling of Retinal Vascular Architecture* 1st ed. J. D. Enderle, ed., Morgan & Claypool Publishers.
- Owen, C.G. & Barman, S.A., 2012. Blood vessel segmentation methodologies in retinal images – A survey. *Computer Methods and Programs in Biomedicine*, 108(1), pp.407–433. Available at: <http://dx.doi.org/10.1016/j.cmpb.2012.03.009>.
- Patton, N. et al., 2006. Retinal image analysis : Concepts , applications and potential. *Progress in Retinal and Eye Research*, 25, pp.99–127.
- Prewitt, J.M.S. & Mendelsohn, M.L., The analysis of cell images*.
- Quigley, H.A., 2006. The number of people with glaucoma worldwide in 2010

- and 2020. *British Journal of Ophthalmology*, 90(3), pp.262–267. Available at: <http://bj.o.bmj.com/cgi/doi/10.1136/bjo.2005.081224>.
- Raja, D.S.S. & Vasuki, S., 2015. Automatic Detection of Blood Vessels in Retinal Images for Diabetic Retinopathy Diagnosis. *COMPUTATIONAL AND MATHEMATICAL METHODS IN MEDICINE*, 2015, pp.1–12.
- Rodrigues, L.C. & Marengoni, M., 2017. Segmentation of optic disc and blood vessels in retinal images using wavelets , mathematical morphology and Hessian-based multi-scale filtering. *Biomedical Signal Processing and Control*, 36, pp.39–49. Available at: <http://dx.doi.org/10.1016/j.bspc.2017.03.014>.
- Rogers, E. & Zack, G.W., 1977. Automatic Measurement of Sister Chromatid Exchange Frequency. *The Journal of Histochemistry and Cytochemistry*, 25, pp.741–753.
- Roychowdhury, S. et al., 2014. Blood Vessel Segmentation of Fundus Images by Major Vessel Extraction and Sub-Image Classification. *IEEE Journal of Biomedical and Health Informatics*, 2194(c), pp.1–11.
- Roychowdhury, S. et al., 2015. Optic Disc Boundary and Vessel Origin Segmentation of Fundus Images. *IEEE Journal of Biomedical and Health Informatics*, 2194(c), pp.1–12.
- Salazar-gonzalez, A. et al., 2014. Segmentation of Blood Vessels and Optic Disc in Retinal Images. *IEEE Journal of Biomedical and Health Informatics*, 2194(c), pp.1–14.
- Seoud, L. et al., 2015. Red Lesion Detection using Dynamic Shape Features for Diabetic Retinopathy Screening. *IEEE TRANSACTIONS ON MEDICAL IMAGING*, XX(XX), pp.1–11.
- Shapiro, L. & Stockman, G., 2000. *Computer Vision*, Prentice Hall.
- Singh, A. et al., 2015. Image processing based automatic diagnosis of glaucoma using wavelet features of segmented optic disc from fundus image. *Computer Methods and Programs in Biomedicine*, 124, pp.108–120. Available at: <http://dx.doi.org/10.1016/j.cmpb.2015.10.010>.
- Smith, P. et al., 1979. A Threshold Selection Method from Gray-Level Histograms. , C(1), pp.62–66.
- Srivastava, R. et al., 2016. Detecting Retinal Microaneurysms and Hemorrhages with Robustness to the Presence of Blood Vessels.

- Computer Methods and Programs in Biomedicine*. Available at:
<http://dx.doi.org/10.1016/j.cmpb.2016.10.017>.
- Staal, J. et al., 2004. Ridge-based vessel segmentation in color images of the retina. *IEEE Transactions on Medical Imaging*, 23(4), pp.501–509.
- Sun, J., Luan, F. & Wu, H., 2015. Optic Disc Segmentation by Balloon Snake with Texture from Color Fundus Image. *International Journal of Biomedical Imaging*, 2015, pp.1–14.
- Tham, Y.-C. et al., 2014. Global Prevalence of Glaucoma and Projections of Glaucoma Burden through 2040. *Ophthalmology*, 121(11), pp.2081–2090. Available at:
<http://linkinghub.elsevier.com/retrieve/pii/S0161642014004333>.
- Velasco, F.R.D., 1980. Thresholding using the ISODATA Clustering Algorithm. *IEEE TRANSACTIONS ON SYSTEMS, MAN AND CYBERNETICS*, (11), pp.771–774.
- Wang, Z. et al., 2004. Image Quality Assessment : From Error Visibility to Structural Similarity. *IEEE Transactions on Image Processing*, 13(4), pp.600–612.
- Wang, Z. & Bovik, A.C., 2009. Mean Squared Error: Love It or Leave It? , (January).
- Yadav, D., Sarathi, M.P. & Dutta, M.K., 2014. Classification of Glaucoma Based on Texture Features Using Neural Networks. , pp.0–3.
- Zhang, B., You, J. & Karray, F., 2012. Detecting Optic Disc on Asians by Multiscale Gaussian Filtering. *International Journal of Biomedical Imaging*, 2012.
- Zhang, L., Fisher, M. & Wang, W., 2015. Retinal vessel segmentation using multi-scale textons derived from keypoints. *Computerized Medical Imaging and Graphics*, 45, pp.47–56. Available at:
<http://dx.doi.org/10.1016/j.compmedimag.2015.07.006>.
- Zhu, C. et al., 2017. Computerized Medical Imaging and Graphics Retinal vessel segmentation in colour fundus images using Extreme Learning Machine. *Computerized Medical Imaging and Graphics*, 55, pp.68–77. Available at: <http://dx.doi.org/10.1016/j.compmedimag.2016.05.004>.
- Zilly, J., Buhmann, J.M. & Mahapatra, D., 2017. Glaucoma detection using entropy sampling and ensemble learning for automatic optic cup and disc

segmentation. *Computerized Medical Imaging and Graphics*, 55, pp.28–41.
Available at: <http://dx.doi.org/10.1016/j.compmedimag.2016.07.012>.

http://imagej.net/Auto_Threshold#Triangle 22/05

<http://forum.imagej.net/t/understanding-imagej-implementation-of-the-triangle-algorithm-for-threshold/752> 22/05

<http://www.mif.vu.lt/atpazinimas/dip/FIP/fip-Segmenta.html#Heading118> 22/05