

Universidade Federal Rural de Pernambuco
Departamento de Informática e Estatística
Mestrado em Biometria

**DETECÇÃO DE VASOS SANGUINEOS EM IMAGENS DE
FUNDO DE OLHOS**

SÉRGIO DE SÁ LEITÃO PAIVA JÚNIOR

RECIFE - PE

Fevereiro/2006

Universidade Federal Rural de Pernambuco
Departamento de Informática e Estatística
Mestrado em Biometria

DETECÇÃO DE VASOS SANGUINEOS EM IMAGENS DE
FUNDO DE OLHOS

SÉRGIO DE SÁ LEITÃO PAIVA JÚNIOR

Dissertação foi julgada adequada para obtenção do título de mestre em Biometria, defendida e aprovada por unanimidade em 17/02/2006 pela banca examinadora.

Orientador.:

Prof. Dr. Borko D. Stosic - UFRPE

Examinadores.:

Prof. Dr. Wilson Rosa de Oliveira Júnior - UFRPE

Prof. Dr. Romildo de Albuquerque Nogueira - UFRPE

Prof. Dr. Enivaldo Carvalho de Rocha - UFPE

RECIFE – PE, Fevereiro/2006

SÉRGIO DE SÁ LEITÃO PAIVA JÚNIOR

**DETECÇÃO DE VASOS SANGUINEOS EM IMAGENS DE
FUNDO DE OLHOS**

Dissertação apresentada a Universidade Federal Rural
de Pernambuco, para obtenção do título de Mestre em
Biometria, área de concentração Modelagem
Computacional

Orientador.: Prof.º Dr. Borko D. Stosic .

RECIFE
Estado de Pernambuco – Brasil
Fevereiro – 2006

A minha família, em especial à minha esposa Walquiria e meus filhos Marcos e Davi por terem sofrido comigo todas as lutas até aqui.. À minha mãe por sempre fazer o seu melhor me apoiando e incentivando, minhas irmãs, sogra e sogro.

DEDICO

AGRADECIMENTOS

A Deus pela inspiração, consolo e força na longa caminhada na vida e em especial neste projeto.

Ao meu orientado prof, Dr. Borko Stosic que acreditou em mim e me incentivou desde a graduação, onde iniciamos alguns trabalhos além de seu apoio e paciência. Trazendo sua grande experiência e fazendo-me ver que a ciência deve ser feita com prazer e não apenas por obrigação.

Ao coordenador do curso de Biometria. Professor Dr. Eufrazio de Souza e o secretário Marcos pela sua dedicação em fazer o melhor para o mestrado de forma incansável.

Aos professores do mestrado Gauss Moutinho, Paulo de Paula, Maria Adélia e Claudia por sua dedicação.

Aos meus professores e amigos Prof. Jones Albuquerque, Prof^a. Mara e Prof. Wilson Rosa que desde a época da graduação e de várias formas sempre demonstraram bastante competência, dedicação e disponibilidade.

Aos meus amigos Pablo, João e Edja, Wellington e família, Prof. Paulo Madruga, Profa. Tânia, Prof. Romero, Prof. Aldo, Prof. Domingos pelo incentivo e companheirismo em diversos momentos..

Aos meus colegas de turma Carlos, Antonio, Tony, Ady Marinho, Damocles, Arundo, Ilzes, Heliovânio, Herbets, Márcio, Cícero, Leonardo, Fábio, Franklin aos colegas da turma de 2005, obrigado pela amizade.

SUMÁRIO

LISTA DE FIGURAS.....	VI
RESUMO.....	VIII
ABSTRACT	IX
1. INTRODUÇÃO	1
2. REVISÃO BIBLIOGRÁFICA.....	3
2.1. ESTRUTURA DO OLHO HUMANO	4
2.2. COMPUTAÇÃO GRÁFICA.....	5
2.3. IMAGEM – UM MODELO MATEMÁTICO SIMPLES.....	5
2.4. RELACIONAMENTO ENTRE PIXELS.....	6
2.4.1. OS VIZINHOS DE UM PIXEL.....	6
2.4.2. CONECTIVIDADE.....	6
2.4.3. MEDIDAS DE DISTÂNCIA.....	7
2.5. SISTEMAS DE CORES.....	7
2.5.1. MODELO DE CORES RGB.....	8
2.5.2. MODELO DE CORES HSV.....	9
2.6. IMAGENS COLORIDAS.....	11
2.7. PROCESSAMENTO DE IMAGENS DIGITAIS.....	12
2.8. SUBTRAÇÃO DE IMAGENS.....	12
2.9. HISTOGRAMA DE CORES.....	13
2.10. NORMALIZAÇÃO DO HISTOGRAMA DE CORES.....	14
2.11. FILTRAGEM.....	15
2.11.1. DOMÍNIOS DA FILTRAGEM:.....	16
2.11.2. FILTRAGEM NO DOMÍNIO ESPACIAL.....	16
2.11.3. FILTRAGEM NO DOMÍNIO DE FREQUÊNCIA.....	17
2.12. TRANSFORMADA DE FOURIER.....	17
2.13. FILTROS NÃO LINEARES.....	19
2.14. FILTRO PASSA-ALTA.....	20
2.15. FILTRAGEM DE ALTO ESFORÇO.....	20
2.16. FILTROS ESTATÍSTICOS.....	21
2.16.1. FILTRO GAUSSIANO.....	22
2.16.2. FILTRO DA MEDIANA.....	23
2.16.3. FILTRO DE KUWAHARA.....	24
2.16.4. FILTRO DE NAGAO-MATSUYANA.....	25
2.17. DETECÇÃO DE BORDAS.....	25
2.17.1. OPERADORES DE GRADIENTE:.....	28
2.17.2. OPERADORES DE SOBEL.....	29
2.17.3. OPERADOR DE ROBINSON.....	30
2.17.4. FILTRO DE CANNY.....	31
2.17.5. LAPLACIANO.....	33
2.18. SEGMENTAÇÃO DE IMAGENS.....	33
2.19. ESQUELETIZAÇÃO:.....	34
3. MATERIAIS E MÉTODOS.....	36
3.1. CORRELAÇÃO.....	38
3.2. DETECÇÃO DE USANDO FILTRO GAUSSIANO.....	39
3.2.1. CONSTRUÇÃO DA MÁSCARA DO FILTRO GAUSSIANO.....	41

3.3.	O OPERADOR LAPLACIANO.....	42
3.4.	DETECÇÃO DE BORDAS UTILIZANDO OPERADOR DE ROBERT.....	43
3.5.	ALGORITMO DE PERCOLAÇÃO DE HOSHEN-KOPELMAN.....	44
3.5.1.	ADAPTAÇÃO DO ALGORITMO DE HOSHEN-KOPELMAN PARA A SEGMENTAÇÃO DA IMAGEM.....	46
3.5.2.	ROC ANALYSIS.....	47
4.	RESULTADOS E DISCUSSÃO	51
5.	CONCLUSÃO.....	56
6.	REFERÊNCIAS BIBLIOGRÁFICAS	57

LISTA DE FIGURAS

Figura		Página
01	Olho visto de frente.....	04
02	Vista lateral do Olho.....	04
03	Imagem da Retina.....	04
04	Processo aditivo na formação de cores.....	08
05	Espaço no modelo RGB.....	09
06	Espaço no modelo HSV.....	10
07	Imagem do fundo de olho decomposta em suas bandas RGB.....	12
08	Subtração de imagens.....	13
09	Imagem de fundo de olho e seus histogramas separados por RGB.....	14
10	Imagem antes e depois do processamento de normalização.....	15
11	Processamento de filtragem domínio de frequência.....	17
12	Efeito de transformação de sinais por Fourier.....	19
13	Efeito do filtro Passa-Alta.....	20
14	Efeito do Filtro Alto-Esforço com $A=1.15$	21
15	Exemplo de uma máscara ou janela.....	22
16	Exemplo de uma Máscara	22
17	Ação do Filtro Gaussiano sobre uma imagem.....	23
18	Imagem com ruído tratado com um filtro da média.....	24
19	Regiões do filtro de Kuwahara.....	24
20	Filtro de Kuwahara aplicado sobre uma região ruidosa.....	25
21	Regiões do filtro de Nagao-Matsuyana.....	25
22	Uma borda de imagem, o perfil de uma linha horizontal, sua primeira e segunda derivadas.....	26
23	Tipos de Bordas.....	27
24	Representação gráfica do nível de cor através de um plano	27
25	Máscara do operador de Sobel.....	29
26	Aplicação do Detector de borda de Sobel.....	30
27	Máscara do operador de Robson.....	30
28	Aplicação do Detector de Borda de Robson.....	31
29	Detecção de bordas por Canny.....	32
30	Processamento de Esqueletização.....	35

31	Original de uma retina com aspecto normal.....	37
32	-Segmentação manual	37
33	Gráfico do perfil de dois vasos	40
34	Máscara gerada a partir do Software RAS.....	41
35	Imagem submetida à máscara gaussiana 2d matched filter..	42
36	Imagem após processamento “2d matched filter” com o respectivo histograma.....	42
37	Imagem após processamento laplaciano com o respectivo histograma.....	43
38	Máscara de Robert.....	44
39	Imagem do fundo do olho após o processamento de detecção de borda. Observe no detalhe ampliado que vários pontos são detectados fora da rede de vasos que compõe a imagem.....	45
40	Reticulados antes e depois do algoritmo de Hoshen- Kopelman.....	46
41	Modificação algoritmo Hoshen-Kopelman.....	47
42	Imagem mostrando a aplicação do algoritmo de Hoshen- Kopelman, Acima a imagem antes e abaixo a imagem após a passagem do algoritmo.....	48
43	Curva ROC.....	50
44	Bom classificador, Péssimo Classificador e mal classificador.....	51
45	Amostra 25.....	54
46	Amostra 21.....	54
47	Amostra 24.....	54
48	ROC Analysis - $A_z=0,9202$	55
49	ROC Analysis 2d Matched Filter - $A_z=0,8936$	56

DETECÇÃO DE VASOS SANGUÍNEOS EM IMAGENS DE FUNDO DE OLHO

Autor: Sérgio de Sá Leitão Paiva Júnior

Orientador: Dr. Borko D. Stosic

RESUMO

Descrevemos neste trabalho um método automático para localizar e segmentar vasos sanguíneos em imagens de fundo de olhos. Este método pode ser usado por um software especialista em imagens de retina para diagnosticar automaticamente doenças como retinopatia diabética entre outras, para avaliação da evolução do tratamento, e para estudos clínicos. O método proposto é baseado na combinação do procedimento “2d matched filter” (usado na localização dos vasos) com o algoritmo de “Hoshen-Kopelman” (usado na segmentação dos vasos). Resultados obtidos com este método foram comparados, com a segmentação manual em 20 imagens do projeto DRIVE, usando ROC (Receiver Operating Characteristic curve) para comparação quantitativa com os resultados de outros trabalhos publicados sobre este assunto.

DETECTION OF BLOOD VESSEL IN RETINAL IMAGES

Author: Sérgio de Sá Leitão Paiva Júnior

Thesis advisor: Dr. Borko D. Stosic

ABSTRACT

We describe an automated method for blood vessel segmentation in two-dimensional color retinal images. This method may be used by specialized software for automated screening of diabetic rethinopathy and other eye diseases, for evaluation of treatment evolution, and clinical study. The proposed method is based on a combination of “2d matched filter” response procedure (for vessel location), and the Hoshen-Kopelman algorithm (for vessel segmentation). We compare the results obtained through this method with the results of manual segmentation of 20 imagens of the DRIVE project, where ROC (Receiver Operating Characteristic curve) analysis was used for quantitative comparison with others works published on this subject.

1. INTRODUÇÃO

A rede de vasos sanguíneo formado na parte interna do olho é um indicador importante de muitas patologias oculares incluindo diabetes, hipertensão e arterioscleroses. Uma doença ocular, como retinopatia diabética, pode levar a cegueira, porém em 90% dos casos o diagnóstico precoce evita a cegueira em quase 100% dos casos[1]. O principal problema é que muitas destas doenças não são acompanhadas de dor, e em alguns casos, apenas de baixa de visão. Isto dificulta o diagnóstico precoce aumentando o risco de cegueira.

Veias e artérias têm alguns aspectos que podem ser observados pelo especialista para um diagnóstico correto. Estes aspectos também podem ser medidos ou tratados computacionalmente por um processamento correto da imagem objetivando a detecção de possíveis anomalias. Estes tratamentos incluem a medição do diâmetro dos vasos, cor, tortuosidade, opacidade, fractalidade, etc.

A imagem obtida da retina humana apresenta uma estrutura bastante complexa, pois a retina é composta de vários elementos e estes estão distribuídos por toda a sua superfície. Vasos sanguíneos se apresentam nesta imagem como uma rede que cresce sempre partindo de um ponto (Disco Ótico) e segue por toda a retina em segmentos que tem direção aleatória. Estes vasos são responsáveis pela irrigação sanguínea para as células do olho. Associado a rede de vasos temos a fóvea, e o nervo óptico (Disco Ótico), elementos estes que são visíveis através da imagem da retina

Para que qualquer análise automática da imagem da retina seja realizada faz-se necessário que a imagem seja submetida a um processamento que possa detectar e separar a imagem original dos elementos a serem analisados automaticamente. Este procedimento é uma condição inicial e pode ser realizado manualmente, utilizando para isto ferramentas gráficas e pessoas qualificadas para a realização da segmentação, ou então uma técnica apropriada de processamento digital de imagem.

No Processamento Digital de Imagens (PDI), importante subdivisão da área de Processamento Digital de Sinais, imagens de entrada são processadas, gerando imagens como produto final. O PDI pode incluir etapas de visão computacional e de computação gráfica. Desde que a entrada e a saída do sistema envolvam imagens, o trabalho global é fundamentalmente de PDI. O PDI é altamente multidisciplinar, envolvendo diversos aspectos e conceitos de ótica, eletrônica, matemática, estatística, fotografia e computação.

Na utilização de Processamento digital de imagem, busca-se uma classificação ótima para os vasos, sendo que podemos ter como parâmetro para comparação da qualidade desta segmentação, os resultados obtidos pela segmentação manual da imagem. Evidentemente que este método comparativo somente pode ser aplicado para validar a técnica de segmentação.

Neste trabalho descrevemos um procedimento que envolve 3 etapas.: Técnicas de pré-processamento de imagem; Detecção de vasos sanguíneos e segmentação em imagens de olhos humanos. Uma boa técnica aplicada à detecção é conhecida como “2d matched filter” que, no nosso trabalho, será utilizada juntamente com o algoritmo de percolação de Hoshen-Kopelman modificado para melhorar a performance neste tipo de imagem. Este algoritmo é utilizado como base para uma análise de agrupamento. Os pixels agrupados em clusters (aglomerados) menores e que podem ser confundidos com ruídos ou comprometer a conectividade dos vasos, irão ser excluídos, restando apenas os que são relevantes para o resultado esperado.

Ao final do trabalho esperamos obter uma imagem segmentada automaticamente (sem nenhuma intervenção humana), que tenha uma boa qualidade para ser utilizada como base em algoritmos ou técnicas de mensuração de características relevantes e que possua uma grande conectividade entre os pixels pertencentes à rede de vasos.

2. REVISÃO BIBLIOGRÁFICA.

Muitas técnicas foram e estão sendo propostas para tratar o problema da segmentação das imagens de fundo de olho. Juntamente com o aparecimento destas técnicas observamos que outros problemas estão sendo atacados, como por exemplo, a distinção entre veias e artérias na imagem [10]. A maioria das técnicas implementa algoritmos baseados em características intrínsecas da imagem e as relações entre pixels que são próprias da imagem. Neste tipo de abordagem geralmente são consideradas apenas relações entre pixels vizinhos sem considerar informações globais da imagem, apesar de que considerações sobre propriedades globais de imagem podem melhorar o desempenho de tais técnicas. Em particular, técnicas de pré-processamento realizadas na imagem toda, como por exemplo normalização dos pixels, podem melhorar o contraste, enfatizar detalhes relevantes, etc.

Duas estratégias tem sido usadas para realização da tarefa de extração dos vasos sanguíneos, uma é a utilização de filtros para a localização de pixels que pertençam à rede de vasos e outra técnica complementar é a utilização de algoritmos que começam a tratar a imagem com a informação, a priori, do filtro utilizado na primeira etapa [3].

Estas técnicas utilizadas juntas se justificam pois a utilização de um filtro na imagem gera uma quantidade de ruído. Este ruído pode ser muito grande dependendo do filtro e dos parâmetros utilizados, logo, um algoritmo apropriado pode percorrer os vasos, excluindo da imagem possíveis ruídos gerados na etapa de localização dos pixels da rede de vasos.

Neste capítulo iremos introduzir conceitos relacionados a imagens digitais e técnicas de processamento de imagem pertinentes ao assunto abordado.

2.1. Estrutura do olho humano

O olho humano é aproximadamente esférico, com diâmetro médio em torno de dois centímetros. Algumas estruturas externas e internas do olho humano podem ser observadas na Figura 1 e na Figura 2. Os raios luminosos provenientes dos objetos externos penetram no olho através de uma abertura frontal na íris, a pupila, e de uma lente denominada cristalino, atingindo a retina, que constitui a camada interna posterior do globo ocular. Quando o olho está apropriadamente focalizado, forma-se uma imagem nítida invertida do cenário externo sobre a retina.

A figura 3 mostra uma foto digital de uma retina humana de aspecto normal retirada por uma câmera especial. Nesta imagem podemos detectar claramente as estruturas presentes na retina (Rede de vasos sanguíneos, fóvea e nervo óptico).

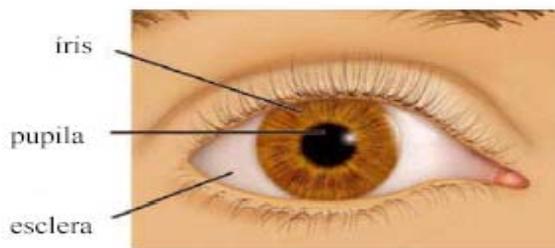


Fig 1 – Olho Visto de Frente

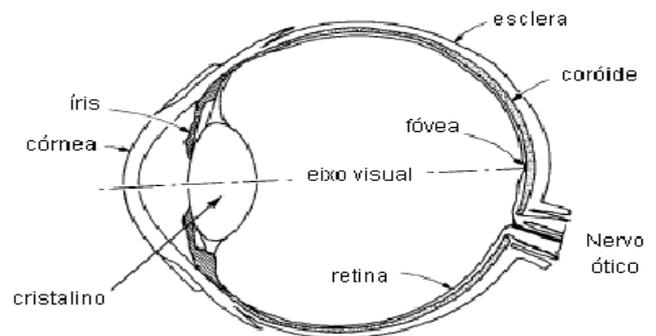


Fig 2 – Olho lateral

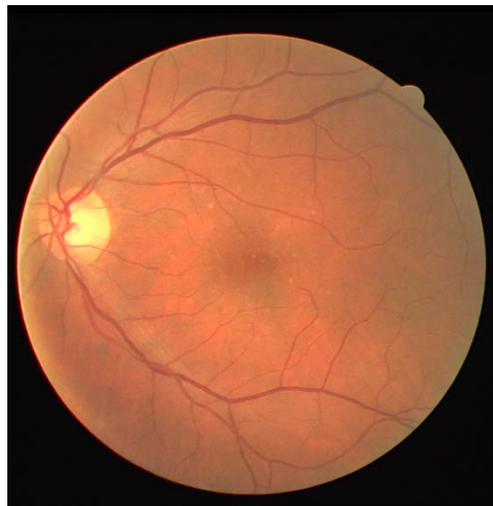


Fig 3 – Imagem da Retina

2.2. Computação gráfica

Segundo a ISO (International Organization for Standardization), a definição de computação gráfica é: “Um conjunto de ferramentas e técnicas para converter dados para (ou de) um dispositivo gráfico através do computador”. A computação gráfica juntamente com técnicas matemáticas, computacionais e estatísticas permite que seja feita uma abordagem mais correta de fenômenos existentes na natureza. O processamento de imagem trabalha com problemas relacionados à melhoria da qualidade da imagem bem como na obtenção de dados a partir da imagem.

2.3. Imagem – um modelo matemático simples.

O termo imagem refere-se a uma função de intensidade luminosa bidimensional, denotada por $f(x,y)$ em que o valor de $f(x,y)$ nas coordenadas espaciais (x,y) dá a intensidade da imagem naquele ponto.

Para ser adequada para processamento computacional, uma função $f(x,y)$ precisa ser digitalizada tanto espacialmente como em intensidade. A digitalização em coordenadas espaciais (x,y) é chamada de amostragem da imagem e a quantização em níveis de cor (ou níveis de cinza para imagens monocromáticas) é chamada de quantização. Suponha que uma imagem contínua $f(x,y)$ é aproximada por amostras igualmente espaçadas arranjadas na forma de uma matriz $N \times M$.

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,M-1) \\ f(1,0) & f(1,1) & \dots & f(1,M-1) \\ \dots & \dots & \dots & \dots \\ f(N-1,0) & f(N-1,1) & \dots & f(N-1,M-1) \end{bmatrix}$$

O lado direito da equação acima representa o resultado da discretização espacial e de brilho de uma imagem. Cada elemento $f(x,y)$ da matriz é conhecido por pixel (contração de *picture element*). Uma imagem monocromática apresenta unicamente graduações de cinzas sendo que um pixel preto tem valor zero e pixel branco tem valor $L-1$ onde L é a precisão da quantização da imagem, normalmente os valor de $L=256$ e $f(x,y) = \{0..255\}$. para imagens monocromáticas.

2.4. Relacionamento entre pixels

Vamos considerar diversos relacionamentos que são importantes entre pixels. Uma imagem será representada por $f(x,y)$ (mesmo para imagens coloridas).e os pixels serão referenciados por letras minúsculas.

2.4.1.Os vizinhos de um pixel.

Um pixel p nas coordenadas (x,y) possui quatro vizinhos horizontais e verticais, cujas coordenadas são:

$$(x+1,y)(x-1,y)(x,y+1)(x,y-1)$$

Este conjunto de pixel é chamado de vizinhos-de-4 de p . Cada pixel está a uma distância de p e alguns ficarão fora da imagem se (x,y) estiver na borda da imagem. Existe também os 4 vizinhos da diagonal de p , cujas coordenadas são.

$$(x-1,y-1)(x-1,y+1)(x+1,y-1)(x+1,y+1)$$

Juntamente com os vizinhos-de-4, este conjunto de pixels é chamado de vizinhos-de-8 do pixel p .

2.4.2.Conectividade

A conectividade entre pixels é um conceito importante usado no estabelecimento das bordas de objetos e componentes de região. Para estabelecer se dois pixels estão conectados é necessário determinar se eles são de alguma forma adjacentes (digamos se são vizinhos de-4), se os níveis de cor (ou de cinza) satisfazem a algum critério de similaridade.

Este critério de conectividade tem papel central nos algoritmos de agrupamento, através delas são definidos critérios para avaliar se dois pontos estão próximos e se, portanto, fazem parte de um mesmo grupo. Estes grupos podem definir uma determinada região de interesse na

imagem, como por exemplo, pixels que pertençam a uma rede de vasos conectados entre si por um determinado critério de conectividade.

2.4.3. Medidas de Distância.

Para os pixels p, q, z com coordenadas $(x, y), (s, t), (u, v)$ respectivamente, D é uma função de distância ou medida de dissimilaridade ou métrica se:

1. $D(p, q) \geq 0$
2. $D(p, q) = D(q, p)$
3. $D(p, z) \leq D(p, q) + D(q, z)$

A distancia euclidiana entre p e q é definida como.

$$D(p, q) = \left[(x - s)^2 + (y - t)^2 \right]^{1/2}$$

Para essa medida de distância os pixels tendo uma distância de (x, y) menor ou igual a algum valor r são os pontos contidos em um disco de raio r centrado em (x, y) .

A distância definida como D_4 (ou distancia quarteirão) é dada pela expressão abaixo:

$$D_4(p, q) = \left[|x - s| + |y - t| \right]$$

Neste caso os pixels cuja distância sejam menor ou igual a um valor r formam um losango em torno de (x, y) , particularmente se $r = 1$ então os pixels são vizinhos de 4 de (x, y) .

A distância chamada de D_8 (ou distância xadrez) é definida como:

$$D_8(p, q) = \text{Max} \left[|x - s|, |y - t| \right]$$

Particularmente para distância $D_8(p, q) = 1$ os pixels são os vizinhos de 8 de (x, y) .

2.5. Sistemas de Cores

A cor de um objeto que emite radiação na faixa visível é definida pela soma das cores espectrais emitidas. O processo de formação de cores, neste caso, é aditivo. Dado o mecanismo de formação de cores do olho humano, o processo aditivo pode ser entendido como uma combinação de radiações monocromáticas nas faixas verde, vermelho e

azul, em proporções variáveis. Por este motivo, estas cores são denominadas cores primárias da luz.

Este processo de geração de cores caracteriza o sistema RGB (Red, Green, e Blue). A Comissão Internacional de Iluminação (CIE) estabeleceu os seguintes valores para os comprimentos de onda das primárias da luz:

- Azul: 435,8 nm
- Verde: 546,1 nm
- Vermelho: 700 nm

As cores primárias combinadas duas a duas em igual intensidade produzem as cores secundárias da luz, magenta, ciano e amarelo:

- Magenta = Vermelho + Azul
- Ciano = Azul + Verde
- Amarelo = Verde + Vermelho

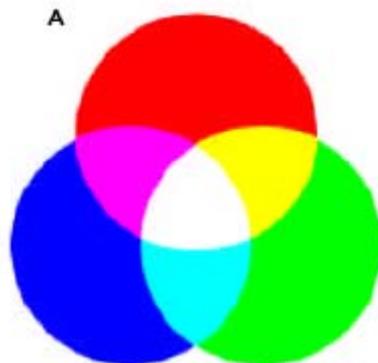


Fig 4 – Processo aditivo na formação de cores

2.5.1. Modelo de Cores RGB

No modelo RGB (Red, Green, Blue), cada cor aparece nos seus componentes vermelho, verde e azul. No espaço RGB (ver figura 5) a diagonal definida pelo conjunto de pontos (i, i, i) é chamada de reta acromática. Pontos sobre a reta acromática representam tonalidades de cinza, ou níveis de cinza, variando continuamente do preto ao branco, à medida que percorremos a reta a partir da origem. O ponto $(0, 0, 0)$ representa o preto (ausência de luz). Um ponto (L, L, L) , onde L é a intensidade máxima que pode assumir qualquer componente de cor,

representa o branco. Outras intensidades de cores estão distribuídas no espaço do cubo.

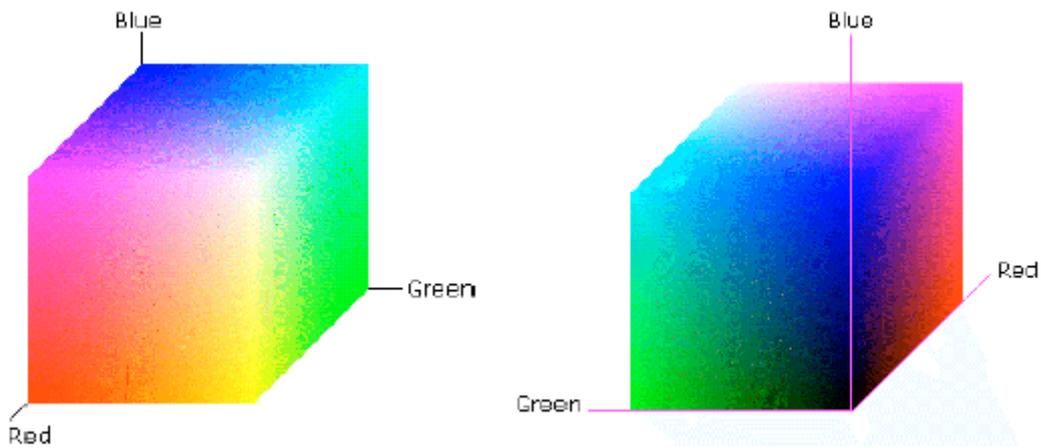
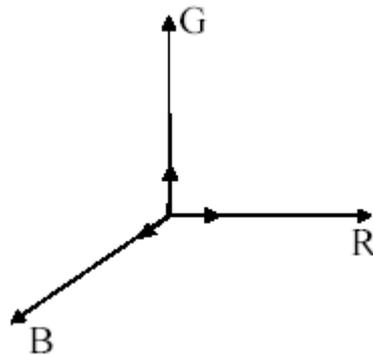


Fig 5 – Espaço do modelo RGB

2.5.2. Modelo de Cores HSV

O modelo de cores HSV (Hue, Saturation, Value - Cor, Saturação, Valor) possui o apelo intuitivo das designações matiz (análoga à cor), sombra (análoga à saturação) e tonalidade (análoga ao valor), provenientes da manipulação de tintas [4]. Na Figura abaixo, podem ser observadas duas representações tridimensionais do modelo HSV.

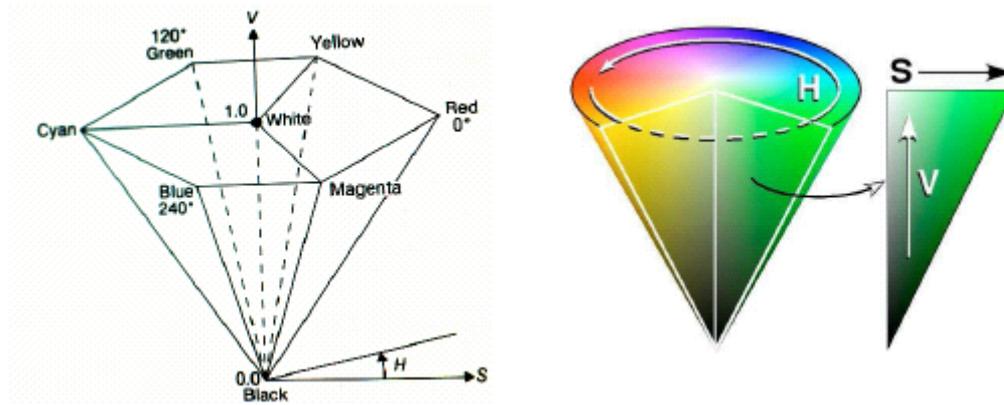


Fig 6 – Espaço do Modelo HSV

O sistema de coordenadas usado no modelo de cores HSV é cilíndrica. Utilizando como referência a Figura acima, vemos que a componente H assume valores angulares no sistema de coordenadas cilíndricas (no intervalo $[0,360]$), a componente S assume valores lineares ao longo do raio do cone (no intervalo $[0,1]$), e a componente V assume valores lineares ao longo do eixo do cone (no intervalo $[0,1]$). No vértice do cone, o valor (V) é igual a zero (o que corresponde à cor preta); Na base do cone, onde estão as cores com maior brilho, $V=1$ (para $S=0$, temos a cor branca). Cabe lembrar que, no plano onde $V=1$, as cores não possuem necessariamente o mesmo brilho percebido [4]. Ao longo do eixo do cone situam-se os tons de cinza. A cor (H) é definida por um valor angular (Figura 6): um ângulo igual a zero corresponde à cor vermelha; um ângulo de 120° corresponde à cor verde, e assim por diante.

Quando a saturação (S) vale zero, o valor da cor (H) torna-se irrelevante, sendo tratado como "indefinido". Quando $V=1$ e $S=1$, todos os valores angulares assumidos por H corresponderão às cores puras (por exemplo, se temos $V=1$, $S=1$ e $H=0$, temos o vermelho puro). Esse fato é análogo ao pigmento puro das tintas, utilizado pelos artistas como ponto inicial para a mistura das cores [4]. Assim, um pintor que quisesse decrementar a saturação (S), adicionaria um pigmento branco à cor pura (sem alterar o valor (V)). Sombras são criadas mantendo-se $S=1$ e decrementando V. Finalmente, diversos tons podem ser criados pela diminuição dos valores de S e de V. Tudo isso levando em

consideração que uma mudança em H equivale à uma mudança no pigmento de cor puro inicial.

Por utilizar uma maneira para representar as cores baseada na percepção humana, e também por fornecer um componente para a cor (H) que independe das magnitudes da saturação (S) e de valor (V) (mesmo quando o valor de H torna-se "indefinido", ainda assim ele permanece independente), o modelo de cores HSV é um modelo mais adequado do que o RGB quando o processamento de imagens envolve algum passo fundamental que necessite que objetos sejam encontrados na imagem através de suas cores. Isso significa dizer que a cor (H) dos objetos de uma imagem é invariante às mudanças de luz presentes nessa imagem (que, por sua vez, são definidas por S e por V) - o que facilita que uma área de determinada cor seja identificada na imagem, independentemente das condições de iluminação na superfície dessa área [16].

2.6. Imagens Coloridas

Em uma imagem digital colorida no sistema RGB, pode-se considerar um pixel como um vetor $f(x,y) = (f_r(x,y), f_g(x,y), f_b(x,y))$, cujas componentes representam as intensidades da cor vermelho, verde e azul. Pode-se considerar, portanto, que uma imagem colorida é a composição de três imagens monocromáticas, $f_r(x,y)$, $f_g(x,y)$, $f_b(x,y)$, denominadas, respectivamente, de banda vermelha (ou banda R), banda verde (ou banda G), e banda azul (ou banda B) da imagem colorida, conforme ilustra a Figura 7. Esta figura pretende destacar que os valores dos pixels nas bandas R, G e B representam de fato níveis de vermelho, verde e azul, respectivamente. Para cada banda, valem os mesmos conceitos apresentados para a imagem digital monocromática. A amostragem é quase sempre efetuada de forma idêntica em todas as bandas.

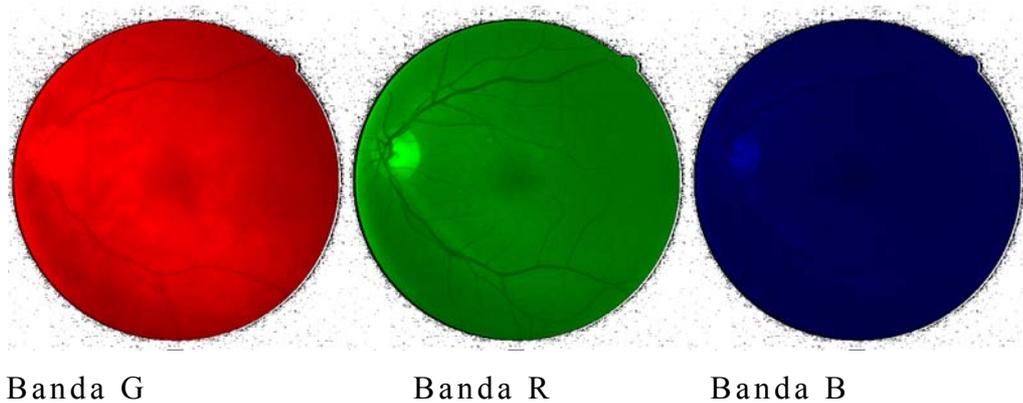


Fig 7 – Imagem do fundo de olho decomposto em suas bandas de frequência R,G,B.

2.7. Processamento de Imagens Digitais

Técnicas de processamento de imagens vem sendo aperfeiçoadas cada vez mais, pois as aplicações se difundem em várias áreas do conhecimento, tais como: Medicina no processamento de imagens do corpo humano (raio X, ultra-sonografia,tomografia,etc). Os geógrafos usam imagem para mapear áreas, a industria para melhoramento de produtividade e qualidade dos produtos, etc...

2.8. Subtração de Imagens

A diferença entre duas imagens $f(x,y)$ e $h(x,y)$ expressa como:

$$g(x,y) = f(x,y) - h(x,y)$$

É obtida através da diferença entre todos os pares de pixels correspondentes de f e h . A subtração de imagens tem numerosas aplicações em segmentação e realce de imagens. Em imagens médicas esta técnica é utilizada para realçar uma determinada região onde foi aplicado um contraste. A imagem obtida a partir da diferença entre as imagens antes da aplicação do contraste e após a aplicação, realça aspectos pouco visíveis. A figura abaixo mostra o resultado de uma segmentação manual de uma imagem de fundo de olhos subtraída da imagem original que gerou a segmentação:

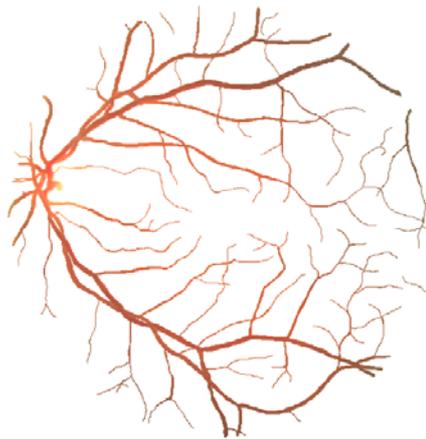


Fig 8 – Subtração de imagens

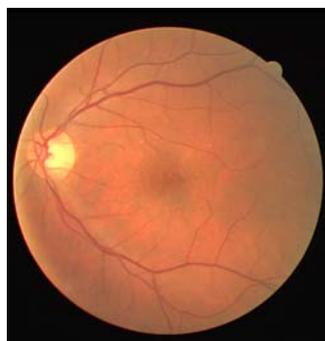
2.9. Histograma de Cores

O histograma de uma imagem digital com níveis de cor no intervalo $[0, L-1]$ é uma função discreta:

$$p(k) = \frac{n_k}{n}, k = 0, 1, \dots, L-1$$

Onde K é o k -ésimo nível de cor, n_k é o número de pixels na imagem com esse nível e n é o número total de pixels na imagem, ou seja $p(K)$ é uma estimativa da probabilidade da ocorrência do nível de cor r_k . Um gráfico dessa função para todos os valores de k fornece uma descrição global da aparência da imagem.

O histograma abaixo, referente a imagem de fundo de olho, nos fornece informações sobre contraste e intensidade das cores vermelho, verde e azul



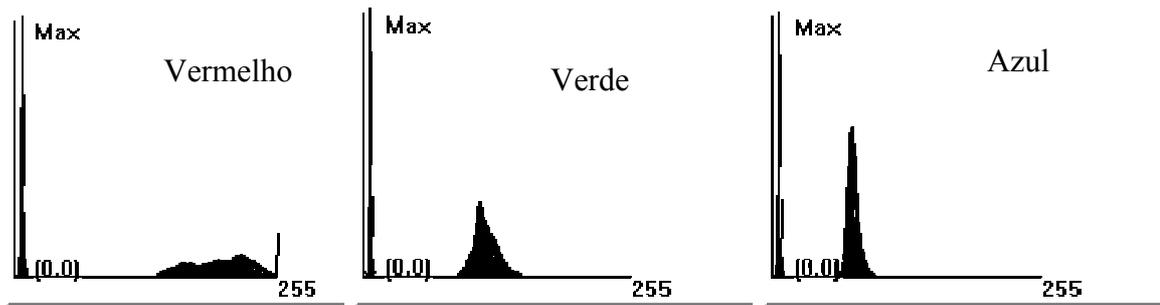


Fig 9 – Imagem original e seus histogramas de cores Vermelho, Verde e Azul.

Uma análise deste histograma nos indica que este tipo de imagem tem um contraste maior na cor vermelha pois os níveis de cor do componente vermelho nos pixels estão mais dispersos, com valores localizados próximos a 255, o que indica que nesta cor a imagem é mais clara do que escura.

Verificamos também a presença de muitos valores próximos a zero, estes valores são os pontos ,mais escuros na imagem.

Os contrastes nos níveis verde e azul, com relação a toda imagem, são menores (forma alongada do gráfico).

2.10. Normalização do Histograma de Cores

O processo de normalização da imagem consiste em escalonamento de cada um dos três planos de cores, em relação a um valor médio. Para cada componente, histograma de valores de pixels (elementos de imagem) foi construído, para determinar o valor médio desta cor. Em seguida, valores mínimos $x_{\min}(i)$ e máximo $x_{\max}(i)$ de escala que contem uma certa quantidade de informação (e.g. 99%) são determinados iterativamente para cada cor i (vermelho, verde, azul), representando posições simétricas inferior e superior em torno da média. Valores de todos pixels sofrem uma transformação linear, que mapeia valores $0 \leq p(i,x,y) \leq 255$ para $x_{\min}(i) \leq p'(i,x,y) \leq x_{\max}(i)$.

$$P'(i, x, y) = \frac{(P(i, x, y) - x_{\min}(i)) * 255}{X_{\max}(i) - X_{\min}(i)}$$

onde $P(i,x,y)$ representa valor de cor i na posição (x,y) antes de transformação, e $P'(i,x,y)$ e valor depois de transformação. A imagem abaixo demonstra o resultado neste caso preservando o componente azul (fator = 1) da imagem e com fator de 0.99 para o componente vermelho e 0.99 para o componente verde ($rgb = (0.99,0.99,1)$).

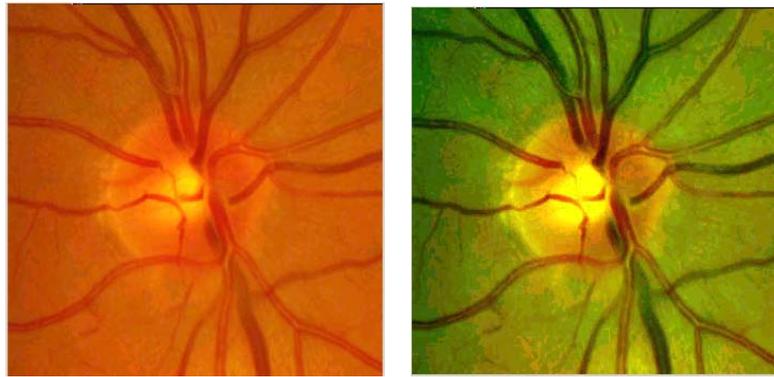


Fig 10 – Imagem Antes e depois do processamento de normalização dos níveis de cor

2.11. Filtragem.

Entende-se um filtro como uma transformação ou operador que mapeia uma seqüência de entrada $f(x)$ em uma seqüência de saída $g(x)$. Sobre esta transformação podem ser colocadas diversas restrições que propicia a definição de várias classes de sistemas como por exemplo: Lineares, não-lineares e invariantes a uma operação.

Um sistema discreto é linear se a resposta para a transformação de dois sinais de entrada, $f(x)$ e $f'(x)$, ponderados por um certo peso “C” pode ser obtida a partir da ponderação da transformação independente dos sinais originais.

$$\psi(f(x)*C; f'(x)*C)=C*\psi(f(x); f'(x))$$

Desta forma define-se um sistema não-linear os sistemas que não atendem a característica de linearidade citada acima. A partir do exposto concluímos que num sistema linear a operação pode ser

invertida enquanto que nos sistemas não-lineares a operação não pode ser invertida.

Um filtro numérico vai influenciar a variação da frequência espacial em uma imagem. Na frequência temporal, a escala usada é geralmente o Hertz (s^{-1}), em uma imagem usamos o 1/metro (m^{-1}) ou 1/pels (pix^{-1}). O termo frequência espacial é análogo ao termo frequência temporal e ela descreve a velocidade da modificação de uma luminosidade em uma direção na imagem.

Em geral uma filtragem em imagens digitais tem como objetivo preparar a imagem de uma forma mais específica para um determinado tratamento sendo, assim, bastante dependente da aplicação a que se destina.

Nas imagens de fundo de olho que estamos tratando, alguns filtros são importantes tanto para realçar aspectos pouco visíveis, como para preparar a imagem para a segmentação aplicando-se um determinado critério.

2.11.1.Domínios da Filtragem:

As técnicas de filtragem para imagens digitais podem ser classificadas em dois grupos distintos no que diz respeito ao domínio de aplicação do filtro. Existem os métodos de filtragem no domínio espacial e os métodos de filtragem no domínio de frequência.

2.11.2.Filtragem no domínio Espacial.

Os métodos de filtragem no domínio espacial atuam diretamente sobre a matriz de pixels da imagem, assim estes filtros podem ser definidos como:

$$g(x,y)=\psi[f(x)]$$

Onde $g(x,y)$ é a imagem resultado ou de saída, $f(x)$ é a imagem original ou de entrada e ψ é o operador da filtragem definido tipicamente em uma vizinhança de (x,y) .

2.11.3. Filtragem no Domínio de Frequência.

Utilizado para realizar segmentação ou realce, vários filtros utilizam informações sobre as frequências das cores, tais como transformada de Fourier de uma imagem ou a transformada cosseno discreta. Estas técnicas geram um conjunto de coeficientes a partir dos quais é possível eliminar ou realçar (conforme o caso) faixas de frequências numa imagem. Estas técnicas dão origem aos filtros passa baixa, passa alta, passa banda, etc..

Esta retirada de informações pode melhorar a detecção de determinadas características uma vez que o espaço dimensional da imagem pode ser reduzido. Estas técnicas são comumente utilizadas em processamento de imagem na área de visão computacional.

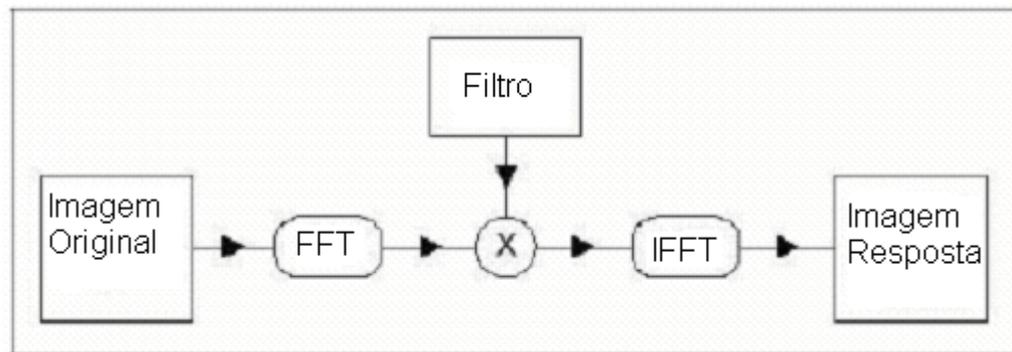


Fig 11- processamento de filtragem em domínio de Frequência

2.12. Transformada de Fourier

Joseph Fourier deixou para a matemática um rico legado: a transformada que leva o seu nome é utilizada em diversas áreas da ciência e tecnologia hoje em dia. Sua aplicação em processamento de imagens tem elevada importância, desde a simples filtragem até a utilização na compressão de arquivos de imagem.

Dentre as principais aplicações da transformada de Fourier, encontra-se análise, reconstrução e compressão de imagens, bem como o reconhecimento de padrões e objetos. Detalhes destas aplicações podem ser vistos em [17][06].

Através da transformada de Fourier pode-se decompor um sinal em seus componentes de frequência (senos e cossenos), de forma que um coeficiente de Fourier reflete a importância de determinada frequência para o sinal.

Dado um sinal contínuo e unidimensional $x(t)$, sua transformada de Fourier é definida por:

$$y(f) = F(x(t)) = \int x(t) \cdot e^{-i2\pi ft} dt$$

Em que f denota a frequência e t o tempo. Uma condição suficiente para a existência da transformada de Fourier de um sinal é que ele seja integrável, ou seja:

$$\int_{-\infty}^{\infty} |x(t)| dt < \infty$$

Podemos, a partir da transformada contínua de Fourier, definir sua versão discreta. Seja $x(n)$ um sinal discreto definido por uma cadeia de tamanho N ($n=0,1,\dots,N-1$), assumindo-se que x é um sinal periódico, e que a cadeia $x(n)$ contém um período deste sinal, a transformada discreta deste sinal se dá por :

$$Y(s) = \sum_{n=0}^{N-1} x(n) e^{\frac{-i2\pi sn}{N}}, s = 0,1,\dots,N-1$$

Os componentes $y(s)$ são os descritores de Fourier de $x(n)$. com estes coeficientes podemos obter uma reconstrução do sinal da imagem através da inversa da transformada discreta de Fourier.

A transformada de Fourier possui várias propriedades interessantes para o processamento de imagens. dentre elas podemos destacar:

- Linearidade: $a \cdot x_1(t) + b \cdot x_2(t) \leftrightarrow a \cdot y_1(f) + b \cdot y_2(f)$, sendo a e b constantes, x_1 e x_2 dois sinais e y_1 e y_2 suas transformadas de Fourier.
- Teorema da translação: $x(t-a) \leftrightarrow e^{(-i2\pi af)} y(f)$.
- Teorema da convolução: $x_1(t) * x_2(t) \leftrightarrow y_1(f) * y_2(f)$.

Na figura abaixo há um exemplo da utilização da transformada de Fourier. Foram criados dois sinais aleatórios, discretos de tamanhos 50. Posteriormente foi calculada a transformada de Fourier desses sinais e

com os 25 primeiros componentes, foi realizada reconstrução deste sinal. Este gráfico nos mostra uma aproximação muito boa e um efeito de suavização dos sinais originais.

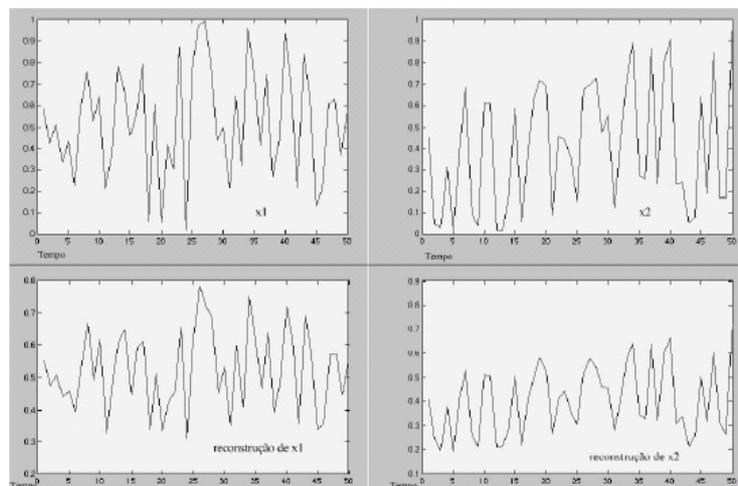


Fig 12. Efeito de transformação de sinais por Fourier

Outras técnicas de diminuição de dimensionalidade como Componentes principais, ou transformada de Hotelling [18], e discriminantes lineares LDA ou discriminante linear de Fisher. Podem ser utilizados com o mesmo propósito de diminuir ou restringir a dimensionalidade de uma imagem.

2.13. Filtros não lineares.

O uso de filtros lineares, principalmente quando o objetivo relaciona-se com a eliminação de ruídos, introduz algumas questões que podem ser equacionadas de forma alternativa. Muitas vezes, em conjunto com o resultado da aplicação de um filtro específico, observa-se o aspecto borrado aplicado à imagem resultante.

Estes problemas são abordados por filtros não-lineares com resultados mais satisfatórios. Como característica geral, estes filtros evitam uma suavização homogênea ao longo das regiões próximas ao contorno, além de não degradar a resolução da imagem.

Uma classe de filtros não-lineares, muito empregada na eliminação de ruídos, com preservação dos contornos, são os chamados filtros estatísticos. Estes apresentam algumas variações sendo que o

mais conhecido e utilizado é o filtro da mediana. Os filtros ditos como mínimo e máximo são variantes desta classe com utilização, porém, mais limitada. Ainda, nesta classe baseada em métodos estatísticos, existe o filtro da moda. Outras classes dizem respeito aos métodos e variações propostos por outros pesquisadores tais como o filtro de Nagao-Matsuyama e o filtro de Kuwahara.

2.14. Filtro Passa-Alta

Com o objetivo de aguçar detalhes finos numa imagem (como bordas), ou detalhes que tenham sido borrados na aquisição da imagem ou através da aplicação de um filtro, podemos usar filtros de aguçamento

O filtro passa-alta é um filtro que deixa passar apenas as altas frequências na imagem e é implementada através de uma máscara por meio de uma convolução com a imagem. Esta máscara tem valores negativos em sua borda e valores positivos no centro de modo que a soma dos coeficientes da máscara é igual a zero. Deste modo quando a máscara está sobre uma área com níveis de cor constante ou de pequena variação, a saída da máscara é zero ou muito pequena. Este resultado é consistente quando desejamos ressaltar variações bruscas de nível de uma cor que esteja sendo filtrada.

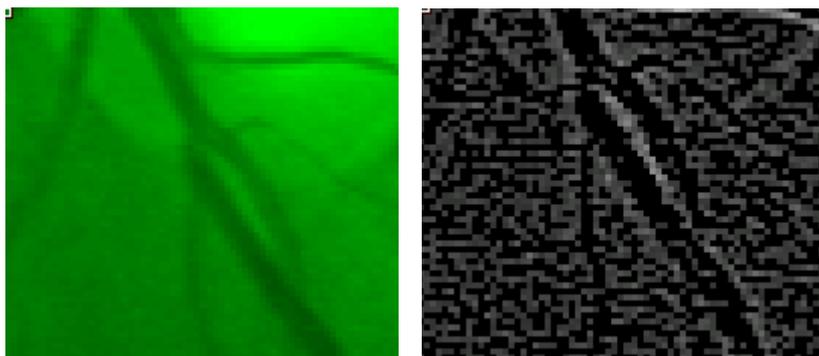


Fig 13 Efeito do filtro Passa-Alta

2.15. Filtragem de alto esforço.

Um filtro do tipo alto-esforço é obtido quando multiplicamos a imagem original, $f(x,y)$ por um fator de amplificação “A” e somamos a este resultado o elemento filtrante passa-alta.

$$\text{Alto_Esforço} = (A - 1) * f(x, y) + \text{Passa_Alta}$$

Em valores de A maiores que 1, parte da imagem retorna de volta ao resultado do filtro, o que permite restaurar um pouco das frequências baixas perdidas na operação. O resultado é uma imagem semelhante à imagem original com um maior realce das bordas ligado ao valor de A.

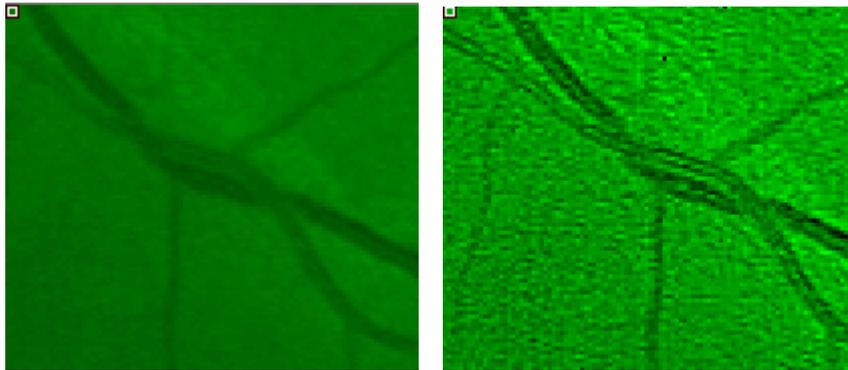


Fig 14 Efeito do Filtro Alto-Esforço com A=1.15

2.16. Filtros estatísticos.

Os filtros estatísticos baseados na ordem dos elementos têm por objetivo a substituição do pixel central de uma janela na imagem com um tamanho “w”, a qual deve ser movimentado sobre a imagem de forma semelhante ao processo de convolução, pelo k-ésimo valor dos pixels desta janela após o arranjo dos mesmos em ordem crescente de seus valores.

Podemos considerar uma seqüência $P(1), P(2), \dots, P(N)$ dos N valores de pixels presentes na janela de tamanho “w” e, ainda, a seqüência ordenada $O(1), O(2), \dots, O(N)$ dos N valores da mesma janela. Neste contexto, a função definida por:

$$R_{N,k}(\text{imagem}) = O(k)$$

caracteriza o filtro da ordem $R_{N,k}$. Podemos observar, como exemplo, a matriz existente na Figura 13, a qual representa, parcialmente, uma imagem com 256 níveis de cor, além da representação de uma janela

$n=3$, ou seja, 3×3 , com base na qual os valores serão ordenados para determinação do percentil desejado. Por outro lado, com filtros baseados em métodos estatísticos, não são introduzidos valores de brilho diferentes daqueles já presentes na imagem original. Outras características são dependentes do percentil desejado para o filtro. Os valores mais comuns são o do 50º percentil ($k = 50$), denominado de mediana, o do primeiro percentil - o filtro do mínimo - onde $k = 1$ e o filtro do máximo - o 100º percentil, com $k = N$.

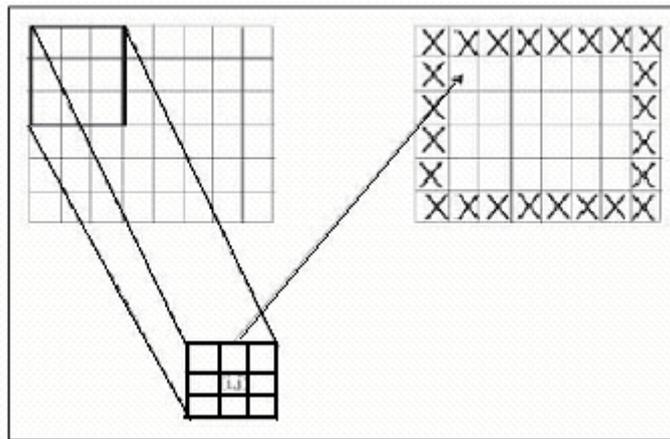


Fig 15 – Exemplo de Máscara ou janela

2.16.1. Filtro Gaussiano.

O filtro gaussiano é aplicado para redução de ruídos em imagens que apresentam uma alta taxa de ruído gaussiano. Na verdade a técnica utilizada consiste na convolução de uma máscara de distribuição gaussiana com a imagem. A máscara pode ser conforme mostrada abaixo onde Z_i denota os vizinhos do pixel central:

Z_1	Z_2	Z_3
Z_4	Z_5	Z_6
Z_7	Z_8	Z_9

Fig 16 Exemplo de uma Máscara

$$f = z_1 + 2z_2 + z_3 + 2z_4 + 4z_5 + 2z_6 + z_7 + 2z_8 + z_9$$

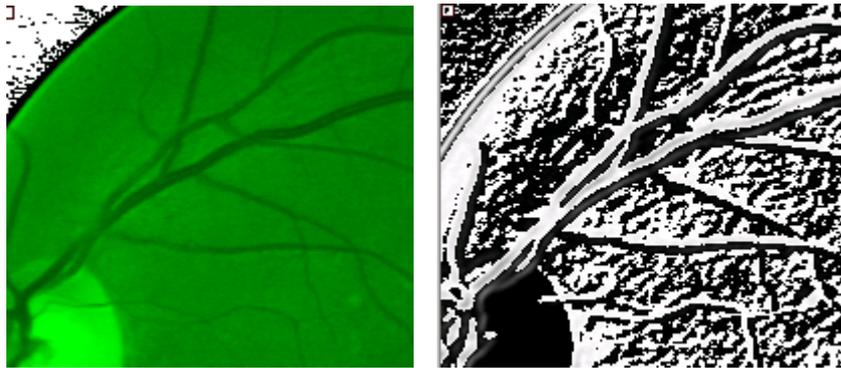


Fig 17 Ação do Filtro Gaussiano sobre uma imagem

2.16.2. Filtro da mediana

É, dentre os filtros estatísticos, o mais utilizado. Da seqüência ordenada, na atribuição do novo valor de um ponto, é sempre escolhido o valor intermediário, correspondendo ao 50º percentil ou $K = (N + 1)/2$. Assim, e supondo que uma determinada janela 3×3 apresentasse o conteúdo $\{158, 162, 134, 144, 156, 155, 152, 176, 154\}$. A seqüência, após o processo de ordenação, apresentaria os valores como a seguir: $\{134; 144; 152; 154; 155; 156; 158; 162; 176\}$ o que implicaria na atribuição do valor 155 para o pixel central da janela, visto que este valor ocupa a posição central, ou mediana, na seqüência. Em geral, o filtro da mediana destrói pontos isolados, sendo eficiente para ruídos impulsivos, ou seja, ruídos distribuídos aleatoriamente pela imagem. Assim, os pixels afetados pelo ruído são corrigidos sem que se espalhe o efeito dos mesmos para a sua vizinhança. Da mesma forma, pode ser observado que o valor da mediana não se modifica pelo aparecimento de valores extremos, fora do domínio da ordenação. O sinal de entrada é respeitado pelo filtro o que, geralmente, diminui o problema da falta de nitidez.

Na figura abaixo temos um exemplo da utilização do filtro da mediana aplicado sobre uma imagem na qual foi introduzido um ruído impulsivo através de um filtro de alto-esforço muito sensível a ruídos. Após aplicação do filtro da mediana, podemos observar que o ruído da imagem fora substituído em muitos pontos, diminuindo seu efeito.

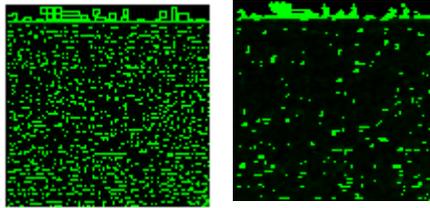


Fig 18 – Imagem com ruído e tratada com um filtro da mediana.

2.16.3. Filtro de Kuwahara.

É importante que os métodos de filtragem, enquanto suavizam uma imagem, preserve as bordas, mantendo sua posição e delineamento.

Existem muitas variações possíveis para a implementação do filtro de Kuwahara, principalmente quanto à variedade de formatos e tamanhos para as janelas. Uma implementação particular considera uma janela de tamanho $J = 4L + 1$, $L=1..n$ é um inteiro. A Figura 19 ilustra esta janela que também é particionada em quatro regiões. Em cada uma destas regiões o brilho médio e a variância são determinados. O valor resultante, que substituirá o pixel central da janela, é a média da região que apresentar a menor variância.

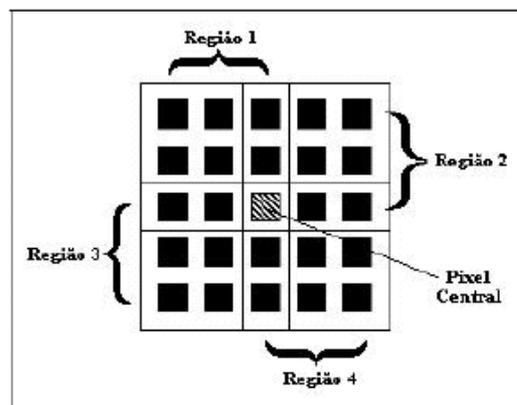


Fig 19- Regiões do filtro de Kuwahara

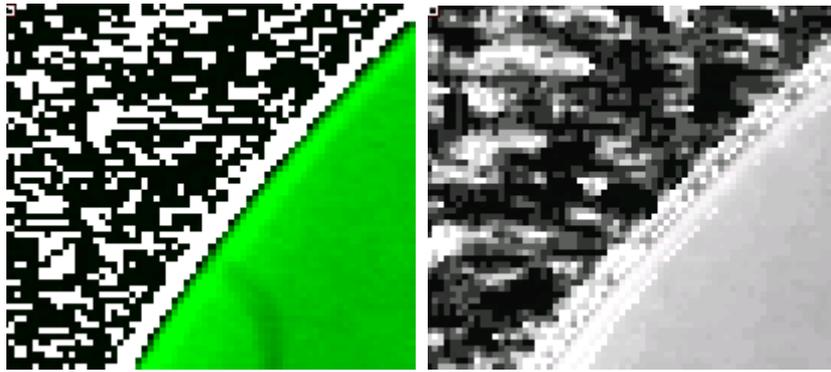


Fig 20 Filtro de Kuwahara aplicado sobre uma região ruidosa

2.16.4. Filtro de Nagao-Matsuyana

De forma semelhante ao Filtro de Kuwahara, este método também está baseado nas médias e variâncias de regiões distintas. A definição destas janelas é, contudo, feita de forma diferente. O método de suavização associa a cada ponto a ser filtrado, o nível de cor médio dos elementos numa vizinhança 5x5, centrada neste mesmo ponto. São estabelecidas 9 regiões, conforme a Figura 21, sendo oito assimétricas, e avaliadas as 9 médias e as 9 variâncias. A intenção do filtro é substituir o ponto central da janela pelo valor da média da região que apresentar a menor variância.

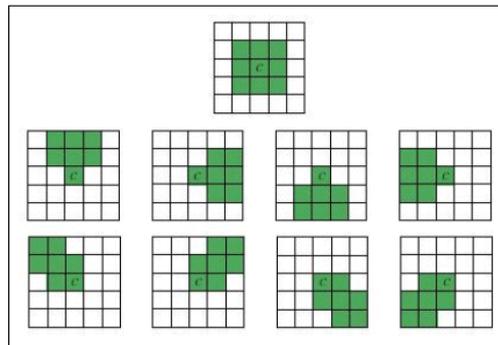


Fig 21 - Regiões do filtro de Nagao-Matsuyana

2.17. Detecção de bordas

Uma borda é o limite entre duas regiões com propriedades relativamente distintas. Algumas técnicas são aplicadas quando as duas regiões em questão são homogêneas o suficiente para que a transição entre as duas regiões possa ser determinada apenas pela

descontinuidade dos níveis de cor ou de cinza da imagem, outras técnicas de limiarização e de segmentação orientada a regiões podem ser utilizadas quando esta premissa não é verificada.

Basicamente a idéia por trás de uma técnica de detecção de borda é a computação de um operador local diferencial [5]. A figura 22 abaixo ilustra este conceito mostrando uma faixa clara sobre um fundo escuro o perfil do nível de cor ao longo de uma linha de varredura horizontal da imagem e a primeira e segunda derivada dessa linha de perfil.



Fig 22 – Uma borda de imagem, o perfil de uma linha horizontal, sua primeira e segunda derivadas.

A primeira derivada do perfil de nível de cor é positiva na primeira borda (à esquerda), negativa na segunda (à direita) e nula nas áreas de cor constante. Portanto a magnitude da primeira derivada pode ser usada para detecção de uma borda na imagem. Já a segunda derivada possui uma passagem por zero no ponto intermediário da transição dos níveis de cor, este cruzamento fornece uma abordagem poderosa para localização de bordas.

Existem propriedades físicas e geométricas relacionadas à imagem que origina uma borda.

Geométrico:

- Delimitação do Objeto: Descontinuidade em profundidade e/ou cor da superfície ou textura.
- Delimitação da superfície: Descontinuidade na orientação da superfície

Ótico:

- Reflexão: reflexão da direção da luz na superfície.
- Sombras: De outros objetos ou de partes do mesmo objeto
- Marcas na superfície.

Alguns tipos de bordas podem ser visto na figura abaixo:

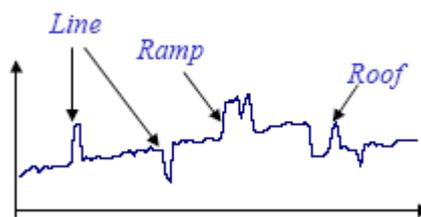
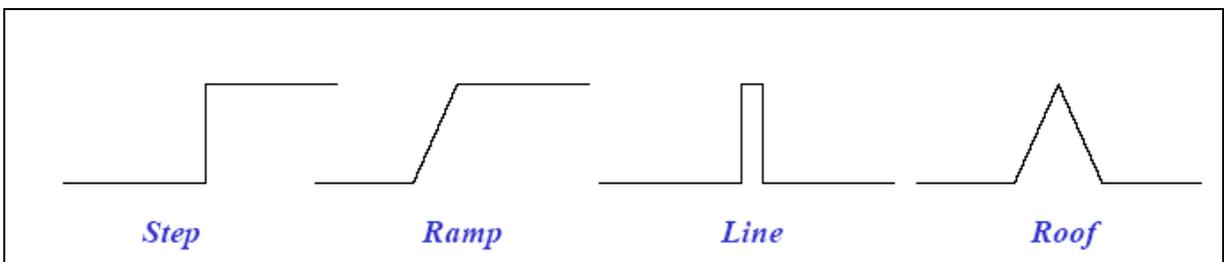


Fig 23 – Tipos de Bordas e gráfico mostrando os tipos de bordas

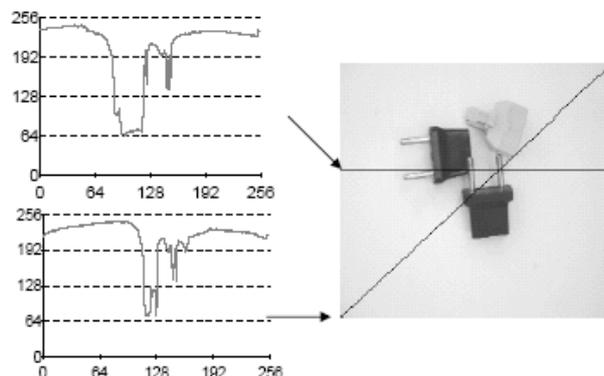


Fig 24 -Representação gráfica do nível de cor através de um plano

Detecção de bordas é uma operação que busca na imagem variações bruscas de intensidade. Operadores de primeira e segunda

derivadas dão informações a respeito de variações bruscas nas intensidades (como visto anteriormente). Através de operadores locais diferenciais podemos obter a primeira derivada da imagem em qualquer ponto usando-se a magnitude do gradiente naquele ponto a segunda derivada é obtida de forma similar utilizando o operador laplaciano.

2.17.1. Operadores de Gradiente:

Podemos definir o gradiente de uma imagem $f(x,y)$ no ponto (x,y) como sendo o vetor:

$$\nabla f = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix}$$

O vetor gradiente aponta na direção de mudança mais rápida de f na posição (x,y) . Em detecção de borda a magnitude deste vetor é um valor importante chamada de gradiente e denotado por $\text{mag}(\nabla f)$, em que:

$$\text{mag}(\nabla f) = [G_x^2 + G_y^2]^{1/2}$$

Outro valor importante na detecção de bordas é a direção do vetor gradiente, que juntamente com o gradiente, pode ser utilizado para ligação de borda e detecção de fronteiras numa imagem. A direção do vetor gradiente em que o ângulo é medido em relação ao eixo x é dada por.

:

$$\alpha(x, y) = \tan^{-1} \left[\frac{G_y}{G_x} \right]$$

É comum a prática de aproximar os valores de gradiente por valores absolutos:

$$G \approx |G_x| + |G_y| \quad \text{ou} \quad G \approx \max(|G_x|, |G_y|)$$

Particularmente os operadores de gradiente são implementados através de máscaras de convolução implementada de forma a percorrer todos os pixels da imagem e para cada pixel (x,y) um valor associado ou operador, chamaremos de resposta da máscara, é medido e, posteriormente, classificado dentro de um determinado critério. A convolução é uma importante propriedade das transformadas de Fourier.

Os operadores de gradiente são particularmente sensíveis a ruídos na imagem pois eles impõem uma mudança brusca de intensidade de cor, como os operadores de gradiente são implementados através da convolução de máscaras, estes ruídos tem uma resposta alta quando aplicamos a máscara escolhida para a operação desejada. Dependendo do critério a ser utilizado para segmentação estes ruídos podem ser confundidos como parte da imagem, sendo então necessário outros métodos auxiliares para redução dos ruídos.

2.17.2. Operadores de Sobel

O efeito da suavização é particularmente desejável quando aplicamos operadores de gradiente, os operadores de Sobel têm esta característica.

$$(a) \begin{bmatrix} z1 & z2 & z3 \\ z4 & z5 & z6 \\ z7 & z8 & z9 \end{bmatrix} \quad (b) \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad (c) \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$$

Fig 25 Máscara do operador de Sobel

A figura acima mostra a região de tamanho 3x3 de uma imagem em que os valores de z são os níveis de cor naquela região (a), a máscara usada para o calculo de G_x (b) no ponto central da imagem e no calculo de G_y (c) no mesmo ponto.

Sobel é muito menos sensível ao ruído e os resultados são mais precisos.

A computação de $|G|$ se torna mais complexa devido a operações envolvidas no cálculo e por isto $|G|$ é aproximada da seguinte forma: $|G| = |G_x| + |G_y|$. O módulo do gradiente é proporcional à derivada local da intensidade

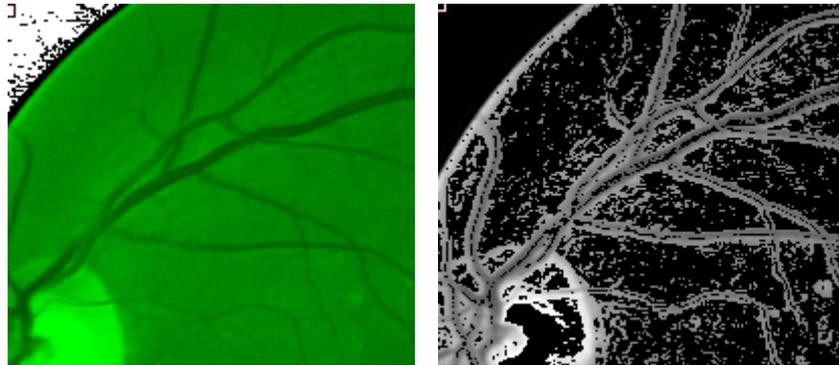


Fig 26 Aplicação do Detector de borda de Sobel

2.17.3. Operador de Robson

É similar em operação ao de Sobel, porém usa um conjunto de oito máscaras, onde quatro delas são as seguintes:

$$\begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \quad \begin{bmatrix} 2 & 1 & 0 \\ 1 & 0 & -1 \\ 0 & -1 & -2 \end{bmatrix}$$

$$\begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix} \quad \begin{bmatrix} 0 & -1 & -2 \\ 1 & 0 & -1 \\ 2 & 1 & 0 \end{bmatrix}$$

Fig 27 Máscara do operador de Robson

As outras quatro são simplesmente negações destas quatro. A magnitude do gradiente é o valor máximo obtido ao aplicar todas as oito máscaras ao pixel vizinho, e o ângulo do gradiente pode ser aproximado como o ângulo na linha de zeros na máscara dando a resposta máxima. Este algoritmo aumenta a precisão de $|G|$, mas requer mais computação do que o operador de Sobel, devido ao tamanho das máscaras.

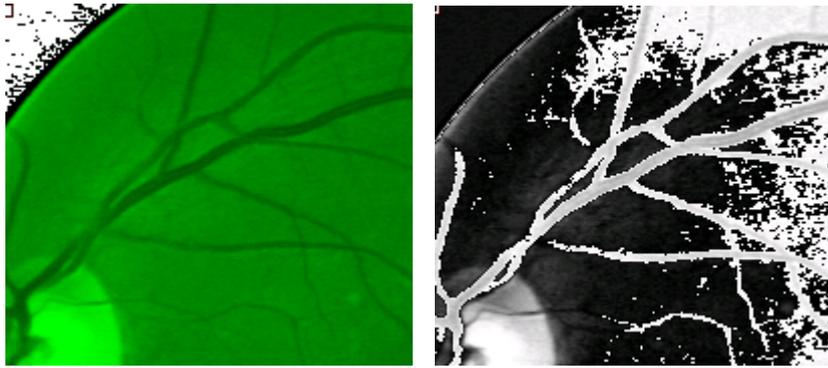


Fig 28 Aplicação do Detector de Borda de Robson

2.17.4. Filtro de Canny.

Um conjunto de metas que um detector de bordas deveria Ter são eles:

1. Taxa de erro: o detector de bordas deveria detectar e achar somente bordas, nenhuma borda deveria faltar;
2. Localização: a distância entre os pixels de borda encontradas pelo detector de bordas e a borda atual deveriam ser a menor possível;
3. Resposta: o detector de bordas não deveria identificar múltiplos pixels de borda onde somente exista um único pixel.

O detector de bordas de Canny é um filtro de convolução que uniformizaria o ruído e localizaria as bordas. O problema é identificar um filtro que otimize os três critérios do detector de bordas. Se considerarmos uma borda de uma dimensão variando no contraste e então covolucionando a borda com a função de uniformização de Gauss, o resultado será uma variação contínua do valor inicial ao final, com uma inclinação máxima no ponto onde existe um "degrau". Se esta continuidade é diferenciada em relação a x , esta inclinação máxima será o máximo da nova função em relação a original.

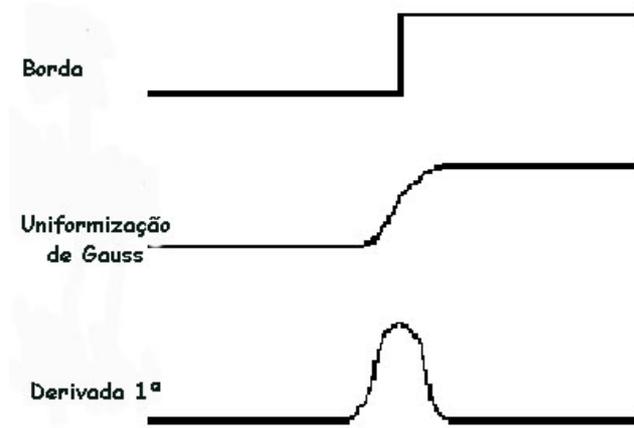


Fig 29: Detecção de bordas por Canny

Os máximos da convolução da máscara e da imagem indicarão bordas na imagem. Este processo pode ser realizado através do uso de uma função de Gauss de 2-Dimensões na direção de x e y . Os valores das máscaras de Gauss dependem da escolha do sigma na equação:

$$G(x) = \frac{1}{\sqrt{2\pi\alpha}} e^{-\frac{x^2}{2\alpha}}$$

$$G'(x) = \frac{-x}{\sqrt{2\pi\alpha^3}} e^{-\frac{x^2}{2\alpha}}$$

A aproximação do filtro de Canny para detecção de bordas é G' . Convolutionando a imagem com G' obtemos uma imagem I que mostrará as bordas, mesmo na presença de ruído. A convolução é relativamente simples de ser implementada, mas é cara computacionalmente, especialmente se for em 2-dimensões. Entretanto, uma convolução de Gauss de 2-dimensões pode ser separada em duas convoluções de Gauss de 1-dimensão.

A intensidade computacional do detector de bordas de Canny é relativamente alta, e os resultados são geralmente pós-processados para maior clareza. Entretanto, o algoritmo é mais eficiente no processamento de imagens com ruídos ou com bordas difusas.

2.17.5.Laplaciano.

O laplaciano de uma função bidimensional $f(x,y)$ é uma derivada de segunda ordem definida por:

$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2}$$

Assim como no caso do gradiente, o laplaciano pode ser implementado digitalmente de diferentes maneiras, para o caso de uma região 3x3 a forma mais encontrada:

$$\partial^2 f = 4z_5 - (z_2 + z_4 + z_6 + z_8)$$

Onde os z_i ($i=1,2\dots 8$) são os valores do vizinhos do pixel. A exigência principal do laplaciano é que o coeficiente associado ao pixel central seja positivo e os outros pixels externos sejam negativos, uma vez que o laplaciano é uma derivada então a soma dos coeficientes deve ser nula. Outra característica do laplaciano é a sensibilidade a ruídos.

A utilização prática deste filtro só pode ser feita na presença de um filtro gaussiano, a técnica combinada de filtro gaussiano + operador laplaciano para detecção de bordas é conhecida por Método de Marr-Hildreth.

2.18. Segmentação de imagens

Existe uma certa dificuldade em se estabelecer procedimentos de segmentação em imagens. A identificação dos segmentos deve obedecer a algumas características: Os pixels devem possuir alguma propriedade em comum dentro da imagem. A propriedade em comum pode ser uma superfície que representa um osso dentro de uma radiografia, uma peça sendo submetida a um controle de qualidade ou um mapa ilustrando alguma característica de uma foto ou um vaso sanguíneo. Dentre as propriedades desejáveis de uma imagem são destacadas algumas a seguir:

- A região representada pelos pixels deve ser homogênea.
- Os segmentos são regiões fechadas e devem ser delimitadas por bordas ou outros segmentos.

- O segmento possui certas propriedades matemáticas associadas. As propriedades mais comuns utilizadas para representar as regiões são os diagramas de Venn.
- As regiões adjacentes não devem possuir pixels em comum
- Os segmentos devem ser uniformes e homogêneos com relação a níveis de cor ou textura.
- As regiões devem ser o mais simples possível e não possuir buracos pequenos
- Diferenças entre regiões adjacentes devem ser significativas
- As bordas devem ser precisas

A segmentação é uma soma de várias outras técnicas elementares de processamento e pré-processamento realizado sobre uma imagem. Cada situação requer uma solução diferenciada, de acordo com as características da imagem. É evidente que estas características só podem ser obtidas em ambientes controlados, mais em geral, nossas imagens não possuem esta característica ou o nível de controle não atinge estas especificações, sendo assim faz-se necessário a criação de técnicas que possuam uma abrangência maior para variações da imagem.

2.19. Esqueletização:

A esqueletização é um procedimento que surgiu na década de 60, utilizado para extrair um conjunto de pontos no interior de um objeto de tal modo a representá-lo. Este conjunto de pontos é chamado de esqueleto do objeto. Os esqueletos possuem várias aplicações na área de processamento de imagens, tais como, agrupamento, segmentação, vetorização, descrição de formas, reconhecimento de caracteres, inspeção, etc.

Desde que o conceito de esqueleto foi introduzido, vários algoritmos de esqueletização foram propostos com o intuito de melhorar a eficiência computacional, mas nem sempre com uma preocupação em estudar as suas propriedades matemáticas.

O esqueleto de uma região pode ser definido pela transformação do eixo médio (medial axis transform - MAT) proposto em [19]. A MAT de uma região R com borda B é definida da seguinte forma : para cada ponto p em R, encontramos seu vizinho mais próximo em B. Se p tiver mais de um vizinho desse tipo, então se diz que ele pertence ao eixo médio, ou esqueleto, de R. O conceito de mais próximo depende da definição de distância, logo o resultado é influenciado pela escolha desta medida de distância.

A implementação direta da MAT de uma região é uma tarefa computacionalmente complexa pois envolve potencialmente o cálculo da distância de cada ponto interior a os pontos da fronteira. Sendo assim algoritmos computacionalmente aceitos são aqueles que vão apagando as bordas dentro de um certo critério de modo que os pontos externos não devem ser removidos, não quebre a conectividade e não cause uma erosão excessiva de uma região.

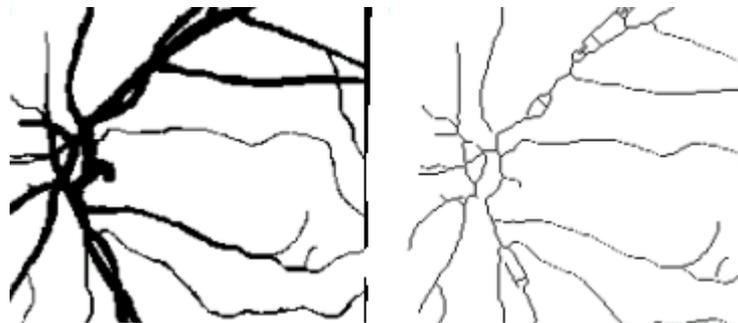


Fig 30 Processamento de Esqueletização

3. MATERIAIS E MÉTODOS.

Existem duas diferentes formas de obter imagens de fundos de olhos: A retinografia que utiliza câmaras do tipo non-mydratic que não requer a dilatação da pupila para obtenção da imagem do fundo do olho, ou métodos de obtenção utilizando contraste e fazendo a dilatação da pupila através de uma técnica chamada angiograma. Nosso método de segmentação foi testado e realizado numa base de dados disponível na Internet de imagens utilizando a técnica de retinografia retiradas com câmeras non-mydratic e com segmentação manual correspondente para cada imagem.

O projeto DRIVE database consiste em 40 imagens (7 imagens de olhos patológicos) juntamente com suas respectivas segmentações manuais. As imagens foram capturadas de forma digital através de uma câmera Cânon CR5 do tipo non-mydratic com uma esfera de ação de 45° graus de visão (FOV). As imagens são do tamanho de 768 x 584 pixels, 8 bits por canal de cor. As imagens foram comprimidas nos formatos gif e tif e posteriormente transformadas para o formato BMP para análise através do programa desenvolvido no Laboratório de Computação do Programa de Pós-graduação em Biometria da UFRPE.. As imagens foram divididas em dois conjuntos chamados de conjunto de treinamento e conjunto de testes.

Dois observadores segmentaram manualmente as imagens deste banco de dados. Um dos observadores segmentou 10,4% dos pixels contra 14,9% de pixels do segundo observador. As segmentações dos dois observadores são claramente diferentes pois o segundo observador conseguiu segmentar pequenos vasos que não foram observados pelo primeiro observador.

A figura abaixo mostra uma imagem obtidas do projeto DRIVE e suas segmentações manuais:

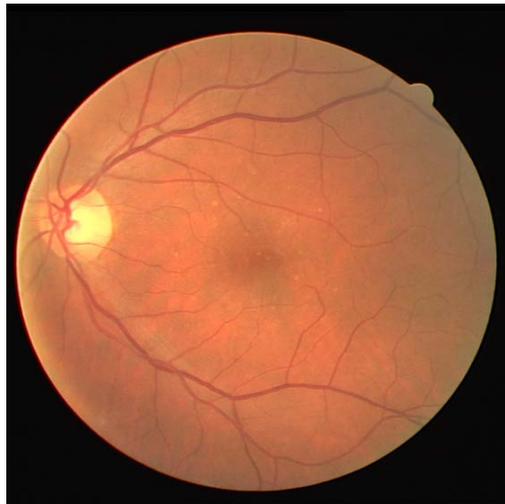


fig 31 – Original de uma retina com aspecto normal.

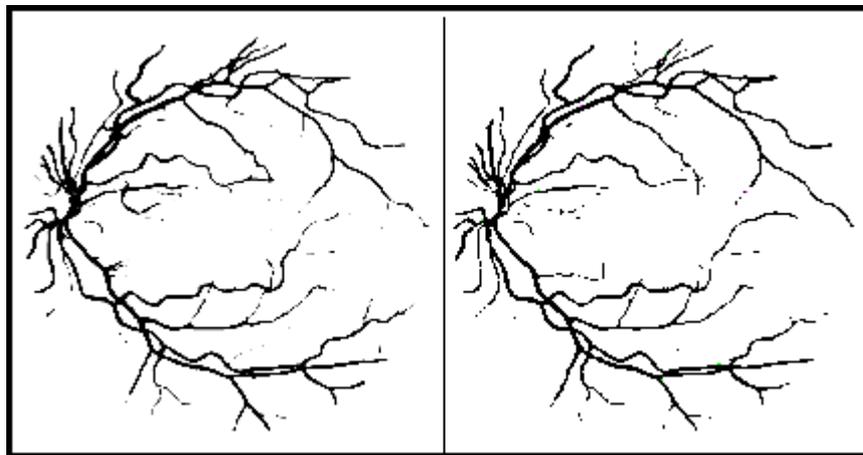


Fig 32 -Segmentação manual 1 - Segmentação manual 2

É importante notar que a perfeição na segmentação manual está diretamente relacionada à sensibilidade de cada segmentador quando distingue os vasos da imagem. Alguns podem ser mais minuciosos do que outros ao segmentar pequenos vasos. No entanto, esta é a segmentação mais próxima da real, e nós a utilizamos para efeito de comparação com a segmentação proposta aqui.

Para realização das técnicas aplicadas à imagem, foi desenvolvido no Laboratório de Computação do Programa de Pós-graduação em Biometria da UFRPE um programa escrito na linguagem C, utilizando a API do Windows para tratamento de arquivos de imagem. O software foi chamado de RAS – Retinal Analysis and Segmentation Software. No software foram desenvolvidos os algoritmos dos principais métodos descritos neste trabalho. Além disto todas as análises estatísticas que

estão implementadas, foram comparadas com as mesmas análises geradas pelo programa Minitab©. Algumas estatísticas foram realizadas apenas pelo minitab©.

Neste capítulo veremos os principais métodos utilizados que apóiam as discursões finais.

3.1. Correlação

Muitos trabalhos relacionados a segmentação de vasos levam em consideração apenas o canal Green da imagem RGB. Observando a imagem separada em seus canais, podemos observar que no canal Green o contraste dos pixels nos vasos é maior do que nos outros canais Red e Blue. Quando dispensamos os valores associados aos canais Red e Blue, estamos desperdiçando informações sobre os vasos cujo contraste nestes canais são mais evidentes, ou só aparecem neles.

Realizamos os seguintes procedimentos para o cálculo do fator de correlação:

- Separamos os pixels da imagem toda por canal RGB.
- Aplicamos a função Correlação do RAS.
- Aplicamos o mesmo procedimento no minitab ® para efeito de comparação:

Os coeficientes obtidos foram os seguintes (aproximados com 2 casas decimais).

:

	Imagem 1		Imagem 2		Imagem 3		Imagem 4		Imagem 5		Imagem 6	
	R	B	R	B	R	B	R	B	R	B	R	B
G	0.96	0.98	0.96	0.98	0.93	0.97	0.94	0.98	0.96	0.98	0.95	0.97
R	X	0.95	X	0.93	X	0.92	X	0.93	X	0.93	X	0.92

Tabela

Observando a tabela podemos concluir que nestas imagens o fator de correlação é próximo a 1 (um) para todos os conjuntos de valores de pixels, indicando que os pixels são positivamente e fortemente correlacionados. O fato de que a informação contida na imagem esta

distribuída igualmente entre os três canais, justifica procedimento adotado na maioria dos trabalhos em utilizar só o canal green (que contem o maior contraste), além de fato que a omissão de outros canais leva a perda de informação.

3.2. Detecção usando filtro Gaussiano.

A técnica utilizada neste trabalho para detecção da rede de vasos sanguíneos utiliza o filtro gaussiano e teoria de convolução para obter valores de respostas significativos. Esta técnica é conhecida como “Matched filter”. E nós implementaremos uma variação conhecida como “2d matched filter” [8]

Se olharmos mais atentamente para a rede de vasos que compõe a imagem, podemos observar três características importantes para o emprego dos filtros gaussianos:

1. Os vasos têm pequenas curvaturas na sua extensão, assim podemos aproximar seu formato com pequenos segmentos lineares.
2. Vasos são mais escuros quando comparados com outras áreas da retina. A figura abaixo mostra um gráfico dos valores dos pixels ao longo da secção transversal do vaso. Embora a intensidade varie um pouco de vaso para vaso é possível aproximar esta distribuição dos vasos a uma curva normal (gaussiana)

$$\bullet \quad f(x, y) = A \left\{ 1 - k \exp\left(\frac{-d^2}{2\alpha^2}\right) \right\}$$

- Onde: “d” é a distância perpendicular entre o ponto (x,y) e a linha que passa pelo centro do vaso, “ α ” exprime a variância da intensidade do vaso, “A” é a intensidade do nível de cor no local e “k” mede a refletância do ponto em relação a vizinhança local. “A”, “k” e “d” são definidas em função de (x,y)

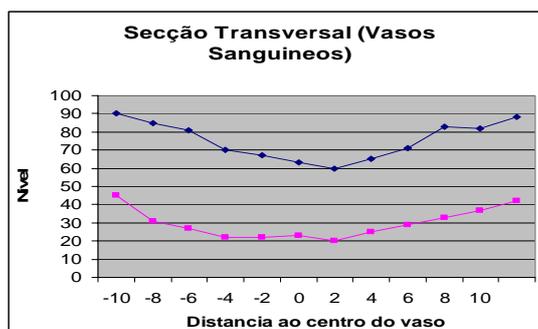


Fig 33 - Gráfico do perfil de dois vasos na imagem levando em consideração o nível de cor Green

- O tamanho dos vasos decresçam com a distancia em relação ao disco óptico, no entanto podemos considerar um espaço de 2 a 10 pixels (36 – 180 μm). Para cálculos iniciais consideramos 2α .

Podemos então considerar que a intensidade de cor do perfil dos vasos são simétricos entorno da linha que passa pelo centro do vaso, conseqüentemente: $s(-t)=s(t)$. um filtro ótimo com estas características deve ter a mesma forma e intensidade do vaso, ou seja:

- $$h(d) = -\exp\left(-\frac{d^2}{2\alpha^2}\right)$$

Para decidirmos se um determinado pixel pertence ou não a um vaso, devemos escolher um parâmetro para a resposta do filtro quando este passar pela imagem.

Quando estendemos este conceito para imagens (2d) devemos considerar que este vaso tem uma orientação com relação ao seu eixo central, e ela varia num ângulo θ ($0 \leq \theta \leq \pi$). O filtro obterá a maior resposta apenas quando $\theta \pm \pi/2$, assim necessitamos rotacionar o filtro para todos os possíveis ângulos, as respostas são comparadas e apenas a maior resposta de cada pixel é armazenada.

3.2.1. Construção da Máscara do filtro gaussiano.

A máscara é uma matriz de duas dimensões com origem no ponto (0,0), cujo núcleo é dado por:

$$\bullet \quad k(x, y) = -\exp\left(\frac{-u^2}{2\alpha^2}\right)$$

onde: u é o valor do ponto (x,y) multiplicado pela matriz de rotação:

$$\bullet \quad r = \begin{vmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{vmatrix}$$

O valor de u é limitado por $2*\alpha$ e o valor de α é passado como um parâmetro da função, a literatura indica $\alpha=1$. Abaixo segue um exemplo de uma máscara para $\theta=0$ observe que a formação dos valores no interior da máscara segue uma discretização normal em torno do valor central. Como, neste exemplo $\theta=0$, a orientação da distribuição também segue esta tendência.

0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	4	2	-1	-3	-5	-3	-1	2	4	0	0	0
0	0	0	4	2	-1	-3	-5	-3	-1	2	4	0	0	0
0	0	0	4	2	-1	-3	-5	-3	-1	2	4	0	0	0
0	0	0	4	2	-1	-3	-5	-3	-1	2	4	0	0	0
0	0	0	4	2	-1	-3	-5	-3	-1	2	4	0	0	0
0	0	0	4	2	-1	-3	-5	-3	-1	2	4	0	0	0
0	0	0	4	2	-1	-3	-5	-3	-1	2	4	0	0	0
0	0	0	4	2	-1	-3	-5	-3	-1	2	4	0	0	0
0	0	0	4	2	-1	-3	-5	-3	-1	2	4	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Fig 34 -Máscara gerada a partir do Software RAS.

A aplicação da máscara na imagem gera também vários falsos positivos e também vários pontos desconectados dos demais vasos, para

isto acontecer basta que a dimensão ou a intensidade de cor do vaso varie e, conseqüentemente, varie o valor da resposta do filtro.

A figura abaixo mostra três imagens de fundos de olhos onde foi aplicada a máscara gaussiana 2d matched filter com $L=9$ e $\alpha = 1$, é importante salientar que este procedimento não binariza a imagem, a menos que seja aplicada uma técnica auxiliar que pode ser um corte nos valores dos pixels, a utilização do algoritmo de detecção de bordas e.g. Robert, Sobel, Robson, Canny, etc., ou ainda um algoritmo de percolação.

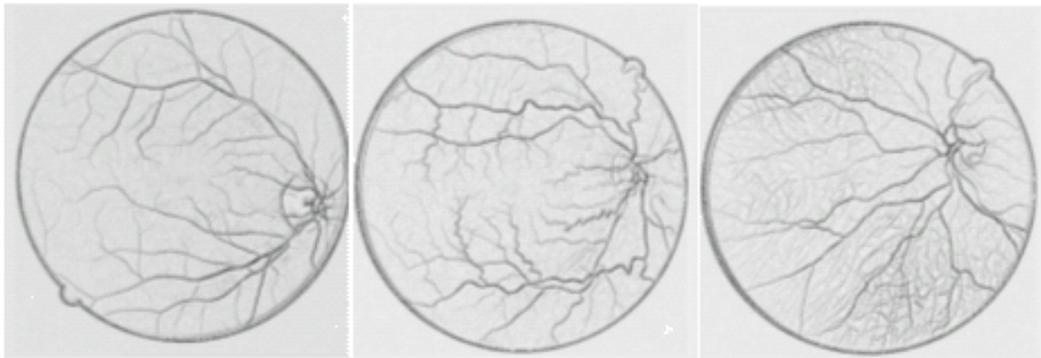


Fig 35-Imagem submetida à máscara gaussiana 2d matched filter

3.3. O Operador Laplaciano.

A utilização prática do filtro Laplaciano só pode ser feita na presença de um filtro gaussiano, a técnica combinada de filtro gaussiano + operador laplaciano para detecção de bordas é conhecida por Método de Marr-Hildreth [20]. Utilizamos inicialmente o processamento “2d matched filter” que consiste em rotacionar uma máscara gaussiana sobre a imagem a fim de obter pontos que pertençam à rede de vasos da imagem, podemos agora passar sobre esta imagem um filtro laplaciano para melhorarmos o contraste obtido no processamento “2d matched filter” que é insatisfatório para uma binarização da imagem ou para utilização de uma técnica de detecção de borda.

Abaixo segue alguns resultados obtidos quando passamos o laplaciano na imagem processada pelo “2d matched filter”, observe que o histograma da imagem processada pelo filtro gaussiano não possibilita uma binarização, já as imagens processadas pelo laplaciano têm uma distribuição menos concentrada.

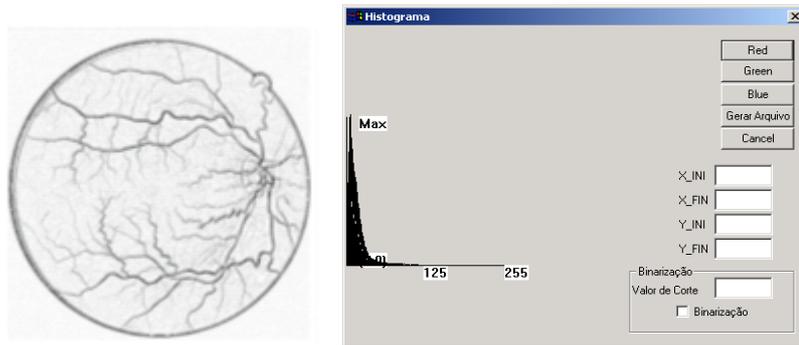


fig 36 -Imagem após processamento “2d matched filter” com o respectivo histograma.

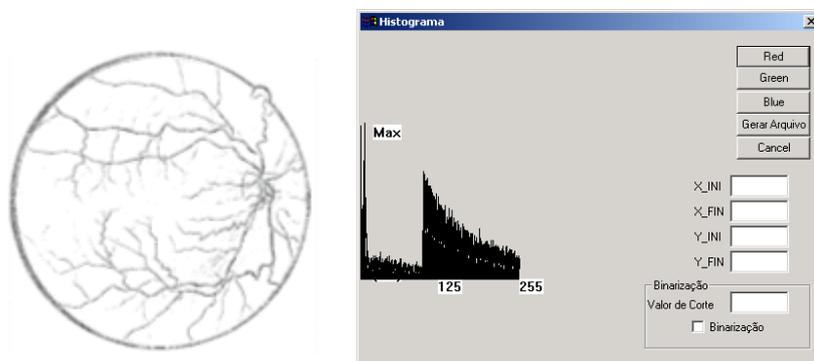


fig 37 -Imagem após processamento laplaciano com o respectivo histograma.

3.4. Detecção de Bordas Utilizando. Operador de Robert.

O operador de Robert é um operador simples baseado na diferença entre os pontos da diagonal.

$$G[f(x, y)] \cong |f(x, y) - f(x+1, y+1)| + |f(x+1, y) - f(x, y+1)|$$

um dos problemas encontrados na binarização da imagem através do histograma é que quando associamos um valor para o corte estamos desprezando indistintamente tanto pixels da imagem como fora dela. Achamos melhor aplicar o detector de bordas pois podemos assim binarizar a imagem baseando-se na presença da borda ou não.

A figura abaixo representa uma máscara digital que implementa o operador de Robert.

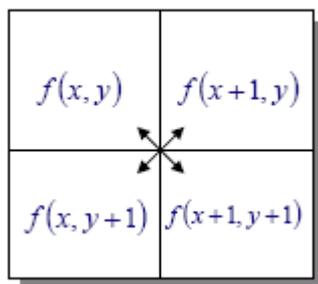


Fig 38 – Máscara de Robert

Alguns resultados da aplicação do algoritmo de Robert sobre a imagem após o uso do laplaciano. Observe que após esta operação a imagem encontra-se binarizada.

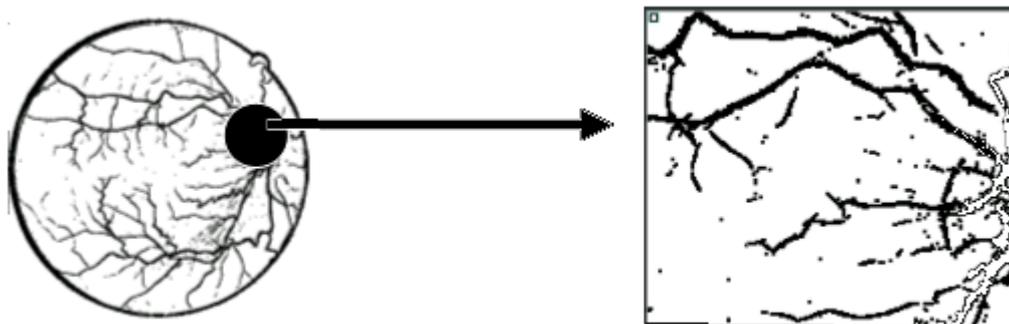


Fig 39 - Imagem do fundo do olho após o processamento de detecção de borda. Observe no detalhe ampliado que vários pontos são detectados fora da rede de vasos que compõe a imagem.

3.5. Algoritmo de percolação de Hoshen-Kopelman

A concepção de percolação tem sido associado com a permeabilidade de um fluido por um meio poroso. A formação de clusters de moléculas idênticas em cristais pode ser a estrutura para a teoria da percolação. Vários exemplos do fenômeno e suas aplicações são enumerados na literatura, entre ele: magnetização espontânea em

diluição com características ferro-magnéticas, difusão de doenças num organismo, formação de polímeros gelatinosos, condutividade elétrica em condutores amorfos e em solução de metal-amônia, Isto demonstra um pequeno exemplo de vários fenômenos de relacionados a percolação presentes na natureza.

Existe uma complexidade computacional associada a determinação de clusters num determinado meio. O algoritmo introduzido por J. Hoshen e R. Kopelman [15] é uma forma computacionalmente rápida e exata de determinar a distribuição dos clusters, as concentrações nos clusters e as probabilidades de percolação. O sucesso do algoritmo é baseado na aplicação de etiquetas “labels” para sites conectados transformando-os em um só cluster.

O algoritmo de percolação de Hoshen-Kopelman faz um loop seqüencial num retangulado que simula uma parte de um cristal, por exemplo, no qual cada ponto pode ser considerado como ocupado quando possui o valor um (ou então assume uma determinada condição) ou vazio, quando possui o valor zero (ou não assume uma determinada condição). Para cada ponto $p(i,j)$ pontos são checados os vizinhos $p(i-1,j)$ e $p(i,j-1)$, se ambos são vazios um novo cluster é então criado, pois o ponto $p(i,j)$ tem a característica desejada. Se um dos dois vizinhos é ocupado e o outro vazio, o algoritmo adiciona o novo ponto ao cluster do ponto vizinho ocupado. Finalmente, quando o ponto considerado conecta dois pontos que pertencem aos clusters diferentes, o cluster que tem menor valor de etiqueta (ou label) recebe o novo ponto, bem como o outro cluster com etiqueta maior. Desta forma, algoritmo evita visitas repetitivas de mesmo ponto, ou seja, um único passo pela grade é suficiente para identificação de todos clusters individuais na imagem.

Abaixo colocamos a imagem de um reticulado que contém vários clusters, cada ponto de um cluster possui o valor um, o algoritmo de percolação de Hoshen-Kopelman percorre todo o reticulado e separa todos os clustrers que estão conectados.

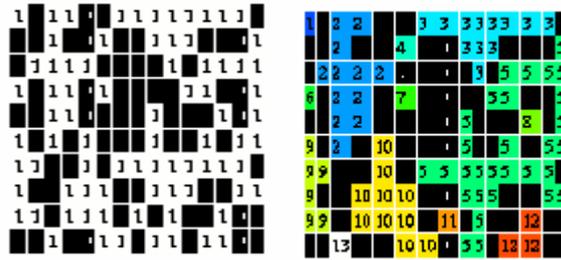


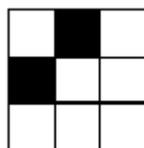
Fig 40 - Reticulados antes e depois do algoritmo de Hoshen-Kopelman.

3.5.1. Adaptação do Algoritmo de Hoshen-Kopelman para a segmentação da imagem

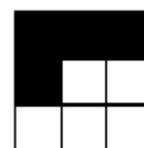
O algoritmo de Hoshen-Kopelman pode ser aplicado a uma imagem com o objetivo de segmentar ou separar a imagem em clusters de tamanhos diferentes que possuem as mesmas características cada, ou seja, podemos determinar uma condição de agrupamento para os pixels e a partir desta condição encontrar quais os pixels são similares e pertencem a um mesmo cluster.

Aplicamos esta técnica para retirar da imagem todos os clusters que são agrupamentos de ruídos introduzidos pelo filtro gaussiano e os outros processos. Estes pixels se encontram em forma de pequenos clusters espalhados por toda a imagem sem conexão com a rede de vasos. Quando o algoritmo percorrer a imagem irá dividi-la em várias regiões com tamanhos determinados, ficando fácil a tarefa de excluir apenas os clusters pelo seu tamanho.

Uma pequena adaptação ao algoritmo foi implementada. Consideramos em cada passo não apenas os vizinhos $p(x-1,y)$ e $p(x,y-1)$ de $p(x,y)$ mas estaremos levando em consideração um conjunto maior de vizinhos: $p(x-1,y)$, $p(x-1,y-1)$, $p(x,y-1)$ e $p(x+1,y-1)$, conforme figura abaixo:



Algoritmo de Hoshen-Kopelman



Modificação proposta

Fig 41 Modificação algoritmo Hoshen-Kopelman

Esta simples adaptação do algoritmo faz com que uma quantidade maior de clusters com tamanho também maior sejam criados. A figura abaixo mostra a aplicação do algoritmo de Hoshen-Kopelman adaptado com o intuito de retirar os ruídos.

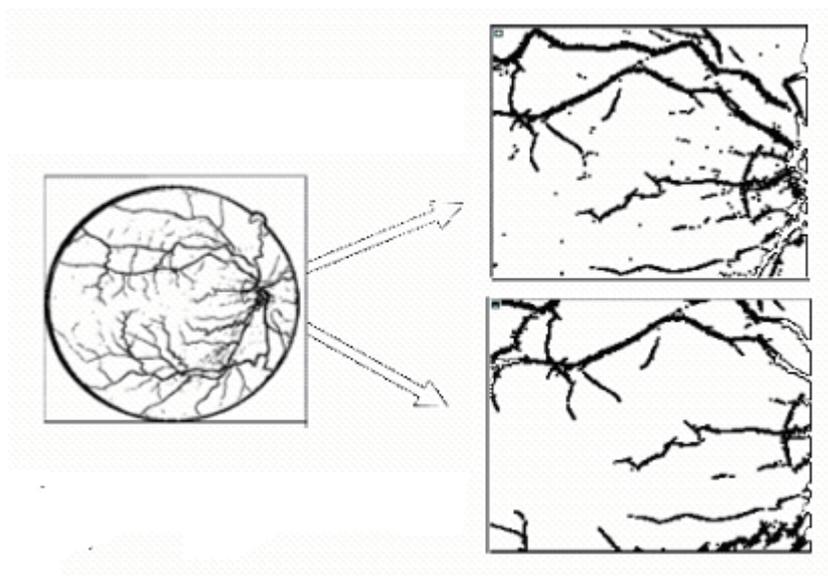


Fig 42 Imagem mostrando a aplicação do algoritmo de Hoshen-Kopelman. Acima a imagem antes e abaixo a imagem após a passagem do algoritmo

Após a aplicação do algoritmo de Hoshen-Kopelman, podemos ainda aplicar um método de homogeneização da imagem com o intuito de fechar os pontos das bordas que estão abertos, ou seja, que pertencem a borda mais não foram detectados, este procedimento consiste em olharmos para os vizinhos de oito do ponto $p(x,y)$ e associar o valor 255 para o ponto $p(x,y)$ se 3 ou mais destes vizinhos são também igual a 255.

3.5.2.ROC Analysis

A análise ROC (Receiver Operating Characteristic) é uma ferramenta poderosa para medir e especificar problemas no desempenho

do diagnóstico em medicina. Esta análise por meio de um método gráfico simples e robusto, permite estudar a variação da sensibilidade e especificidade, para diferentes valores de corte.

A área abaixo da curva ROC está associada ao poder discriminante de um teste de diagnóstico. Analiticamente, a área abaixo da curva ROC pode ser determinada através de métodos de resolução numérica, tipo regra do trapézio, métodos estatísticos e estimativa de máxima verossimilhança.

Geometricamente, a curva ROC é um gráfico de pares "x" e "y" (que correspondem, a especificidade e á sensibilidade, respectivamente) num plano designado por plano ROC unitário. A designação de plano ROC unitário, deve-se ao fato das coordenadas deste gráfico representarem medidas de probabilidade, e por conseguinte variarem entre zero e um.

A Análise ROC teve origem na teoria da decisão estatística e foi desenvolvida entre 1950 e 1960 para avaliar detecção de sinais de radar e no uso em psicologia. Posteriormente foi aplicado a uma grande variedade de exames médicos e em particular às imagens médicas.

O sistema de coordenadas ROC apresenta como ordenada a proporção de acertos TPR (True Positive Rate) que designa à sensibilidade e como abscissa a proporção de falsos alarmes FPR (False Positive Rate) que designa especificidade além de outras métricas , definidas a partir da tabela de contingência abaixo:

Obtido x Real	Open(p)	Close (n)
OPEN(P)	TP	FP
CLOSE(N)	FN	TN

- TP = True Positive (valores coincidentes positivos)
- FN = False Negative (Valores negativos no teste e positivos na referência)
- FP = False Positive (Valores positivos no teste e negativo na referência)
- TN = True Negative (Valores coincidentes negativos)

- $TPR = \frac{TP}{TP + FN}$ True Positive Rate
- $FNR = \frac{FN}{TP + FN}$ Positive Error Rate
- $TNR = \frac{TN}{TN + FP}$ True Negative Rate
- $FPR = \frac{FP}{TN + FP}$ False Positive Rate
- $PPV = \frac{TP}{TP + FP}$ Positive Predictive Value
- $NPV = \frac{TN}{TN + FN}$ Negative Predictive Value

Quando as proporções são projetadas linearmente, os valores de coordenadas variam de zero até um sendo delimitada por um quadrado unitário. A diagonal positiva é designada linha do acaso em que $TPR = FPR$ e a diagonal negativa corresponde a $TPR = 1 - FPR$. A figura abaixo mostra o sistema de coordenadas ROC.

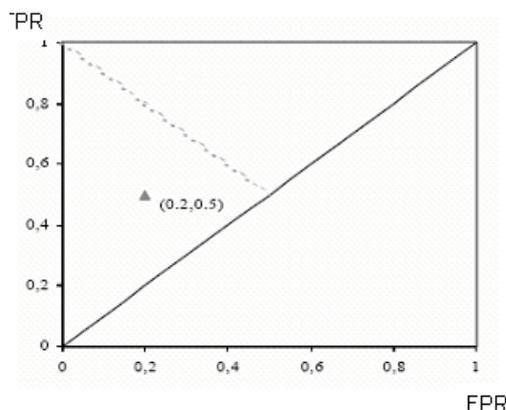


Fig 43 – Curva ROC

A fração de TPR ou verdadeiros positivos corresponde a probabilidade de decidir que a característica em questão está presente quando realmente está presente. A fração de TNR ou verdadeiros negativos corresponde a probabilidade de decidir que a característica está ausente quando ela está realmente ausente.

Para efeito de comparação de imagens dizemos que o valor TP (True Positive) é quando detectamos um pixel $p(x,y)$ como sendo verdadeiro (detectamos como vaso) na imagem que segmentamos e o

pixels $p'(x,y)$ correspondente na imagem de referência é um vaso também. TN ocorre quando detectamos um pixel $p(x,y)$ na imagem segmentada que não pertence a um vaso e na imagem de referência o pixel $p'(x,y)$ também não pertence a um vaso. FP ocorre quando $p(x,y)$ é positivo e $p'(x,y)$ é negativo para vaso e por fim FN (Falso negativo) quando $p(x,y)$ é negativo para vaso e $p'(x,y)$ é positivo para vaso. Sendo assim a sensibilidade, ou TPR, mede o quanto o método é sensível em segmentar os vasos, por outro lado, a especificidade, ou FPR, indica o quanto o método é preciso nesta medida.

Para determinarmos a curva ROC devemos calcular todos os pontos TP, TN, FP, FN da imagem segmentada para valores de i ($0 \leq i \leq 255$), montar a tabela de referência e em seguida calcular o valor de TPR e FPR para cada i , só então plotar os pontos TPR e FPR.

A área abaixo da curva ROC definida por A_z representa um fator que poderá servir de comparação do método aplicado com outros métodos. Evidentemente que a forma da curva nos indica se o método é eficiente ou não.

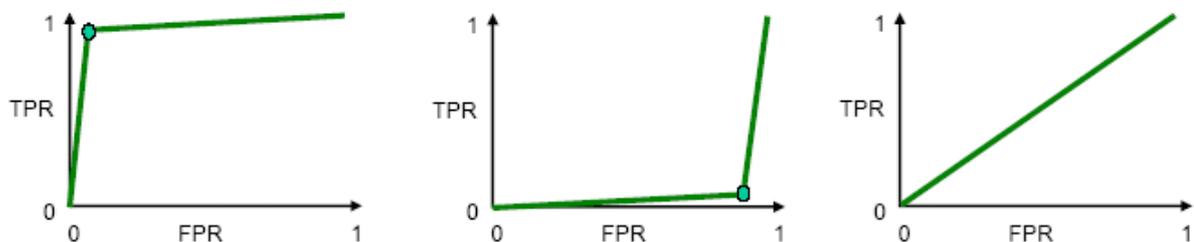


Fig 44 Bom classificador, Péssimo Classificador e mal classificador

4. RESULTADOS E DISCUSSÃO

As 20 imagens foram submetidas as seguintes técnicas de processamento nesta seqüência:

- Normalização da imagem (componente green)
- Filtro da Média
- 2d Matched Filter (Filtro Gaussiano)
- Laplaciano
- Detector de Bordas Robert.
- Algoritmo de percolação Hoshen-Kopelman
- Procedimento para retirada das bordas externas

Durante a pesquisa verificamos que a alteração da ordem e/ou a exclusão de alguns destes procedimentos muitas vezes causam diminuição na eficiência absoluta da técnica.

Em seguida todas as imagens foram submetidas a comparações com suas respectivas imagens segmentadas. A comparação foi feita da seguinte forma: Foram contados todos os pixels segmentados automaticamente na imagem através do processamento, em seguida foram contados todos os pixels da imagem segmentada manualmente por um observador do projeto DRIVE. Cada pixel da imagem segmentada através do procedimento foi comparada com o seu respectivo pixel na imagem manual. Cada concordância ou não concordância foi registrada. PPV é um índice que mede a proporção de pixels detectados coincidentes, em relação a todos os pixels detectados e indica a sensibilidade do teste. Para o calculo usamos a seguinte forma:

$$PPV = \frac{TP}{TP + FP}$$

Onde: TP (True Positive) é o número de pixels coincidentes entre as duas imagens e (TP+FP) é o número de pixels segmentados na imagem, esta grandeza diz respeito a precisão da segmentação

Foi também registrada a TPR (True Positive Rate) que diz respeito à sensibilidade do método ou seja sua eficiência absoluta do código

através da proporção entre o número de pixels coincidentes com o total da imagem segmentada manualmente, da seguinte forma:

$$TPR = \frac{TP}{TP + FN}$$

Onde (TP+FN) é o número de pixels segmentados manualmente.

Resultados obtidos estão sintetizados nas tabelas de contingência abaixo, os números acima das colunas da tabela indicam o número da amostra no projeto DRIVE.:

	21	22	23	24	25	26	27
Automático	22320	29399	27086	30622	20578	35959	26526
Manual	24658	29809	21723	38229	31669	27573	29073
TP	15071	18845	13614	22453	14738	19359	17286
FP	7249	10554	13472	8169	5840	16600	9240
FN	9587	10964	8109	15776	16931	8214	11787
TN	298053	289597	294765	283562	292451	285787	291647
PPV	0.675	0.641	0.502	0.733	0.716	0.538	0.651
TPR	0.611	0.632	0.626	0.587	0.465	0.702	0.594

Resultados obtidos nas amostras 21 à 27

	28	29	30	31	32	33	34
Automático	32325	34757	28285	18196	23518	23450	28756
Manual	32228	27751	25884	19898	26984	26686	32287
TP	20240	19753	16894	10988	15808	15395	16477
FP	12085	15004	11391	7208	7710	8055	12279
FN	11988	7998	8990	8910	11176	11291	15810
TN	285647	287205	292685	302854	295266	295219	285394
PPV	0.626	0.568	0.597	0.603	0.672	0.656	0.572
TPR	0.628	0.711	0.652	0.552	0.585	0.576	0.510

Resultados obtidos nas amostras 28 à 34

	35	36	37	38	39	40
Automático	39434	41774	42059	27155	32680	35578
Manual	28612	35884	28841	28477	28348	25001
TP	21302	24557	21326	17193	19655	19137
FP	18132	17217	20733	9962	13025	16441
FN	7310	11327	7515	11284	8693	5864
TN	283216	276859	280386	291521	288587	288518
PPV	0.540	0.587	0.507	0.633	0.601	0.637
TPR	0.744	0.684	0.739	0.603	0.693	0.765

Resultados obtidos nas amostras 35 à 40

Nas imagens abaixo são mostrados alguns resultados obtidos, na seqüência: imagem original, segmentação manual, e resultado obtido neste trabalho.

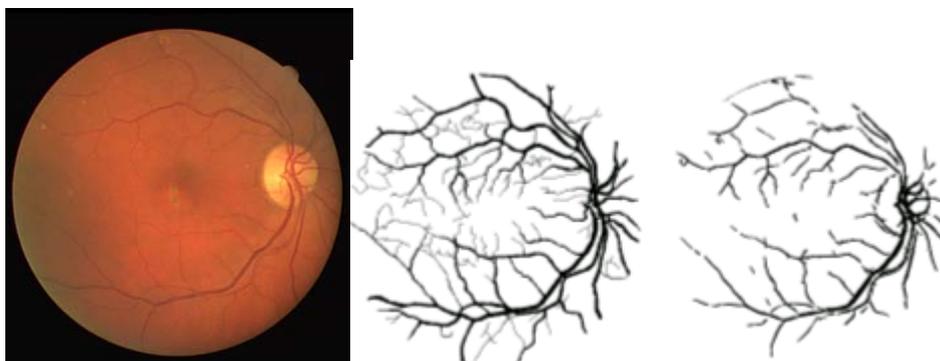


Fig 45 - Amostra 25

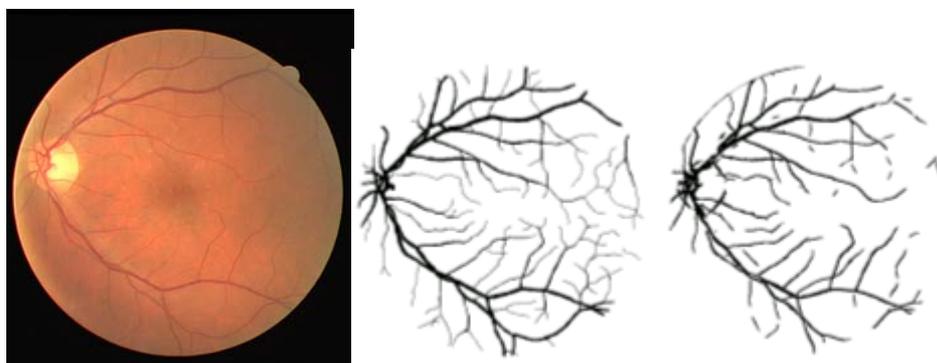


Fig 46 - Amostra 21

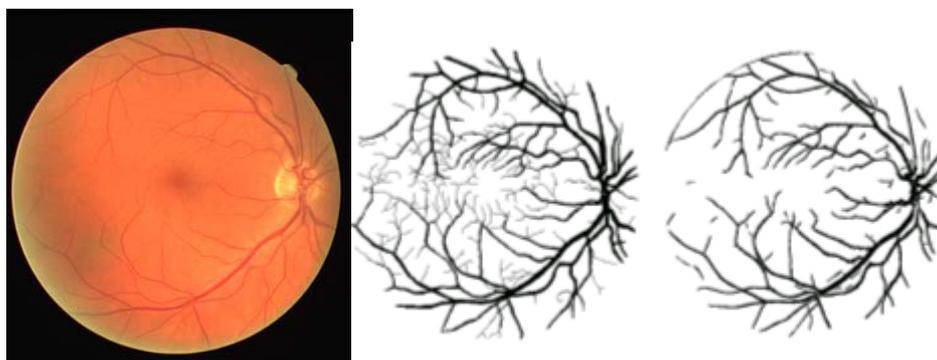


Fig 47 - Amostra 24

O índice PPV obtido indica a sensibilidade do teste e varia em torno de 62% de coincidências com a segmentação manual, o que é compatível com níveis atingidos com outros métodos propostos na literatura. Uma vantagem de método proposto aqui, é que imagem segmentada tem alta conectividade (maior do que os outros métodos) e

que representa uma outra forma de quantificar a qualidade da segmentação.

Um fator que introduz erros na imagem é o algoritmo de detecção de vasos 2d matched filter detectar a borda da imagem e a borda do nervo ótico. O procedimento para corrosão da borda não consegue retirar todos os pixels da borda, apenas bordas com largura máxima de 6, e não foi aplicada nenhuma outra técnica para detecção do nervo ótico.

Uma imagem (amostra 21) foi submetida à técnica de análise da curva ROC e definição do fator Az (área sobre a curva). Para esta análise a imagem foi submetida apenas aos seguintes tratamentos: Normalização, 2d Matched Filter, filtro da media e para cada valor de i ($0 \leq i \leq 255$) foi passado os algoritmos de Hoshem-Kopelman e corrosão da borda. O resultado obtido foi $Az = 0.9202$, e a curva é mostrada abaixo:

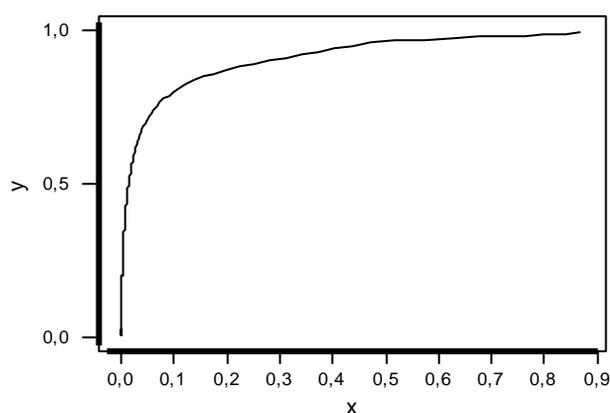


Fig 48 ROC Analysis - $Az=0,9202$

O valor de $Az= 0.9202$ obtido representa um limite de eficiência do método como um todo, observamos que este valor é superior ao método de detecção de vaso utilizado (no nosso caso o 2d matched filter) o que indica que o procedimento melhorou o resultado obtido na segmentação. Abaixo calculamos a curva ROC para o método 2d matched Filter e obtivemos um $Az = 0.8936$.

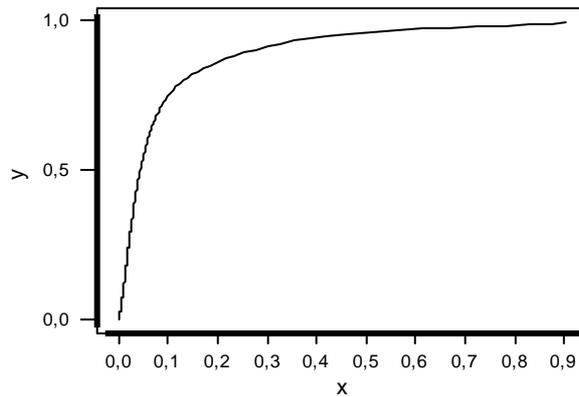


Fig 49 ROC Analysis 2d Matched Filter - $A_z=0,8936$

Outras técnicas de detecção de vasos disponíveis na literatura obtiveram os seguintes scores para A_z :

Técnica	A_z
Pixel Classification [22]	0.9294
Zana et al [21]	0.8084
Jiang et al [23]	0.9114
Chaudhuri et al [08]	0.7878
Hoover [12]	0.7590

A técnica apresentada por este trabalho tem um score melhor que alguns outros trabalhos apresentados na literatura com a vantagem de que neste procedimento os vasos se encontram, na maior parte, conectados isto é fundamental para e serve como base para alguns testes como medidas de tortuosidade, etc. Outro fator é que o nível do ruído é controlado pelo algoritmo de percolação de Hoshen-Kopelman. O método “pixel classification” proposto em [22] é baseado em resposta do filtro gaussiano (2d matched filter) e na classificação do pixel através do algoritmo que classifica os Knn vizinhos de uma janela. Este método apresenta uma grande quantidade de ruído e uma baixa conectividade.

5. CONCLUSÃO

O procedimento proposto neste trabalho para detecção e segmentação de vasos sanguíneos de imagens de retina, foi uma combinação do algoritmo “2d matched filter” com o algoritmo de Hoshen-Kopelman. O Resultado obtido é bom quando comparados a outros valores na literatura, com um valor $Az=0.9202$ para a área da curva ROC, e este é um fator de comparação utilizado por vários trabalhos científicos publicados.

Por outro lado, este método gera uma estrutura segmentada de alta conectividade (maior do que outros métodos propostos), que representa um outro fator importante para análises posteriores de imagens segmentadas (e.g. tortuosidade, distribuição de tamanhos e de ângulos de segmentos, dimensão fractal, etc.).

Como resultado deste trabalho apresentamos o software RAS que implementa as rotinas descritas neste trabalho.

Este trabalho representa um primeiro passo na criação de um banco de dados de imagens segmentadas de olhos que sejam considerados normais ou com vários tipos de patologias, cuja análise posterior pode ser feita de formas diversas, a fim de descobrir se existe uma relação que possa agrupá-las, e assim detectar uma possível patologia.

6. REFERÊNCIAS BIBLIOGRÁFICAS

- [1].FERRIS FL. **How Effective are treatments for diabetic retinopathy?**.JAMA 1993.P-1290-1291
- [2].A ESTRUTURA INTERNA DO OLHO HUMANO.in **ENCICLOPEDIA Digital Image Processing: PIKS inside/** W. Prat, - 3rd Ed., 2001
- [3].O.CHUTATAPE et all. Retianl Bloob Vessel detection and tracking by matched gaussian and Kalman filters.in **PROCEEDINGS OF THE 20TH ANNUAL INTERNATIONAL CONFERENCE OF IEEE ENGEERING IN MEDICINAL AND BIOLOGY SOCITY.** vol 20 n. 6 1998
- [4]. J. D. FOLEY, VAN DAM.**Fundamentals of interactive computer graphics,** Addison-Wesley,1997.
- [5].W. K. PRATT. **Digital Image Processing.** 2 ed A Willey Intercience Publication 1991.
- [6].RAFAEL C. GONZALES, RICHARD E. WOODS. **Processamento de imagens digitais.**São Paulo Edgard Blucher. 508 p
- [7].EDUARDO AVEVEDO E AURA CONCI.**Computação gráfica teoria e prática.**2 ed.Rio de Janeiro.Elsevier 2003.351 p.
- [8].SUBHASIS CHAUDHURI et al.Detection of blood vessels in retinal images using two-demensional Matched Filters.**IEEE Transaction on medical imaging.**vol 8 n 3.Set 1989.
- [9].JOES STAAL et al. Ridge-Based vessel segmentation in color images of the retina. **IEEE Transactions on medical imaging.**vol 23 n 4 abr 2004
- [10].HUIQI LI OPAS CHUTATAPE. Fundus image fetures Extraction in PROCEEDINGS OF THE 22nd ANUAL EMBSINTERNATIONAL CONFERENCE.2000, Chicago Il. **anais**
- [11].O. CHUTATAPE et al. Retinal bloob vessel detection and tracking by matched gaussian and Kalman filters. In PROCEEDINGS OF THE 20th ANNUAL CONFERENCE OF THE IEEE ENGEINEERING IN MEDICINE AND BIOLOGY SOCIETY.val 20 n 6 1998

- [12].ADAM HOOVER et al. Locating Blood vessel in retinal images by piecewise threshold probing of a matched filter response. **IEEE transaction on medical imaging** .vol 19 n 3 mar 2000
- [13].LUO GANG et al. Detection and measurement of retinal vessels in fundus images using amplitude modified second-order gaussian filter. **IEEE transactions on biomedical engineering**. Vol 49 n 2 fev 2002
- [14].ANA CRISTINA DA SILVA BRAGA. **Curvas ROC aspectos funcionais e aplicações**. 2000. 267 p. Tese (Engenharia de produção e sistemas. Métodos numéricos e estatísticos). Universidade do Minho. Braga Portugal.
- [15].J. Hoshen and R. Kopelman. Percolation and cluster distribution.I. cluster multiple labeling technique and critical concentration algorithm. **Physical review B**. Vol 14 n 8. out 1976
- [16].B. FANG et al, **Recostruction on vascular structures in retinal images** in ICPI03, 2003, p 157-160.
- [17].CASTLEMAN K.R. **Digital image processing**. Prentice-Hall 1992.
- [18].HOTELLING. Analysis of a complex of statical variables into principal component. **Jornal Educ Psychol**. Vol 24 p417-441,498-520
- [19].BLUM H. A transformation for extracting new descriptors of shape. **Models for the perception of speech and visual form**. WathenDunn. 1967
- [20].Marr. D and Hildreth. Theory of edge detection. ProcedureR. Soc. 1980. Vol b207p 187-217
- [21].F. ZANA AND J. KLEIN. A multimodal registration algorithm of eye fundus images using vessels detection and Hough trnsform. **IEEE transaction on medical imaging**.1999. p 419-428.
- [22].M. NIEMEIJER et al. **Comparative study of retinal vessel segmentation methods on a new publicly available database**. disponivel em <http://www.isi.uu.nl/Research/Databases> acesso em 10 dez. 2005.

- [23].X. JIANG AND D. MOJON. Adaptive local thresholding by verification-based multithreshold probing with application to vessel detection in retinal images, **IEEE Transactions on Pattern Analysis and Machine Intelligence** 2003, p. 131–137.
- [24].A. HOOVER and M. GOLDBAUM, Locating the optic nerve in a retinal image using the fuzzy convergence of the blood vessels, **IEEE Transactions on Medical Imaging**. 2003, p. 951–958, 2003.
- [25]. F. ZANA and J. KLEIN, Segmentation of vessel-like patterns using mathematical morphology and curvature evaluation, **IEEE Transactions on Image Processing**. 2001.p. 1010–1019.
- [26]. HANLEY, J. A. and B. J. MCNEIL. A Method of Comparing the Areas under Receiver Operating Characteristic Curves, **Radiology**.1983.p 148 :839– 843 .
- [27].HALL E.L. Almost uniform distributions for computer image enhancement. **IEEE Transactions computers**.1974.Vol. C-23,n 2, p 207-208.
- [28].SCHAKOLFF, R.J. **Digital image processing and computer vision**. New York, John Wilians.1989.
- [29].PITAS I and VENETSANOPOULOS A.N. **Nonlinear digital filters: priciples and applications**.1990. Boston ed. Kluger.