

Eloisa Marciana Kolberg Theisen

**CONFIABILIDADE NO PROCESSO DE RASTREABILIDADE
POR MEIO DE ANÁLISE DE IMAGENS RETINAIS**

Dissertação apresentada ao Curso de Pós-Graduação em Sistemas e Processos Industriais – Mestrado – da Universidade de Santa Cruz do Sul, para a obtenção do título de Mestre em Sistemas e Processos Industriais.

Orientador: Prof. Dr. Rubén Edgardo Panta Pazos

Co-orientador: Prof. Dr. Rolf Fredi Molz

Santa Cruz do Sul, março de 2008.

Eloisa Marciana Kolberg Theisen

**CONFIABILIDADE NO PROCESSO DE RASTREABILIDADE
POR MEIO DE ANÁLISE DE IMAGENS RETINAIS**

Esta dissertação foi submetida ao Programa de Pós-Graduação em Sistemas e Processos Industriais – Mestrado, Área de Concentração em Controle e Otimização de Processos Industriais, Universidade de Santa Cruz do Sul – UNISC, como requisito para a obtenção do título de Mestre em Sistemas e Processos Industriais.

Dr. Rubén Edgardo Panta Pazos
Professor Orientador

Dr. Rolf Fredi Molz
Professor Co-orientador

PhD. Rodney Carlos Bassanezi

PhD. Marco Flôres Ferrão

AGRADECIMENTOS

Inicialmente agradeço a **Deus** por estar neste momento realizando este trabalho e toda e qualquer obra de sua criação, pois apesar de nem sempre compreendermos muito bem as suas façanhas, sabemos que há algum propósito nelas.

Agradeço ao meu orientador, Prof. Dr. **Rubén Edgardo Panta Pazos**, pela orientação e paciência na correção das minhas falhas e detalhes que passam despercebidos, além do grande incentivo às apresentações/submissões de trabalhos em eventos. É colocando-se a “cara para bater” que se aprende! Sem contar a infalível memória para fórmulas!

Agradeço também ao meu co-orientador, Prof. Dr. **Rolf Fredi Molz**, por ter aceitado despende do seu tempo, com enorme paciência, nas inúmeras correções e redirecionamentos do trabalho ao longo do período e principalmente por ensinar de forma extraordinária programação. Realmente realiza milagres!

Agradeço também **aos professores membros desta banca** por terem aceitado a fazerem parte desta e assim fazem-me sentir honrado por tais presenças. Também um agradecimento muito especial a **todos os professores deste curso** de pós com os quais tive contato em aulas e enriqueceram minhas idéias, me auxiliaram em questões de algoritmos ou IA e até mesmo quimiometria... pude aplicar muitos conhecimentos que outrora nem teria a imaginação de utilizar. Um real e verdadeiro: Parabéns!!! Enriqueceram-me muito e de forma inexplicável!

Gostaria de agradecer também à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – **CAPES** pela bolsa concedida, viabilizando minha participação neste Programa de Pós-Graduação.

Agradeço à Universidade de Santa Cruz do Sul – **UNISC** e a todos os docentes e colaboradores do **Programa de Pós-Graduação em Sistemas e Processos Industriais** que de alguma forma contribuíram para esta pesquisa. Faz-se necessário agradecer à secretaria deste programa de pós-graduação e, especialmente, às secretarias Janaina Iochims Ramires Haas, Camila Borges, Cláudia de Souza Lopes e Lucas Nobre que, por incontáveis vezes,

foram prestativos e eficientes, ultrapassando o limite de suas obrigações para que os mestrandos não se desviassem de suas pesquisas mais do que o necessário, para realizarem atividades burocráticas.

Aos demais **mestrandos e bolsistas de pesquisa deste programa de pós-graduação**, com quem tive mais contato também merecem os meus mais sinceros agradecimentos, pois foram muito mais que colegas e, ao contrário do esperado, formaram um conciso grupo de amigos. Valeu pessoal, especialmente o grupo MM's: **Márcia Werlang & Marlize Rizzi!**

Não posso esquecer da amizade ocorrida em virtude de congressos com **Karla Christina Tribuzy Bandeira** que, através do Prof. **Rodney Carlos Bassanezi**, proporcionou nosso conhecimento e variadas trocas de experiências com as “lindinhas” arraias do Rio Negro!

Meus **amigos/colegas da EMEF Profª Odila Rosa Scherer**, que foram muito compreensivos e que sempre formam uma equipe de real trabalho: Girlene Simone Manganelli, Isabel Cristina Sackser, João Batista Gomes, Noely Sausen Stein e Simone Maria Schwedler. Vocês são D++++!!!!

A **minha família** pelo suporte psicológico, financeiro e afetivo. À paciência e carinho de **meus pais** e parentes que, por vezes, seguram barras pesadas, momentos difíceis, quando estive longe, principalmente minha mãe **Meraci** e meu pai **Edison** que sempre se emocionaram muito ao me ver galgar um grau maior de educação além de me apoiarem muito... Um especial agradecimento ao meu filho **Thales** e meu esposo **Leandro** pela saudável competição entre eles e com o curso que estive freqüentando... apesar de tudo sempre me disseram: Segue em frente, arregace as mangas e um te amo carinhoso... sem contar as vibrações da **Nicole** que ainda nem conhece o mundo afora...

Por fim, agradeço a todas as pessoas que ajudaram, direta ou indiretamente, durante a realização deste mestrado. A todos vocês o meu muito obrigado!

Salmo 144

- 1 *De Davi.
Bendito seja o Senhor, meu rochedo,
que adestra minhas mãos para o combate,
meus dedos para a guerra;*
- 2 *ele é meu aliado e minha fortaleza,
meu baluarte e meu libertador,
meu escudo, que me dá abrigo;
ele me submete meu povo.*
- 3 *Senhor, o que é o homem para o
tomares em consideração?
O mortal, para nele pensares?*
- 4 *O homem é semelhante a um sopro;
seus dias como a sombra que se esvai.*
- 5 *Senhor, inclina os céus e desce,
toca os montes, para que fumeguem!*
- 6 *Fulmina os raios e dispersa-os,
dispara tuas flechas e dissemina-as!*
- 7 *Do alto estende a mão,
salva-me e livra-me das imensas águas:
do poder dos estrangeiros,*
- 8 *cuja boca fala mentiras,
e cuja destra é mão de perjúrio!*
- 9 *Entoar-te-ei, ó Deus, um cântico novo,
a ti cantarei um hino na harpa de dez cordas.*
- 10 *Tu, que das a vitória aos reis
e salvas Davi, teu servo,*
- 11 *salva-me da espada cruel,
livra-me do poder dos estrangeiros,
cuja boca fala mentiras,
e cuja destra é mão de perjúrio!*
- 12 *Sejam como plantas nossos filhos,
já desenvolvidos na adolescência;
nossas filhas, como colunas bem talhadas,
como esculturas de um palácio!*
- 13 *Nossos celeiros estejam repletos,
fornecendo provisões e mais provisões!
Nossos rebanhos multipliquem-se aos milhares,
às dezenas de milhares pelos pastos!*
- 14 *Nossas reses andem prenhes,
sem acidente nem perda
a deplorar em nossas praças!*
- 15 *Feliz o povo, ao qual assim acontece!
Feliz o povo cujo Deus é o Senhor!*

RESUMO

A presente dissertação apresenta os processos envolvidos na aplicação do sistema de reconhecimento da identidade de indivíduos, mais precisamente de bovinos e bufalinos, que é um dos itens mais importantes na implementação do processo de rastreabilidade em carnes. Esforços internacionais e nacionais visam um controle mais rígido da qualidade, a proveniência e certificação de carnes, que vai desde a propriedade até a indústria. A identificação dos indivíduos será realizada por varredura de retina, um dos métodos mais precisos em biometria. O processamento e análise de variadas imagens de retina, provenientes da literatura e do banco de imagens adquirido, são realizados conjuntamente com *softwares* matemáticos consagrados e *softwares* livres sendo que os procedimentos serão transpostos à elaboração de um algoritmo para embarcação em equipamento captura de imagens, que incorporará o sistema de rastreabilidade da empresa credenciadora. O processo ocorre com a fase de identificação automática das características retiniais, através de processos clássicos com imagens, aplicação da Transformada Hough na detecção de coordenadas centrais da Região de Interesse no estudo, o realce de características proporcionado pela Congruência de Fase, aliados à aplicação de Bancos de Filtros Bivariados de Transformada *Wavelet* na compactação dos dados, determinando assim as características a serem analisadas. Para a classificação dos indivíduos foi aplicada a proposta de Análise de Matrizes Esparsas e a proposta *Eigenretina*, criada nesta dissertação, embasada na Análise de Componentes Principais e em estudos anteriores sobre biometria e classificação de padrões.

Palavras-chave: Transformada *Wavelet*, Congruência de Fase, Processamento de Imagens, Classificação de Formas, Análise de Componentes Principais.

ABSTRACT

In this dissertation is presented the involved processes that appear in the application of the recognizing system about individual identification, specially bovines and buffalos, that are one of itens more remarkable in the implementation of the traceability process of meats. International and Brazilian efforts aim at a more rigid control of the quality, the origin and certification of meats, going since the property until the industry. The individual identification will be carried through by sweepings of retina, one of the methods most necessary in biometrics. The processing and analysis of diverse images of retina, that appear in literature and bank of images acquired, are carried through jointly with free softwares and consecrated math softwares, such that the procedures will be transposed to the elaboration of an algorithm for embebbed software in equipment capture of images, that will incorporate the system of traceability of the authorized company. The process occurs with the phase of automatic identification of the characteristics, through classic processes with images, application of the Hough Transform into the detection of central coordinates of the Region of Interest, the emphases of the characteristics for the Phase Congruency, allies to the application of Banks of Bivariate Wavelet Filters in order to data compaction, thus determining the characteristics to be analyzed. For the classification of the individuals it was applied the proposal of Sparse Matrix and the Eigenretina proposal, created in this dissertation, based on the Principal Component Analysis and previous studies on biometric and pattern classification.

Keywords: Wavelet Transform, Phase Congruency, Image Processing, Shape Classification, Principal Component Analysis.

LISTA DE FIGURAS

Figura 1. Equipamento que Captura Imagens da Retina de Bovino.....	20
Figura 2. Fotografia da Íris e o <i>IrisCode</i> ®(acima).	23
Figura 3. Elementos de Análise da Íris.....	24
Figura 4. Alguns Elementos de Análise da Impressão Digital	25
Figura 5. Par de <i>Wavelets</i> 2D de Gabor.....	25
Figura 6. Sistema de Coordenadas Polares para a Utilização do Par <i>Wavelet</i> Gabor.	26
Figura 7. Imagens do Olho Esquerdo de um Indivíduo Humano.....	29
Figura 8. Equalização de Histograma dos Valores de Cinza da Figura 7(a).	31
Figura 9. Elemento Estruturante em Cruz (a) e sua Representação Morfológica na Forma Digital (b).	32
Figura 10. Exemplos de Erosão Binária da Região de Interesse (RI) de IM002294.TIF.....	34
Figura 11. Exemplo de Dilatação Binária da Região de Interesse de IM002294.TIF.....	35
Figura 12. Normalização da Região de Interesse de IM002294.TIF.....	36
Figura 13. Modelo de Congruência de Fase	38
Figura 14. Ilustração do Arranjo da Construção da Energia em PC.....	39
Figura 15. Comparação de Efeitos da Congruência de Fase	41
Figura 16. Aplicação da Centralização da Região de Interesse (RI) por Transformada Hough.	44
Figura 17. <i>Wavelet</i> -mãe <i>Symmlet</i> 8, em Diferentes Escalas e Localizações.	46
Figura 18. Análise ou Compactação de Sinal, em Vários Níveis, por Banco de Filtros <i>Wavelet</i>	48
Figura 19. 1º Nível de Compactação Daub4 do Sinal Gerado pela Equação $g(x) = 20x^2(1 - x)^4 \cos(12\pi x)$	48
Figura 20. Compactação até o 3º nível Daub4 do Sinal Gerado pela Equação $g(x) = 20x^2(1 - x)^4 \cos(12\pi x)$	52
Figura 21. Análise da Eliminação de Ruídos de um Sinal Compactado até o 3º Nível de Compactação	54
Figura 22. Octógono com as Devidas Compactações e Detecções de Bordas.	55
Figura 23. Resultados do 1º Nível de Compactação com Uso de Banco de Filtros Bivariados de Transformada <i>Wavelet</i> de Haar na Imagem IM002294.TIFF.	57
Figura 24. 1º e 2º Níveis de Compactação na Aplicação de Banco de Filtros Bivariados de Transformada <i>Wavelet</i> de Haar.	59
Figura 25. 1º e 2º Níveis de Compactação com Uso de Bancos de Filtros Bivariados de Transformada <i>Wavelet</i> Daub4.	61

Figura 26. Comparação dos Dados a_1 no Primeiro Nível de Compactação com Uso de Banco de Filtros Bivariados de Transformada <i>Wavelet</i> de Haar e Daub4.....	62
Figura 27. Testes Iniciais Sobre Imagem Originalmente Colorida do Grupo de Discussões. .	73
Figura 28. Seleção de Imagens Retinais de um Mesmo Paciente e os Respectivos “Blocos-Resumo”	74
Figura 29. Esquema da Implantação do Sistema de Identificação Biométrico Dentro do Sistema de Rastreabilidade Bovina.	76
Figura 30. Estrutura do Sistema de Identificação pela Retina, Sob o Ponto de Vista da Visão Computacional.....	78
Figura 31. Imagem, Histograma e Limiarização.	80
Figura 32. Fluxograma do Processamento Padrão das Imagens Retinais para Classificação. .	83
Figura 33. Análise de Matrizes Esparsas do Conjunto de Treinamento em (a) e do Conjunto de Teste em (b).	85
Figura 34. Cenário da Identificação Retinal I.....	88
Figura 35. Matriz do Conjunto de Treinamento de Forma Vetorizada.	89
Figura 36. Representação do <i>RetinaSpace</i> dos 30 Elementos de Treinamento.....	90
Figura 37. Vetores de Imagens Centrados A em (a) e a Base de Vetores <i>Eigenretina</i> em (b).	91
Figura 38. PCA do Conjunto de Treinamento em (a) e da Imagem de Teste nº10 em (b).	92
Figura 39. Reconstrução Bidimensional do Conjunto de 29 Imagens da <i>Eigenretina</i>	93
Figura 40. Cenário da Identificação Retinal II	94
Figura 41. <i>Eigenretina</i> das Imagens Escala de Cinza em (a) e Projeção da Imagem de Teste nº 10 em (b).....	95

LISTA DE QUADROS

Quadro 1. Coeficientes <i>Scaling</i> de Daub4.....	50
Quadro 2. Coeficientes <i>Wavelets</i> de Daub4.	51
Quadro 3. Conjunto de Filtros Bivariados de Transformada <i>Wavelet</i> de Haar	56
Quadro 4. Banco de Filtros Bivariados de Transformada <i>Wavelet</i> Daub4.....	60
Quadro 5. Coeficientes do Banco de Filtros Bivariados de Transformada <i>Wavelet</i> Daub4.....	60

LISTA DE TABELAS

Tabela 1. Valores de <i>Pixels</i> Não-Coincidentes Entre as Imagens.....	85
Tabela 2. Correspondência da Legenda Utilizada para Matrizes Esparsas	86

LISTA DE ABREVIATURAS

AMS	<i>American Mathematical Society</i>
C	<i>Cosine Distance</i> – Métrica utilizada em classificação
CCD	<i>Charged Coupled Device</i> (componente eletrônico que converte a luz em informações digitais)
DNA	<i>Deoxyribonucleic acid</i> (Ácido Desoxirribonucléico)
DPI	<i>dots per inch</i> (pontos por polegada)
EE	Elemento Estruturante
ERAS	Estabelecimentos Rurais Aprovados no SISBOV
FBI	<i>Federal Bureau Investigation</i> – USA
GPS	<i>Global Positioning System</i>
ICA	<i>Independent Component Analysis</i>
ITUNISC	Incubadora Tecnológica da Universidade de Santa Cruz do Sul (RS/Brasil)
JPG	<i>Joint Photographic Experts Group</i> – Formato de Arquivo de Imagem
L1	<i>Manhattan Distance</i> – Métrica utilizada em classificação
L2	<i>Euclidean Distance</i> – Métrica utilizada em classificação
LDA	<i>Linear Discriminant Analysis</i>
LED	<i>Light Emitting Diode</i> (Diodo Emissor de Luz)
MAPA	Ministério da Agricultura, Pecuária e Abastecimento
MRA	<i>Multiresolution Analysis</i>
NIR	<i>Near Infrared</i> – Infravermelho próximo
NMSU	<i>New Mexico State University</i> - Universidade do Estado do Novo México (EUA)
NO	Nervo Óptico
PC	<i>Phase Congruency</i> (Congruência de Fase)
PCA	<i>Principal Component Analysis</i> (Análise de Componentes Principais)
PIXEL	<i>Picture Element</i> (Elemento de Imagem)
RI	Região de Interesse
RMS	<i>Root Mean Square</i>
SDA	Secretaria de Defesa Agropecuária
SDA	Secretaria de Defesa Agropecuária
SISBOV	Sistema Brasileiro de Identificação e Certificação de Origem Bovina e Bubalina
TDW	Transformada Discreta <i>Wavelet</i>
TIF	<i>Tagged Image File Format</i> – Formato de Arquivo de Imagem
TW	Transformada <i>Wavelet</i>

SUMÁRIO

INTRODUÇÃO.....	15
1 FUNDAMENTAÇÃO TEÓRICA	18
1.1 Rastreabilidade e Certificação da Qualidade em Animais de Corte.....	19
1.2 Legislação Brasileira Quanto a Rastreabilidade.....	21
1.3 Sistemas Biométricos de Identificação.....	23
1.4 Fundamentos de Processamento de Imagens Retinais Digitais.....	27
1.5 Limiarização (<i>Threshold</i>) de Imagens e Operadores Morfológicos Binários	30
1.6 Normalização da Imagem em Escala de Cinza	36
1.7 Congruência de Fase.....	37
1.8 Transformada Hough.....	42
1.9 Fundamentos de Transformada <i>Wavelet</i>	45
1.9.1 Transformada <i>Wavelet</i> , de 1-D a 2-D.....	48
1.9.2 Banco de Filtros Bivariados de Transformada <i>Wavelet</i> de Haar e Daub4	55
1.10 Análise de Matrizes Esparsas	63
1.11 Classificação Baseada na Aparência - PCA	64
2 METODOLOGIA.....	71
2.1 As Imagens	71
2.2 O Esquema do Sistema de Rastreabilidade Aliada à Identificação de Indivíduos	75
2.3 O Processo de Identificação Biométrica.....	76
3 RESULTADOS	81
3.1 Processamento Padrão	81
3.2 Análise de Matrizes Esparsas	84
3.3 O Confronto dos Dados via Proposta <i>Eigenretina</i>	87
CONCLUSÕES.....	96
REFERÊNCIAS	99
ANEXOS.....	Erro! Indicador não definido.
ANEXO A – Resumos Aprovados no XXIX CNMAC (Congresso Nacional de Matemática Aplicada e Computacional) – UNICAMP-SP, 18-21 set. 2006, apresentados oralmente e publicados em sua íntegra nos anais deste evento.....	Erro! Indicador não definido.

ANEXO B – Resumo Aprovado no XIII Seminário de Iniciação Científica e XII Jornada de Ensino Pesquisa e Extensão da UNISC-SCS-RS, 23-25 out. 2006, apresentado oralmente e publicado em sua íntegra nos anais deste evento ISBN 85-7578-153-1**Erro! Indicador não definido.**

ANEXO C – Artigo Aprovado no XXX CNMAC – UFSC-SC, 3-6 set. de 2007, apresentado oralmente e publicado em sua íntegra nos anais deste evento... **Erro! Indicador não definido.**

ANEXO D – Resumo Aprovado no XIV Seminário de Iniciação Científica e XIII Jornada de Ensino Pesquisa e Extensão da UNISC-SCS-RS, 1-5 out. 2007, apresentado oralmente e publicado em sua íntegra nos anais deste evento. ISBN 978-85-7578-184-5**Erro! Indicador não definido.**

ANEXO E – Artigo Aprovado no XXVII ENEGEP (Encontro Nacional de Engenharia de Produção) Foz do Iguaçu -PR, 9-11 out. 2007, foi apresentado oralmente e publicado em sua íntegra nos anais deste evento. **Erro! Indicador não definido.**

INTRODUÇÃO

A segurança alimentar e a imagem da marca são as duas forças atrás do interesse na rastreabilidade de carnes. *Um sistema de rastreabilidade* contém elementos de identificação de animais e localidade, um banco de dados central e um processo de verificação. Na importância do controle da carne há uma legislação rigorosa no Brasil: o SISBOV (Sistema Brasileiro de Identificação e Certificação de Origem Bovina e Bubalina). Este sistema busca, aos poucos, adequar todos os produtores ao controle sanitário rígido de seus rebanhos, mas atualmente é exigência principal no quesito exportação de carne e seus derivados.

Ainda não existe uma tecnologia padronizada, tanto nacional quanto internacional, para rastrear um animal desde o nascimento até o produto final nas prateleiras, mas a agregação de processos nos quais a identificação possa ser realizada sem desconforto e com o máximo de confiabilidade garantem a qualidade do produto e maior expressão deste no mercado consumidor, conferindo prestígio à indústria que apresenta métodos rígidos no controle de sanidade.

A grande maioria da pecuária de corte é realizada com bovinos, mas há um crescente interesse por outras carnes, especialmente de búfalo, pois o mesmo, em comparação com a carne bovina apresenta vantagens nutricionais, seu couro é grosso e resistente, o manejo e os cortes de carne são semelhantes aos bovinos, e por fim, são animais mais dóceis. Processos de identificação na rastreabilidade atualmente estão sendo recentemente implantados em rebanhos suínos e ovinos (ABCB, 2006).

Um pilar muito importante do sistema de rastreabilidade animal é o método de identificação individual do animal e, conseqüentemente, de um grupo. Esta dissertação explana sobre o processo de identificação por imagens retiniais de indivíduos, visando implementar uma proposta tecnológica de certificação da qualidade da carne bovina e bubalina em processos industriais, parte essencial do sistema de rastreabilidade. Versará sobre processos matemático-computacionais envolvidos no processamento das imagens e reconhecimento de indivíduos. A idéia original deste trabalho surgiu pela necessidade da empresa Tecniagro Certificações e Sistemas Agropecuários, localizada na Incubadora Tecnológica da UNISC, de se implantar este sistema de identificação.

O objetivo primordial desta dissertação é aplicar processamentos clássicos com imagens, os estudos com a Transformada *Wavelet* e métodos estatísticos na comparação de indivíduos (Identificação Biométrica) desenvolvido em softwares matemáticos e de processamento de imagens para posterior aplicação em uma implementação computacional em software de programação livre.

Esta dissertação está dividida em três capítulos. O primeiro capítulo introduz a importância da rastreabilidade na indústria e comércio de carnes e seus derivados, além de uma legislação específica para o caso. Também relata os sistemas biométricos mais utilizados na análise de padrões e os processos relacionados a imagens digitais. Uma base teórica referente às Transformadas Discretas *Wavelet* em imagens é apresentada com a finalidade de aplicação em Bancos de Filtros Bivariados de Transformadas *Wavelets*. Métodos de classificação das características resultantes dos processos por Análise de Matrizes Esparsas e Análise de Componentes Principais são apresentados como meios de validação dos procedimentos com as imagens neste trabalho.

No Capítulo Dois é abordado a metodologia que foi utilizada nesta pesquisa, descrevendo a escolha das imagens mais adequadas, com testes desenvolvidos para tal fim; um esquema do sistema de identificação relacionada ao sistema de rastreabilidade de animais e a implementação detalhada da ferramenta desenvolvida nos processos com imagens que foi importantíssima na captura de detalhes dos padrões vasculares de retina.

Já no Capítulo Três é apresentado toda a ferramenta padrão para o processamento das imagens retiniais e sua validação via Análise de Matrizes Esparsas e Análise de Componentes Principais. Finalmente se apresentam conclusões incluindo sugestões de trabalhos futuros.

1 FUNDAMENTAÇÃO TEÓRICA

Devido ao fato de a base de um sistema de rastreabilidade de animais de corte ser o reconhecimento e a identificação dos indivíduos, há a necessidade de explanação de determinadas tecnologias já existentes nesta área, da legislação vigente no país e de alguns sistemas de identificação propostos na literatura. Inúmeros problemas ocorrem devido à perda da identidade animal, em rebanhos de corte, e o sistema de reconhecimento por imagens retiniais possibilita a recuperação desta identidade, tornando o sistema de rastreabilidade mais confiável.

O rastreamento de animais na cadeia da carne, exigido pelo comércio internacional, requer a intensificação do manejo nas propriedades rurais e controle rígido dos animais com a identificação individual correta e rápida. Assim, a implantação da rastreabilidade confiável está em discussão há mais de seis anos no Brasil. A proposta da criação do Sistema Brasileiro de Identificação e Certificação de Origem Bovina e Bubalina (SISBOV), em janeiro de 2002, instituiu prazos para adesão e adequação das fazendas ao programa.

Desde então, o SISBOV foi modificado inúmeras vezes até que, diante das ameaças da União Européia, foi criado o sistema de Estabelecimentos Rurais Aprovados no SISBOV (ERAS), no segundo semestre de 2007. O SISBOV também foi afetado pela reestruturação do MAPA (Ministério da Agricultura, Pecuária e Abastecimento) em 2005, ocasião em que a rastreabilidade saiu da esfera da Secretaria de Defesa Agropecuária (SDA) e passou para a Secretaria de Desenvolvimento Agropecuário e Cooperativismo. Ou seja, enquanto toda a questão sanitária estava ligada a uma instituição, a rastreabilidade estava fora dela. Apenas no fim do ano passado, depois da mudança para o ERAS é que o governo devolveu à SDA – órgão que tem ligação direta com as secretarias estaduais de agricultura – a responsabilidade sobre a rastreabilidade (BALDI, 2008).

A auditoria da Organização Mundial de Saúde Animal mostrou que o sistema tem várias falhas, pois desde 1995 o Brasil tenta fazer os ajustes às recomendações internacionais e a Europa fez estes ajustes em 2002. “O acordo internacional é lei e não é praticável. A finalidade de adotar medidas com base na ciência é de evitar equívocos”, afirma Ênio

Marques ex-secretário da SDA e ex-diretor-executivo da Associação Brasileira da Indústria Exportadora de Carne (BALDI, 2008). O problema teve intensificação maior no início deste ano quando a União Européia rejeitou a carne brasileira e seus derivados devidos a problemas no sistema de rastreabilidade, no cadastro de propriedades e em outros fatores relativamente simples.

1.1 Rastreabilidade e Certificação da Qualidade em Animais de Corte

A rastreabilidade existe para garantir ao consumidor um produto seguro e saudável, por meio do controle de todas as fases de produção, industrialização, transporte, distribuição e comercialização, possibilitando uma perfeita correlação entre o produto final e a matéria-prima que lhe deu origem (MARTINS & LOPES, 2003).

Existem variadas técnicas para a rastreabilidade de rebanhos, dentre elas tem-se a identificação pela retina que, em bovinos, é tão confiável quanto a identificação pela impressão digital em seres humanos, sendo única do indivíduo analisado e auxilia no processo de rastreabilidade animal, tornando-o confiável à medida que este padrão não possibilita fraudes.

Além de ser uma tecnologia que não produz dor ou sofrimento animal, ela auxilia especificamente na recuperação da identidade animal no caso de perdas de brincos de identificação ou nos problemas com tatuagens ilegíveis. *Transponders* eletrônicos presos aos brincos ou colocados sob forma cutânea nos animais tornam a leitura e o registro da identidade automatizada, mas o risco da entrada do *transponder* na cadeia alimentar humana tem limitado a popularização desta tecnologia. Os sistemas que requerem análise laboratorial por DNA apresentam como desvantagens o custo e a leitura da identidade em tempo real, sendo mais indicados para assegurar a pureza racial do animal (PRALL, 2002).

Uma companhia chamada *Optibrand*® distribui o equipamento *OptiReader*™, um invento biométrico conforme Figura 1, composto por um computador de mão e uma câmera de vídeo, o qual realiza uma varredura da retina de animais de fazenda e um sistema realiza o

processo de identificação de padrões. Usando-se *LEDs* (*Light Emitting Diode* - Diodo Emissor de Luz) na iluminação do fundo ocular, uma câmera captura a imagem e a envia para o computador de mão e o mesmo envia o código de identificação via *Wireless* ou *Bluetooth* (tecnologias de emissão de informação à distância sem fio) a um servidor localizado até 330 pés de distância do animal (GEARLOG, 2006).

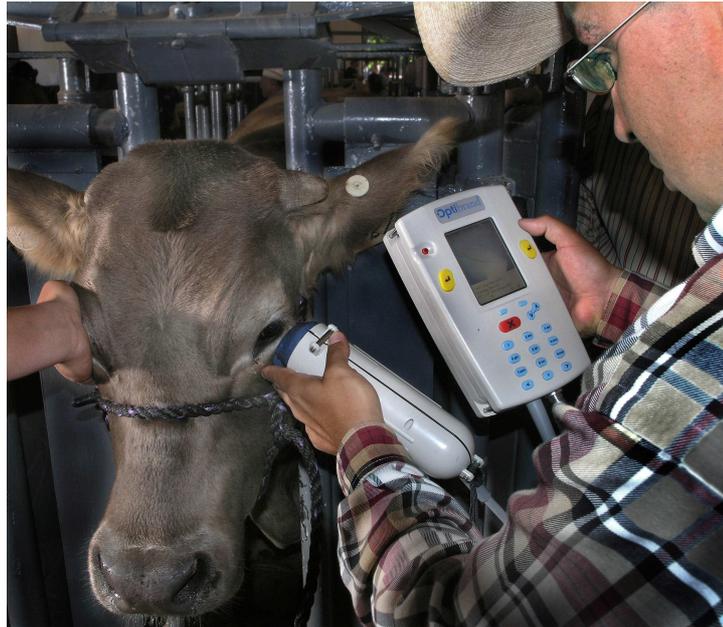


Figura 1. Equipamento que Captura Imagens da Retina de Bovino.
Fonte: NMSU – Universidade do Estado do Novo México – USA.

Esta tecnologia tem um ar bastante austero no que se refere à prevenção de epidemias em rebanhos bovinos e a biossegurança, utilizando até sistemas de *GPS* (*Global Positioning System*) no envio de dados do computador a determinados departamentos governamentais que realizam as ações quanto ao controle dos problemas detectados. O rastreamento de animais da fazenda de origem, na sua movimentação a outras fazendas, chegando ao seu abate em indústrias de processamento de alimentos de origem animal pode ocorrer dentro de um mesmo país ou até entre outros países e o controle de sanidade necessita de rigidez e confiabilidade, através de legislações específicas e uso de tecnologias. As informações podem ser monitoradas pelo consumidor final, realização de *recalls* (rechamadas de substituição de produtos quando necessário) e controle logístico (OPARA, 2003).

1.2 Legislação Brasileira Quanto a Rastreabilidade

O SISBOV – Sistema Brasileiro de Identificação e Certificação de Origem Bovina e Bubalina foi um conjunto de ações, medidas e procedimentos para caracterizar a origem, o estado sanitário, a produção e a produtividade da pecuária nacional e a segurança dos alimentos provenientes dessa exploração econômica (SISBOV, 2002). Fora uma das primeiras tentativas a se adequar aos sistemas de rastreabilidade importantes à exportação de carnes.

Os procedimentos adotados no sentido de identificar, registrar e monitorar, individualmente, todos os bovinos e bubalinos nascidos no Brasil ou importados devem ser previamente aprovados pelo MAPA (Ministério da Agricultura, Pecuária e Abastecimento) para a empresa receber licença de certificação. Estes procedimentos se aplicam em todo território nacional, desde as propriedades rurais de criação de bovinos e bubalinos, às indústrias frigoríficas que processam esses animais, que geram produtos e subprodutos de origem animal além de resíduos de valor econômico.

As Entidades Certificadoras podem ser organizações governamentais ou privadas credenciadas, responsáveis pela caracterização das propriedades, seleção e identificação dos animais para efeito de registro e inserção dos dados individuais de cada animal no SISBOV. A Entidade Certificadora da região, que está buscando o credenciamento, é a Tecniagro Certificações e Sistemas Agropecuários, incubada na ITUNISC, a qual a presente pesquisa foi proposta: ao sistema de reconhecimento da identidade animal frente ao cenário de rastreabilidade no Brasil.

O processo de identificação vai desde o que utiliza a marcação permanente no corpo do animal até a aplicação de dispositivos internos ou externos, que permitam a identificação e o monitoramento individual dos animais, aprovados e autorizados pela SDA (Secretaria de Defesa Agropecuária)/MAPA. Logo, o equipamento e *softwares* a serem aplicados no sistema de rastreabilidade devem ser aprovados por este órgão.

O Documento de Identificação individual acompanhará o animal durante toda a vida, do nascimento ao abate, morte natural ou acidental, registrando as movimentações ocorridas,

resultantes de transferências ou sacrifício emergencial. O controle operacional, com uma base de dados informatizada, será nacional e terá caráter oficial, devendo conter informações atualizadas de animais, propriedades rurais e agroindústrias, todos identificados, registrados e cadastrados no SISBOV pelas entidades credenciadas.

No Documento de Identificação deverão constar: identificação da propriedade de origem, identificação individual do animal, mês do nascimento ou data de ingresso na propriedade, sexo do animal e aptidão, sistema de criação e alimentação, registro das movimentações, comprovação de informação adicional para a certificação, dados sanitários (vacinação, tratamentos e programas sanitários). No caso de animais importados, deverão ser identificados o País e propriedade de origem, datas da autorização de importação e de entrada no País, números de Guia e Licença de Importação e propriedade de destino. No caso de mortes naturais, acidentais ou sacrifício do animal, o respectivo Documento de Identificação deverá ser devolvido à entidade certificadora emitente. No abate, compete aos frigoríficos devolver ao Serviço de Inspeção Federal do MAPA os Documentos de Identificação dos animais.

Quanto aos prazos para registro de propriedades, todos os criatórios produtores de bovinos e bubalinos localizados nos estados livres de febre aftosa ou em processo de declaração integração ao Sistema tinham, no máximo, até dezembro de 2007 o prazo para o cadastramento.

A identificação de animais ou grupos de animais integrantes do SISBOV deverá ser codificada, a fim de possibilitar o acompanhamento da movimentação exigido pelo próprio Sistema. As especificações e as condições necessárias à identificação deverão ser submetidas à aprovação da SDA/MAPA. Os registros dos bovinos e bubalinos deverão estar sempre à disposição dos órgãos competentes do MAPA e da entidade certificadora credenciada que cadastrou a propriedade rural.

Para a homologação do credenciamento das empresas de rastreabilidade é requisito necessário, além do termo de compromisso para cumprimento das normas e requisitos do MAPA, firmado pelo representante legal e pelo responsável técnico, a descrição do modelo do Processo de Identificação, e é neste ponto que o presente trabalho de pesquisa se

concentra: no processo de reconhecimento de animais de forma confiável através de imagens e análise biométrica.

1.3 Sistemas Biométricos de Identificação

A identificação por características biológicas está amplamente em desenvolvimento e, um bom exemplo, ocorre na Universidade de Cambridge – Reino Unido, onde o reconhecimento de padrões da íris é uma realidade.

O reconhecimento de íris é o processo de identificar a pessoa com base na análise dos padrões da íris. A íris é um músculo que se localiza no olho e regula o tamanho da pupila. A sua coloração e estrutura são determinadas geneticamente, mas os detalhes de seus padrões não o são, daí a sua característica distinta para fins de reconhecimento. Com estudos decorridos de 1987 até 1994, ocorreu o desenvolvimento do algoritmo de reconhecimento automático de identificação de íris pelos Drs. Flom, Safir e Daugman, culminando com a patente em 1995 e ampliada até 2011 os direitos ao Dr. John Daugman do *IrisCode*®, código binário originado da imagem da íris que se ilustra na Figura 2 (SHEPARD, 2006).



Figura 2. Fotografia da Íris e o *IrisCode*®(acima).
Fonte: *American Scientist* , por John Daugman, 2001.

A localização da íris e os cuidados com os ruídos da imagem (tais como reflexões) são fundamentais para não empobrecer o desempenho do algoritmo. Outro ponto a ressaltar é a utilização de câmeras digitais de alta qualidade, de luz NIR (*Near Infrared* – Infravermelho próximo) que evita desconfortos nos indivíduos analisados (SHEPARD, 2006).

Para capturar os minuciosos detalhes nos testes padrões da íris, a imagem deve ter um mínimo de 70 *pixels* no raio da íris. Nas experimentações de campo, um raio da íris de 100 a 140 *pixels* foi considerado mais ideal. Câmeras monocromáticas tipo CCD (*Charged Coupled Device*), com resolução de 480 x 640 *pixels*, foram usadas porque iluminação de NIR nos 700nm – a faixa de 900nm foi requerida – para que a imagem possa ser invisível aos seres humanos. O gabarito visual preferivelmente explorado é o que permite cooperar no posicionamento dos olhos dentro do campo de vista de uma única câmera (DAUGMAN, 2004).

Como se pode ver nas figuras 2 e 3, a íris aparece como um complexo padrão aleatório sendo que, no meio de muitas íris, encontram-se algumas características em comum: uma espécie de ziguezague está presente no orifício central e na maior parte circular envolta que é chamada de colarete; radialmente misturam-se no colarete algumas cristas ou cumes lineares e ligeiramente levantados. As áreas ovais escuras, de relevo relativamente profundo, são conhecidas como "*crypts of Fuchs*" (DAUGMAN, 2001).

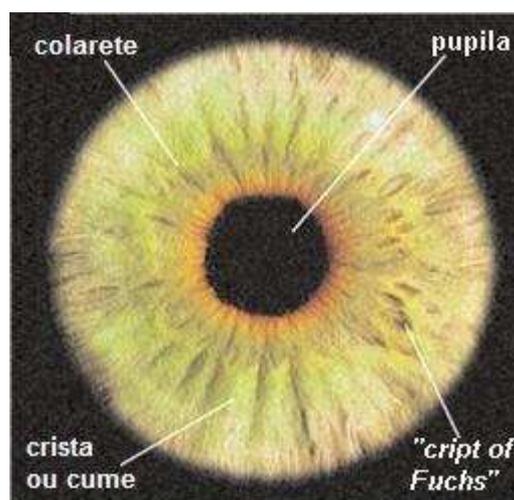


Figura 3. Elementos de Análise da Íris

Fonte: *American Scientist* por John Daugman, 2001.

Paralelamente, pode-se notar que em estudos biométricos, a caracterização das estruturas biológicas segue um mesmo padrão. No estudo de impressões digitais (Figura 4), as linhas são chamadas de cristas (*ridges*) e, quando estas estão num posicionamento central, podem formar variados padrões para o núcleo (*core*). Sendo a busca realizada em um banco de dados, baseando-se primeiramente no padrão do núcleo e seguidamente detectando as coordenadas das minúcias (*minutiae*), resolve-se a primeira etapa do problema da identificação por impressão digital (BONATO, 2002).

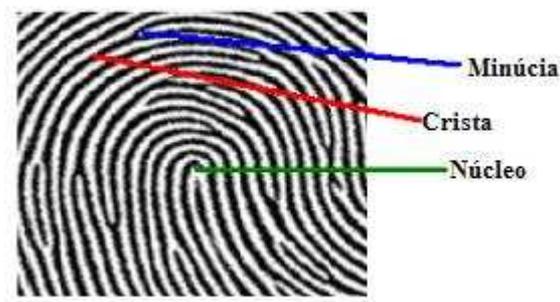


Figura 4. Alguns Elementos de Análise da Impressão Digital

Fonte: Vanderlei Bonato, 2002.

A segunda etapa é realizada com base nas características obtidas da figura, obtém-se um vetor característico e, tal como John Daugman realizou, aplicam-se *wavelets* (neste caso as *wavelets* 2D de Gabor) que podem ser vistas na Figura 5, as quais realizam o trabalho traçando os segmentos da íris em vetores fase. Estas fases incluem a frequência espacial e a posição destas áreas ("o quê e aonde" da imagem) sendo esta a informação usada para traçar o *IrisCode*® (em código binário). A fase não é afetada pelo contraste ou pelos níveis da iluminação e pode ser descrita usando 256 bytes dos dados num sistema coordenado polar (SHEPARD, 2006).

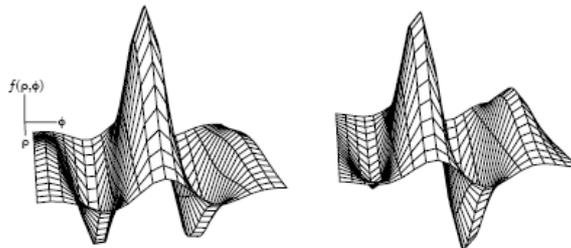


Figura 5. Par de *Wavelets* 2D de Gabor.

Fonte: *American Scientist* por John Daugman, 2001.

A multiplicação do sinal (um “remendo bidimensional” da imagem da íris) com um par de *wavelets* de Gabor tal como mostrado na Figura 5, especifica um vetor do ponto ou da posição no plano complexo descrito na Figura 6. O componente real deste vetor representa a correspondência entre a *wavelet* da simetria uniforme e o sinal; o componente imaginário representa a combinação entre a *wavelet* da simetria ímpar e o sinal. O método de Daugman rejeita a amplitude destes componentes e retém somente uma medida grosseira do ângulo da fase, gravada com dois bits que especificam o quadrante em que o ponto se localiza (Figura 6). Uma string de 1.024 pares constituiu o *IrisCode*®, em 2001, para John Daugman apesar de que outros cientistas se envolveram durante a construção deste sistema de identificação.

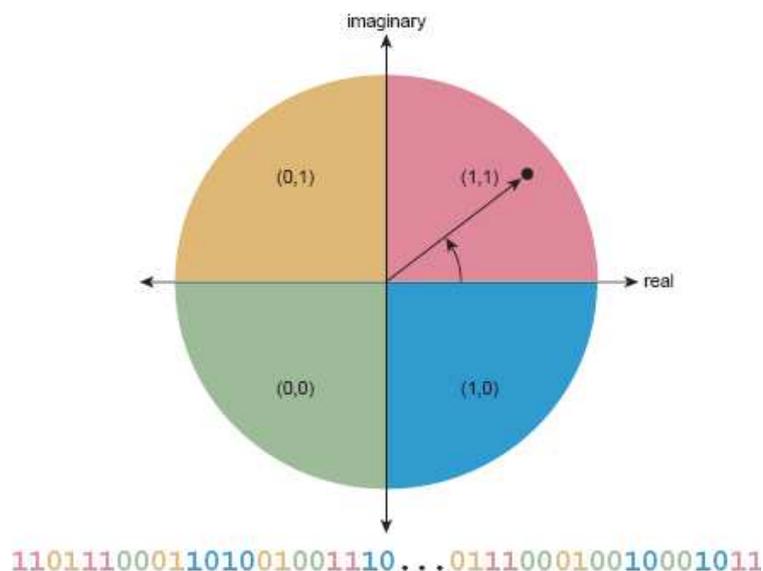


Figura 6. Sistema de Coordenadas Polares para a Utilização do Par *Wavelet* Gabor.

Fonte: *American Scientist* por John Daugman, 2001.

O reconhecimento de retina está embasado nos padrões formados por vasos sanguíneos que são únicos e inigualáveis. Aliando a captura de padrões de retina e da íris há maior confiabilidade no reconhecimento de indivíduos. Órgãos de segurança americanos, responsáveis na avaliação do registro e da aquisição nesta tecnologia, iniciada em maio de 2005, demonstram certo sucesso nas aplicações, mas estudos ainda estão sendo necessários e realizados neste sentido (SHEPARD, 2006).

1.4 Fundamentos de Processamento de Imagens Retinais Digitais

O processamento de imagens digitais, juntamente com a computação gráfica pertence à área de Processamento Gráfico. Em linhas gerais, o primeiro tem o objetivo de analisar imagens e padrões enquanto que o segundo busca sintetizar e visualizar as mesmas.

A importância da visão na vida de cada um de nós é evidente: os sinais luminosos permitem a visualização dos objetos num ambiente. A clara necessidade de automação de atividades cotidianas evidencia um envolvimento crescente com as ferramentas de visão computacional que tem por objetivo obter informações geométricas, topológicas ou físicas sobre uma imagem de entrada (GOMES & VELHO, 2002).

A Visão Computacional, tal como a área de Processamento de Imagens, aborda o assunto algorítmico e computacional associado com a aquisição, processamento e entendimento da imagem, que incorporam os princípios que delineiam as capacidades visuais. Historicamente, a visão computacional tem sido uma ciência experimental, onde as soluções e pesquisas desenvolvidas para aplicações específicas foram obtidas por métodos de tentativa e erro (MOLZ, 2001).

A representação de sinais luminosos, provenientes do ambiente em estudo, é dada em forma de sinais discretos, sendo seu valor em qualquer ponto de coordenadas espaciais (x, y) proporcional ao brilho da imagem naquele ponto. A disposição dos dados luminosos se representa numa matriz, com valores de 0 a 255 níveis de cinza, mas também se pode utilizar uma ordem valores decimais entre $[0,1]$ para a representação destes níveis de cinza (GONZALEZ et al, 2004). Os sinais luminosos em escala de cinza podem também ser convertidos em imagens binárias, realizando uma redução da informação de níveis de cinza para simples valores binários. Assim, as imagens binárias são compostas por uma matriz lógica de valores 0s e 1s obtidas através de um limiar, denominado comumente de limiarização ou *threshold*, cujo valor é definido pelos experimentos com a imagem e algoritmos específicos.

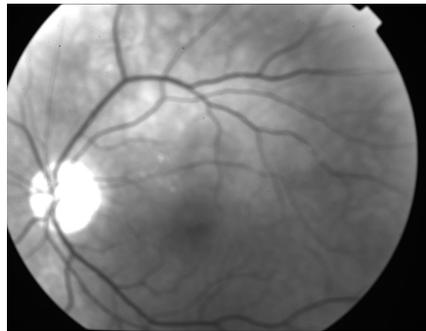
Existem diferentes formas de obter imagens de fundo de olho. Os tipos comuns de câmeras (também chamadas de retinógrafos) são midriáticos ou não midriáticos. Os instrumentos midriáticos são projetados assumindo que os olhos foram dilatados pelo uso de colírios, ao contrário dos não midriáticos, que não requerem dilatação. Os midriáticos produzem imagens de melhor qualidade devido ao maior campo de vista proporcionado pela dilatação (SOARES, 2007).

Esta matriz de imagens, conforme o ajuste do dispositivo de aquisição, pode ser composta de um único plano, tais como as imagens *red-free* (aneritra) utilizadas na maior parte deste trabalho. Neste tipo de imagem monocromática, Figura 7(a), aplica-se um filtro de cor para realçar determinadas estruturas do fundo, deixando vasos da retina, hemorragias e exsudatos mais aparentes (SOARES, 2007). Já imagens coloridas, Figura 7(c) são compostas por um espaço de cores no qual há a combinação de três planos (triestímulos luminosos) como, por exemplo, o sistema RGB (*Red-Green-Blue*) de cores, Figura 7 (d), (e) e (f). Assim, faz-se necessário uma escolha do plano de cores que melhor represente os padrões vasculares da retina.

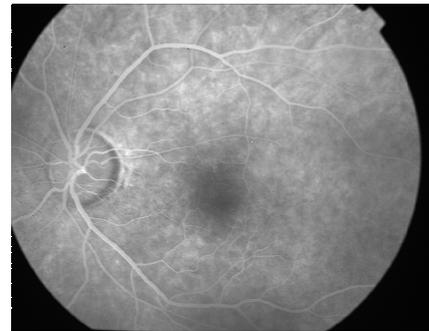
A imagem *red-free*, de acordo com o registro *US Patent 6053865*, refere-se à utilização de um filtro de cor no qual a fotografia não apresenta o componente *Red* do sistema RGB de cores. Assim uma imagem *red-free* é uma imagem que projeta em um único plano os componentes B+G da imagem.

Os vasos sanguíneos do fundo do olho têm como função o fornecimento de nutrientes e oxigênio e ajudam na eliminação de resíduos metabólicos, desaparecendo somente com a morte do indivíduo. A camada superior dos vasos (vasculatura da retina) pode ser vista com facilidade e está disposta na forma de duas redes complexas – uma de veias e outra de artérias – que surgem da região do disco óptico e bifurcam-se sucessivamente ao ocuparem as demais regiões da retina, como ilustrado nas Figuras 7. É possível distinguir a rede de artérias da de veias nas imagens: na Figura 7 (a), as artérias mostram-se mais claras e com um reflexo central mais acentuado; na Figura 7 (b), as artérias aparecem como completamente iluminadas (mais claras), enquanto apenas as bordas das veias mais grossas estão aparentes, devido ao momento em que foi registrado o angiograma com uso de corante (fluoresceína sódica ou indocianina verde) para o contraste. O disco óptico, que pode ser visto como a estrutura mais

clara nas Figuras 7(a), 7(c), 7(d), 7(e) e 7(f), corresponde à região em que fibras nervosas se reúnem para formar parte do nervo óptico. A região mais escura, mais nítida na Figura 7 (b), é a mácula, que contém a fóvea (região de maior acuidade visual) e é livre de vasos sanguíneos (SOARES, 2007).



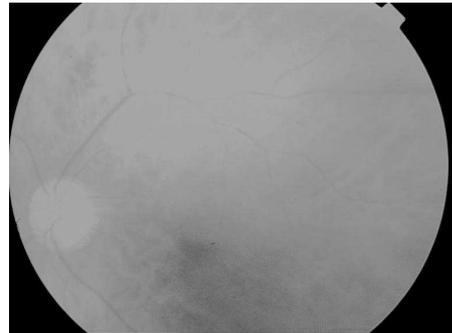
(a) Fotografia aneritra



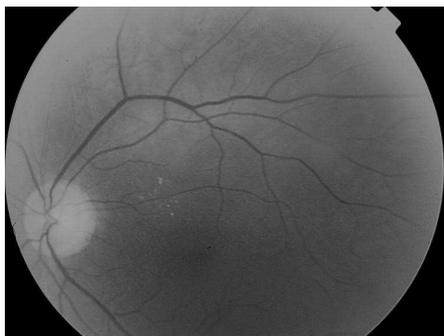
(b) Fotografia de angiografia



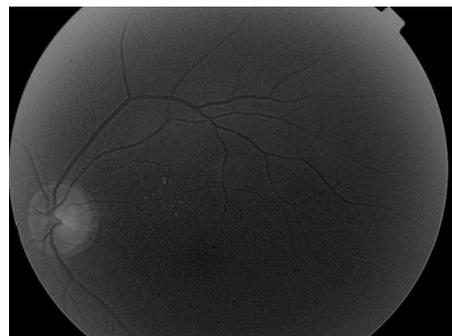
(c) Fotografia colorida



(d) Plano Red



(e) Plano Green



(f) Plano Blue

Figura 7. Imagens do Olho Esquerdo de um Indivíduo Humano.

Imagem *red-free* ou aneritra (a), Imagem de angiografia fluoresceínica, com utilização de corante para contraste (b), Imagem colorida (c) e seus planos Red (d), Green (e) e Blue (f).

Fonte: Banco de Imagens obtido pela autora da presente dissertação THEISEN, 2008.

Em imagens coloridas e não midriáticas, nota-se que o plano *Green* de cores foi o que apresentou melhor contraste de imagem, sendo assim selecionado por Soares et al (2006) nos

processos pela Transformada Discreta *Wavelet* 2D Morlet, na análise das dimensões (espessura) dos padrões vasculares na busca de doenças, tais como a detecção de retinopatia diabética tema da dissertação deste autor.

No trabalho de Zana & Klein (1999) também foi adotado o plano *Green* nos processos de detecção de microaneurismas e lesões vasculares em imagens coloridas de retinas, combinada com a análise de imagens com uso de contraste de fluoresceína (angiografia). A detecção de vasos ocorre na aplicação de filtros detectores de bordas Canny combinados e a Transformada Hough, além de uso de operadores morfológicos na detecção.

1.5 Limiarização (*Threshold*) de Imagens e Operadores Morfológicos Binários

O processo de Binarização de imagens corresponde a realçar características e transformar a imagem de variados níveis de cinza em uma imagem composta de apenas dois valores: 0 e 1. Uma imagem binária $b(x, y)$ é produzida pela Equação 1, onde t é um valor de limiarização (*threshold*) definido:

$$b(x, y) = \begin{cases} 1 & \text{se } I(x, y) > t, \\ 0 & \text{caso contrário} \end{cases} \quad (1)$$

O método de limiarização (definição de valor de *threshold*) de imagens proposto por (OTSU, 1979) se baseia no histograma da imagem, o qual mostra a distribuição dos níveis de cinza e está demonstrado na Figura 8. Este método admite uma análise bimodal do histograma da imagem e encontra o nível de limiarização (*threshold level*) que separa as duas classes, ou seja, separa o primeiro plano do segundo plano da imagem.

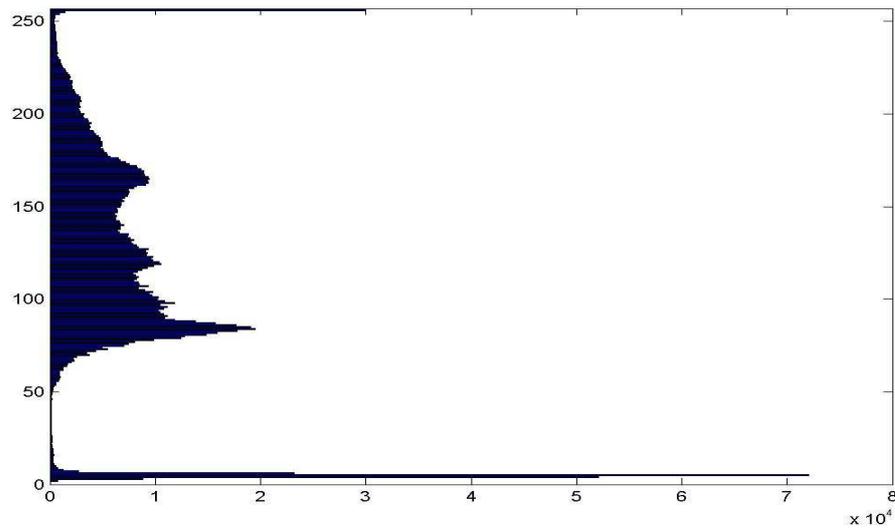


Figura 8. Equalização de Histograma dos Valores de Cinza da Figura 7(a).

Fonte: Elaborado pela autora.

O Método de Otsu reduz a variância entre duas classes internas definidas pela Equação 2:

$$\sigma(t) = q_1(t)\sigma_1(t) + q_2(t)\sigma_2(t) \quad (2)$$

Considere $\sigma(t)$ sendo a soma dos pesos das variâncias de duas modas do histograma como uma função de com nível de limiarização t . Considere $\sigma_i(t)$ e $q_i(t)$, $i=1,2$ seja a respectiva variância e probabilidade de duas modas do histograma separado por um limiar t (*threshold*), apresentada na Equação 2. O limiar t que resulta na minimização de $\sigma(t)$ produz os desejados “primeiro plano(*foreground*) e segundo plano ou fundo(*background*)” de uma imagem binária (*bi-level image*).

Veias e artérias têm muitas características observáveis, incluindo diâmetro, cor, tortuosidade (curvatura relativa) e opacidade (refletividade). A probabilidade de combinação de limiares foi tema do artigo de Hoover et al (2000) que, a cada iteração do algoritmo um conjunto de regiões de teste é aplicado para determinar se o limiar pode ser reduzido num passo adicional. A probabilidade local pára quando uma das regiões de teste falha.

Com a imagem binarizada Operadores Morfológicos Binários podem ser aplicados. Conforme Zmuda et al (1996) a Morfologia Matemática é um tipo de transformação não-linear que processa imagens de acordo com critérios facilmente interpretados, tal como a forma, tamanho, orientação, textura, entre outros. Embora estes paradigmas se estendam para muitos domínios diferentes de imagens, aqui será realizado um enfoque ao domínio das imagens binárias. Na morfologia binária, na vizinhança de cada *pixel* da imagem original, é procurada uma configuração de pontos pretos e brancos nessa vizinhança e do algoritmo.

O princípio básico da morfologia matemática consiste em extrair uma informação relativa à geometria e à topologia de um conjunto desconhecido de uma imagem pela transformação a partir de um outro conjunto completamente definido chamado elemento estruturante. Assim, os operadores básicos de erosão e dilatação, atuam sobre uma imagem através de uma máscara de Elemento Estruturante (EE). O funcionamento destes operadores depende, primordialmente, da semelhança geométrica local entre a imagem e o EE. Na Figura 9, temos um exemplo de EE em cruz.

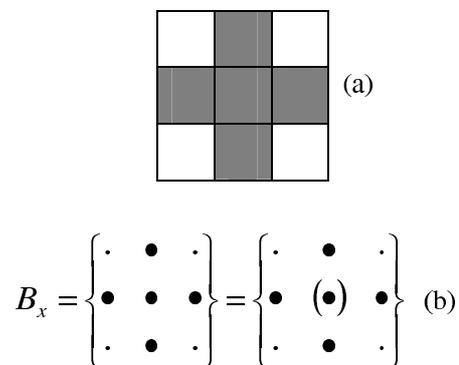


Figura 9. Elemento Estruturante em Cruz (a) e sua Representação Morfológica na Forma Digital (b).

Fonte: FACON, 1996.

Consideremos B o elemento estruturante e B_x representando o elemento estruturante centrado no *pixel* x , sendo definido pelos *pixels* que o formam representados por “.” (*pixel* inativo ou neutro) e “•” (*pixel* ativo que tem um papel a desenvolver na interação com uma imagem). Da mesma maneira, por ser binária, uma imagem digital X contém dois tipos de informação, o fundo (representado por “.”) e os *pixels* relevantes (representados por “•”). Na forma digital, a imagem X é representada entre “[]”. A partir do formato do EE, tem-se a

possibilidade de testar e de quantificar de que maneira esse “está contido ou não” na imagem (FACON, 1996).

Os *pixels* “•” do elemento estruturante criam um subconjunto que vai agir com a imagem X . O resultado dessa interação é colocado numa posição específica, a do ponto central do elemento estruturante, na imagem no momento da ação. O símbolo “(•)” representa este ponto central no elemento estruturante que, em geral, corresponde ao seu centro físico (FACON, 1996).

As operações básicas aplicadas nesta dissertação são as de erosão e dilatação. Um exemplo de erosão é apresentado na Equação 3:

$$\begin{bmatrix} \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \end{bmatrix} \text{ero} \left\{ \begin{array}{c} \cdot \\ \cdot \\ (\bullet) \\ \cdot \\ \cdot \end{array} \right\} = \begin{bmatrix} \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \end{bmatrix} \quad (3)$$

Assim, a erosão de um conjunto X pelo elemento estruturante B é definida na Equação 4:

$$\text{ero}^B(X) = X \text{ ero } B = X \ominus B^T = \bigcap_{b \in B^T} X_b = \bigcap_{b \in B} X_{-b} \quad (4)$$

Conforme Facon (1996) pode-se constatar que o conjunto, X , a ser erodido é deslocado em função das posições permitidas pelo elemento estruturante B . Entende-se que na definição da Equação 4 tem-se que transladar X e não mais B , deslocamento em torno do ponto central. Os deslocamentos são realizados em relação ao ponto central de B^T . Assim, a diferença de processamento com X e B em relação à ilustração da Equação 3 é apresentada na Equação 5:

$$\begin{bmatrix} \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \end{bmatrix} \text{ero} \left\{ \begin{array}{c} \cdot \\ \cdot \\ (\bullet) \\ \cdot \\ \cdot \end{array} \right\} = \begin{bmatrix} \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \end{bmatrix} \cap \begin{bmatrix} \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \end{bmatrix} \cap \begin{bmatrix} \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \end{bmatrix} = \begin{bmatrix} \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \bullet & \bullet & \bullet & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \end{bmatrix} \quad (5)$$

Os efeitos da erosão podem ser visualizados na Figura 10, que utiliza o EE em cruz. Pode-se constatar que, por erosão, o elemento estruturante elimina os conjuntos inferiores a ele em tamanho. Assim, o efeito é de diminuição de partículas, aumenta os buracos e permite a separação de partículas próximas (FACON, 1996).

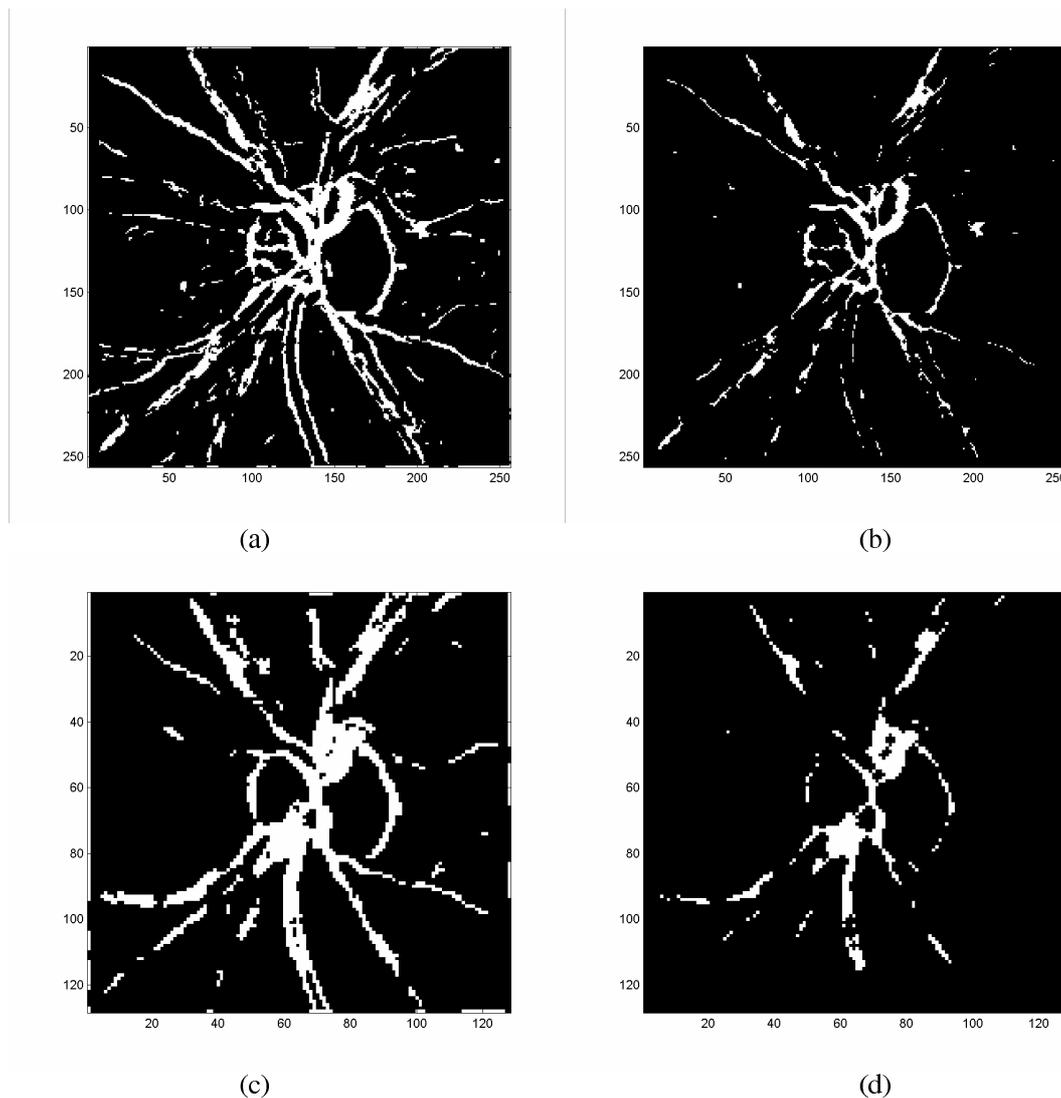


Figura 10. Exemplos de Erosão Binária da Região de Interesse (RI) de IM002294.TIF

(a) RI no 1º nível de Compactação Haar e (b) significa Erosão de (a).
(c) RI no 2º nível de Compactação Haar e (d) a respectiva Erosão de (c).

Fonte: Elaborado pela autora.

Já a dilatação, de forma geral, preenche todos os furos que são inferiores ao EE, permite conectar conjuntos separados (empregando-se EE maior que o espaço entre conjuntos) e expande as partículas (FACON, 1996). Um exemplo de dilatação nos experimentos pode ser visualizado na Figura 11.

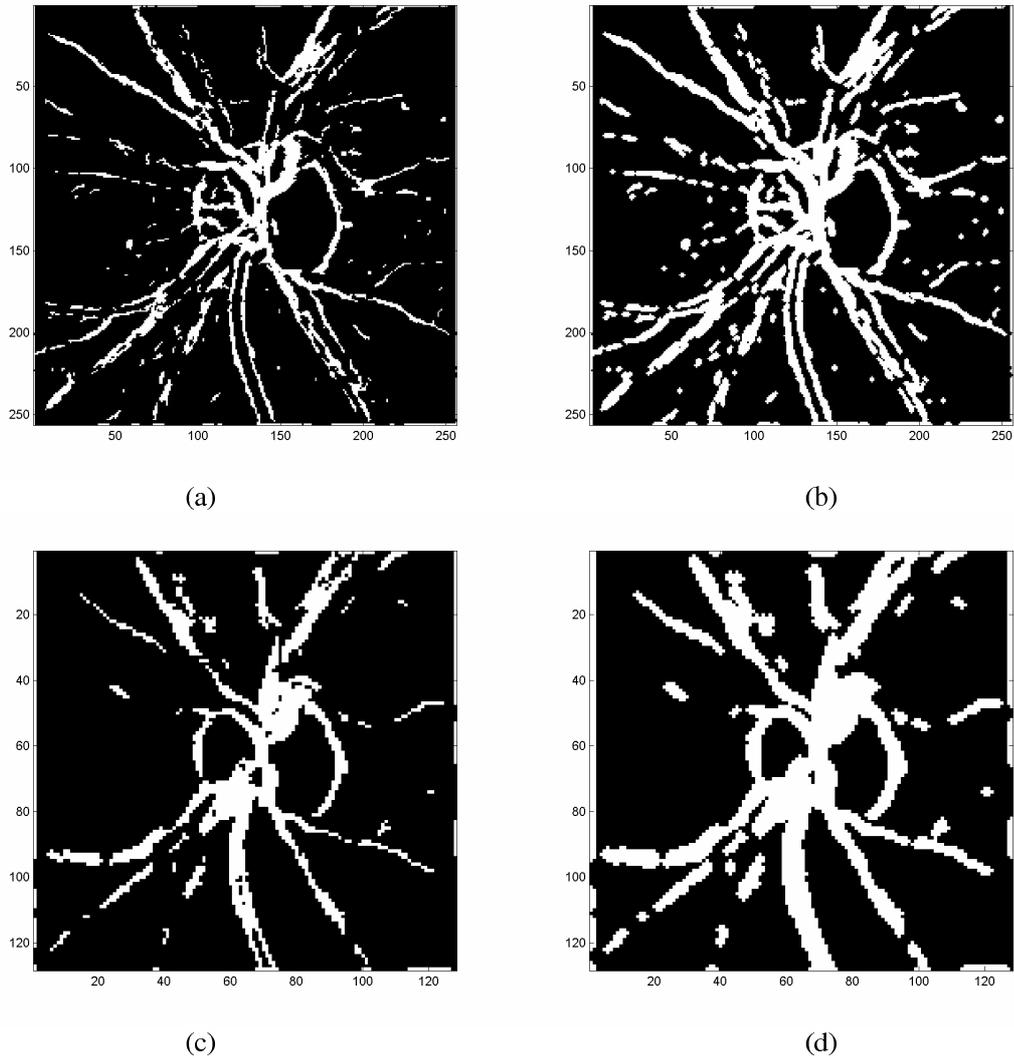


Figura 11. Exemplo de Dilatação Binária da Região de Interesse de IM002294.TIF
 (a) RI no 1º nível de Compactação Haar e (b) significa Dilatação de (a). (c) RI no 2º nível de Compactação Haar e (d) a respectiva Dilatação de (c).

Fonte: Elaborado pela autora.

A operação de dilatação binária dil é definida da seguinte maneira: A dilatação de um conjunto X pelo elemento estruturante B é a Equação 6:

$$dil^B(X) = X \ dil \ B = X \oplus B^T = \cup_{b \in B^T} X_b = \cup_{b \in B} X_{-b} \quad (6)$$

Um exemplo de dilatação pode é apresentado na Equação 7:

$$\begin{bmatrix} \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \end{bmatrix} \text{dil} \begin{Bmatrix} \cdot \\ \cdot \\ \cdot \end{Bmatrix} = \begin{bmatrix} \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \end{bmatrix} \oplus \begin{Bmatrix} \cdot \\ \cdot \\ \cdot \end{Bmatrix}^T = \begin{bmatrix} \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \end{bmatrix} \oplus \begin{Bmatrix} \cdot \\ \cdot \\ \cdot \end{Bmatrix} = \begin{bmatrix} \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \end{bmatrix} \cup \begin{bmatrix} \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \end{bmatrix} = \begin{bmatrix} \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \end{bmatrix} \quad (7)$$

1.6 Normalização da Imagem em Escala de Cinza

O trabalho de Ross (2003) disserta sobre a utilização dos padrões de impressões digitais aliados a outros métodos de identificação (reconhecimento de face e geometria das mãos), com a aplicação de uma metodologia de aprendizagem usada para computar parâmetros multibiométricos. Espera-se que com os sistemas de fusão da informação, considera o autor, maior confiabilidade e robustez do que os sistemas que confiam em uma única fonte de informação. Neste trabalho, as intensidades de *pixel* em cada setor da imagem são normalizadas para uma média e variância constante, anterior à utilização de um banco de filtros de Gabor, com a finalidade de produzir o conjunto de imagens filtradas. Na Figura 12 é demonstrada a normalização da Região de Interesse (RI) do padrão vascular do Nervo Óptico (NO) procedimento anterior à aplicação dos filtros *wavelets* no presente trabalho.

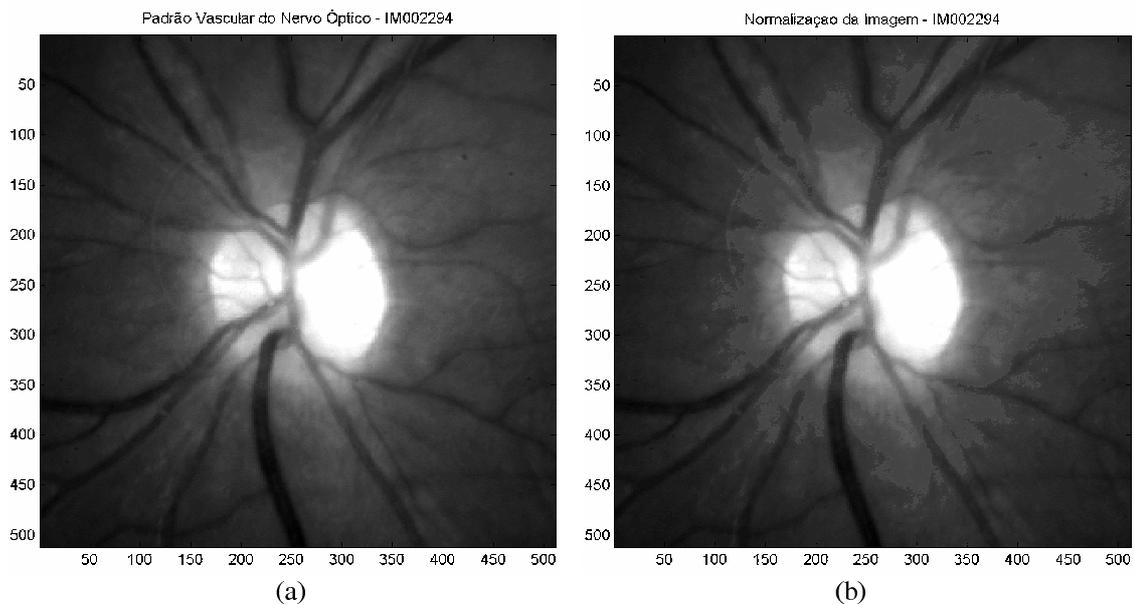


Figura 12. Normalização da Região de Interesse de IM002294.TIF
Fonte: Elaborado pela autora.

No trabalho de Andrysiak & Choraś (2005) foram normalizadas as imagens, em torno de certa média e variância, antes da aplicação dos filtros multicanais de Gabor para a detecção de pontos salientes e características de texturas na recuperação de imagens. A normalização é executada com a finalidade de remoção do ruído do sensor de imagem e da deformação dos níveis de cinza. Além disso, a extração de pontos salientes, executada mais tarde no método, depende da variação da iluminação na imagem. Conseqüentemente, a fim de obter a uniformidade de iluminação e contraste, este passo é executado inicialmente sobre a região de trabalho. Para todos os *pixels* na imagem I , o processo de normalização é definido como segue na Equação 8:

$$f(x, y) = \begin{cases} E_0 + \sqrt{\frac{V_0(I(x, y) - E)^2}{V}} & \text{se } I(x, y) > th \\ E_0 - \sqrt{\frac{V_0(I(x, y) - E)^2}{V}} & \text{caso contrário} \end{cases} \quad (8)$$

onde E_0 e V_0 são os desejáveis valores de média e variância, respectivamente, e E e V é a média e a variância computados na imagem dada e descritas nas Equações em (9), respectivamente, sendo $E_0 = 100$ e $V_0 = 100$ (ANDRYSIK & CHORAŚ, 2005).

$$\begin{aligned} E &= \frac{1}{M^2} \sum_{x=0}^{M-1} \sum_{y=0}^{M-1} I(x, y), \\ V &= \frac{1}{M^2} \sum_{x=0}^{M-1} \sum_{y=0}^{M-1} (I(x, y) - E)^2 \end{aligned} \quad (9)$$

1.7 Congruência de Fase

É uma metodologia de detecção de características em imagens com uma poderosa e significativa particularidade que é sua constância na captura de detalhes quanto à variação de luminosidade de uma imagem, assim como tem o poder detectar uma escala larga de características interessantes (MYERSCOUGHT & NIXON, 2004).

O modelo de *Phase Congruency* (PC), traduzido como Congruência de Fase, é baseado na frequência do processamento visual. Supõe-se que, em vez de processar dados visuais espacialmente, o sistema visual é capaz de executar cálculos usando a fase e a amplitude dos componentes individuais da frequência em um sinal (MORRONE et al, 1986).

Assim, a ferramenta computacional subjacente é a Transformada de Fourier, ou um de seus equivalentes. Para compreender a PC, é necessário pensar que o sinal de uma função $f(x)$, em qualquer momento x na imagem, como sendo composto de várias ondas senoidais em amplitudes e ângulos diferentes de fase, esboçando um mapa vetorial, como na Figura 13, em um mapa de vetor (OWENS, 1997).

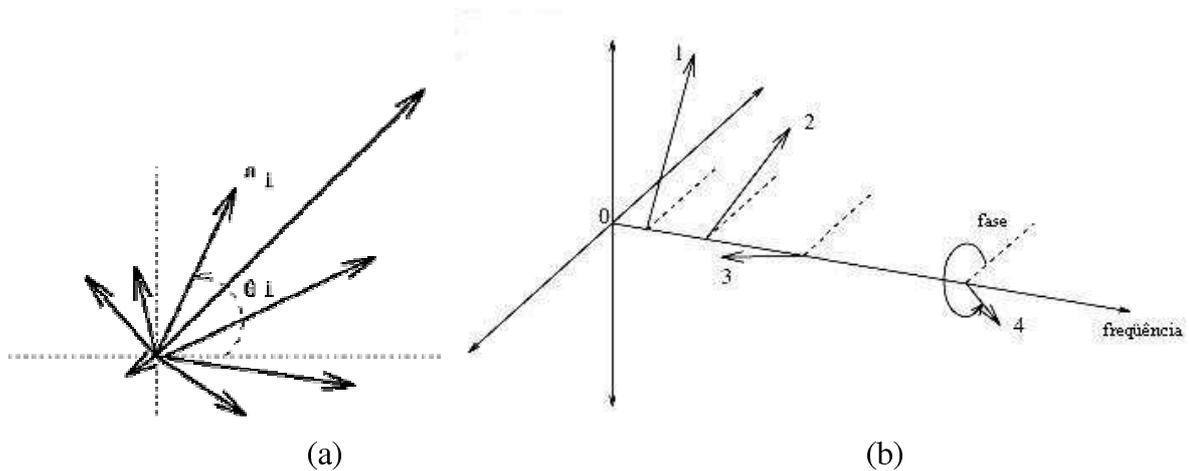


Figura 13. Modelo de Congruência de Fase de um conjunto de vetores em (a) e outro conjunto de vetores ao longo da frequência em (b).
Fonte: OWENS, 1997(a) & KOVESI, 1999(b).

Ao encontrar o ângulo médio da fase e calcular o desvio padrão de todos estes ângulos de fase sobre este ângulo médio, obtém-se uma medida de Congruência de Fase. Em outras palavras: numa avaliação complexa do local sobre os componentes de Fourier numa posição x no sinal requer que cada um tenha uma amplitude $A_n(x)$ e um ângulo de fase $\varphi(x)$. Os valores do vetor da origem ao ponto de extremidade é a Energia Local $|E(x)|$, que corresponde ao deslocamento de fase no domínio da frequência (MORRONE et al, 1986), como mostra a Figura 14. A medida de Congruência de Fase foi primordialmente desenvolvida por Morrone et al (1986) e é mostrada na Equação 10:

$$PC(x) = \frac{|E(x)|}{\sum_n A_n(x)} \quad (10)$$

Sob esta definição, Congruência de Fase é a relação de $|E(x)|$ ao longo do trajeto total realizando-se um exame pelos componentes locais de Fourier ao alcançar o ponto de extremidade. Se todos os componentes de Fourier se realizassem na fase onde todos os vetores complexos estariam alinhados então a relação $|E(x)| / \sum_n A_n(x)$ seria 1. Se não houver nenhuma coerência da fase a relação cai a um mínimo de 0. A Congruência de Fase fornece uma medida que seja independente do valor total do sinal que o faz constante às variações na iluminação e/ou contraste da imagem. Fixados valores de ponto inicial significante da característica podem, então, ser usados sobre classes largas das imagens (KOVESI, 2003).

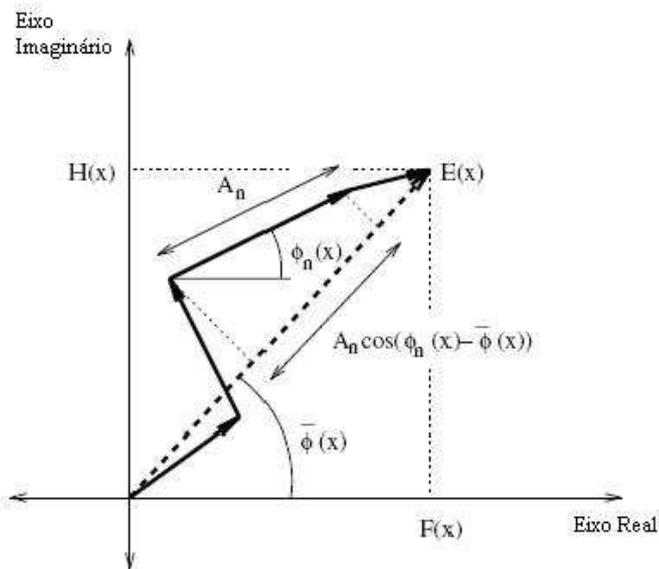


Figura 14. Ilustração do Arranjo da Construção da Energia em PC a soma das amplitudes de Fourier e a Congruência de Fase dos componentes de Fourier de um sinal.
Fonte: KOVESI, 1999.

Pode-se mostrar que esta medida de Congruência de Fase é uma função do cosseno do desvio de cada componente da fase de sua média, conforme Equação 11 (KOVESI, 2003).

$$PC_1(x) = \frac{\sum_n A_n (\cos(\varphi(x) - \bar{\varphi}(x)))}{\sum_n A_n(x)} \quad (11)$$

Um modelo da percepção de característica chamado de modelo da energia local postula que as características são percebidas em pontos nos quais os componentes de Fourier da imagem se realizam à máxima fase. Quase todos trabalham de modo a concentrarem e a encontrar os pontos de fase de congruência máxima, procurando máximos na energia local, indicando contrastes. Estes pontos chamados de Congruência de Fase passam por um banco de filtros log Gabor no trabalho de Kovese (1999) que relata a filtragem de imagens e maior detalhamento de características proporcionado por esta técnica em comparação a detectores de bordas clássicos do Processamento de Imagens, tais como Canny e Sobel.

Ao aplicar o algoritmo de Congruência de Fase, elaborado por Kovese (1999) e executado no MATLAB®, percebeu-se que a imagem apresentava maiores contrastes e sua binarização apresentou melhores detalhes, que pode ser percebido na Figura 15 (c) e Figura 15(d). Neste comparativo da Figura 15, aparece também uma comparação com o detector de bordas Canny com as modificações propostas no trabalho de Fleck (1992) na Figura 15(e) e Figura 15(f).

Intuitivamente, os resultados bons da segmentação podem ser obtidos com um simples valor de limiarização. Entretanto, este operador não considera as sensíveis mudanças de iluminação, como pôde ser visto na Figura 15(b). Para superar este problema, o limite das regiões prováveis do ruído pode primeiramente ser localizado pela informação da borda baseada na congruência de fase, que é uma quantidade menor dimensionalmente e invariante à mudança da iluminação. Este fato denota a importância de utilização desta filtragem nas imagens que tem mudanças sensíveis de luminosidade, tal como entre o padrão vascular e o fundo, conforme demonstrados na Figura 15.

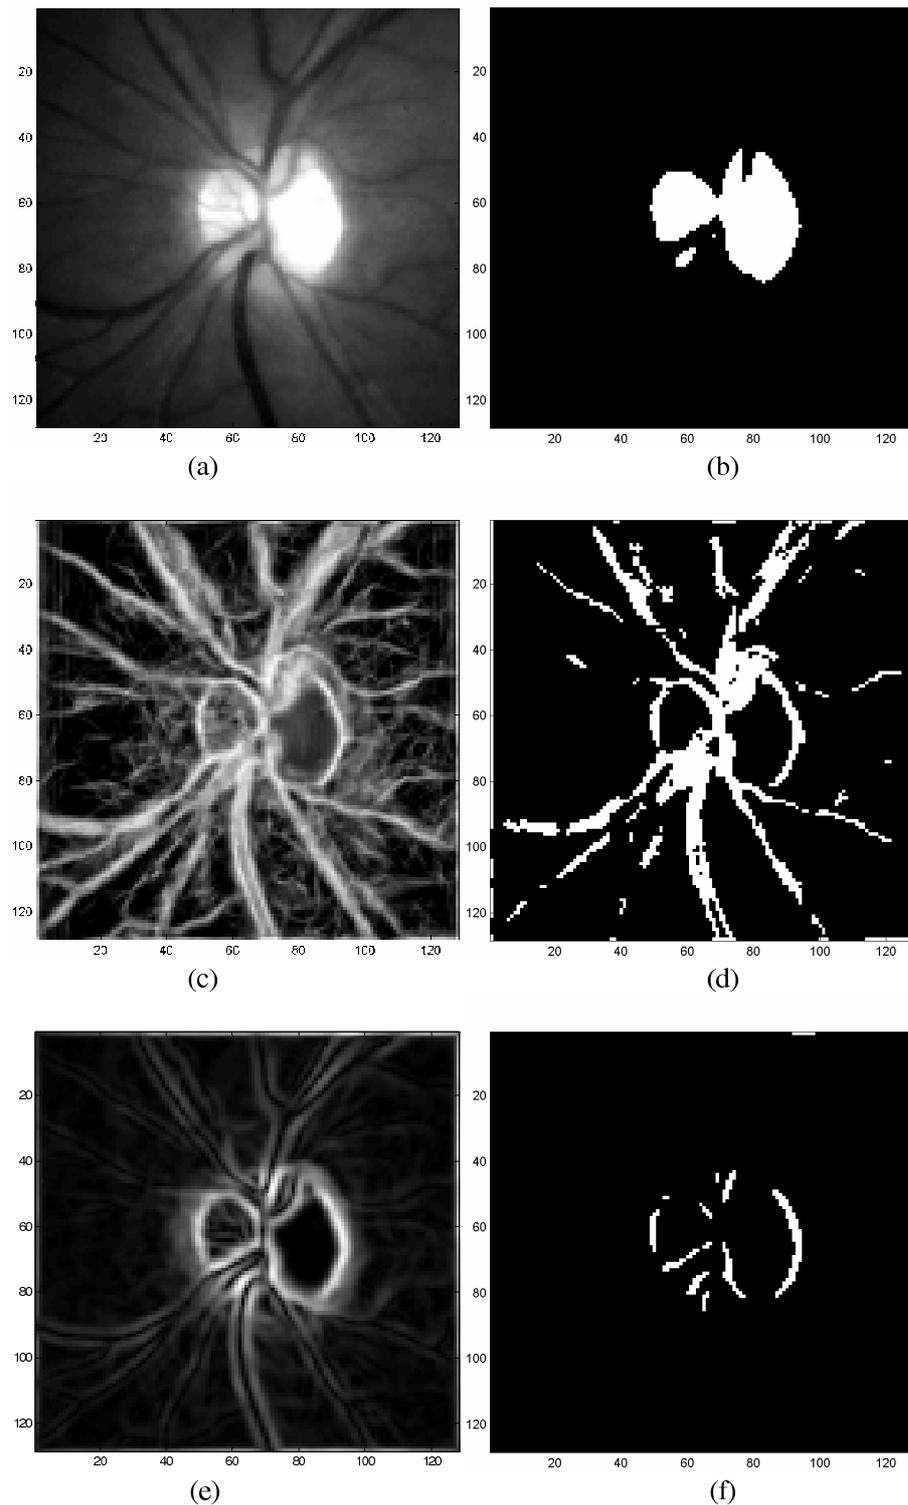


Figura 15. Comparação de Efeitos da Congruência de Fase com outras técnicas na binarização de imagem retinal.

- (a) Imagem original da RI. (b) Imagem binarizada (limiar de $t=175$) de (a).
 (c) Aplicação do Modelo de Congruência de Fase de KOVESI (2003). (d) Imagem binarizada ($t=175$) de (c).
 (e) Gradiente de Canny na proposta de FLECK (1992). (f) Imagem binarizada ($t=175$) de (e).

Fonte: Elaborado pela autora.

Huang et al (2004) aplica uma extensão do modelo de Congruência de Fase de Kovesi (1999), com contribuições adicionais a este trabalho, sobre a remoção dos ruídos em imagens de íris com a finalidade de extração de características e montagem de um vetor característico no reconhecimento de indivíduos pela íris. As informações das características de uma imagem da íris podem apresentar ruídos causados pelas pestanas, pálpebras, reflexão, etc. Assim, para as imagens originais da íris serem primeiramente segmentadas de forma rápida, optaram por uma simples filtragem, detecção de bordas e aplicação da Transformada Hough. A íris localizada é, então, normalizada a um bloco retangular com um tamanho fixo, técnica que é considerada um modelo antigo de segmentação da íris, pois não remove os ruídos além de ser sensível a variação de iluminação do ambiente, motivo pelo qual optaram em aplicar o Modelo de Congruência de Fase que realça os detalhes a serem detectados.

1.8 Transformada Hough

A Transformada Hough é um algoritmo padrão de visão computacional que pode ser usada para determinar os parâmetros de objetos geométricos simples em imagens, tais como linhas, círculos e elipses. A Transformada Circular Hough pode ser empregada para deduzir as coordenadas do raio e do centro das regiões da pupila e íris tal como realizada na tese de Masek (2003). Como a região do nervo óptico é de formato circular, nota-se que esta transformada pode ser útil na detecção do centro da imagem sobre a região do Nervo Óptico.

O algoritmo automático da segmentação baseada na Transformada Circular Hough primeiramente gera um mapa de borda, calculando as primeiras derivadas de valores da intensidade em uma imagem do olho e então limiarizam o resultado. Do mapa de borda, os pontos eleitos são moldados no Espaço de Hough para os parâmetros dos círculos que passam através de cada ponto da borda. Estes parâmetros são as coordenadas do centro e o raio, que podem definir todo o círculo de acordo com a Equação 12:

$$(x - a)^2 + (y - b)^2 = r^2 \quad (12)$$

Onde (a,b) são as coordenadas do centro do círculo que passa através de (x,y) e r é o raio. Neste caso, é requerido um acumulador tridimensional com uma atenção ao incremento na complexidade computacional do algoritmo. Um ponto importante a notar: a Transformada Hough identifica o parâmetro da curva que melhor se ajusta aos dados, entretanto círculos que são gerados para serem círculos completos são compostos por infinitos pontos. Para identificar um segmento curvo que é gerado por estes parâmetros transformados, maiores análises de imagem são requeridas (VERNON, 1991).

Um ponto máximo no Espaço de Hough, dentre os pontos colocados pela detecção de picos da Figura 16(d), corresponderá às coordenadas do raio e do centro do círculo que define melhor os pontos da borda. A vantagem principal da técnica de Transformada Hough é que ela é bem tolerante às aberturas em descrições do limite da característica e é relativamente não afetada pelo ruído da imagem. Estas características podem observadas no algoritmo de detecção da Região de Interesse em torno da forma quase circular do Nervo óptico (NO), com código descrito por Gozalez et al (2004) e demonstrado na Figura 16, o qual mostra os pontos de acumulação e a detecção das coordenadas do centro.

Para cada *pixel* de borda, os pontos no círculo circundante em diferentes raios são tomados e seus pesos são incrementados, Figura 16(c), aderindo-os à matriz de acumulação. Deste modo, depois todos os raios e *pixels* de borda terem sido encontrados, o máximo provindo da matriz de acumulação, Figura 16(d) é usado para o encontro do centro do círculo e raio.

Um dos problemas com o método da Transformada Hough é que requiere valores de ponto inicial a ser escolhido para a detecção da borda, e este pode resultar nos pontos críticos da borda que serão removidos, tendo por resultado a falha detectar círculos/arcos. Outro problema é que a Transformada Hough é computacionalmente intensa e assim pode não ser apropriada para aplicações em tempo real na opinião de Masek (2003).

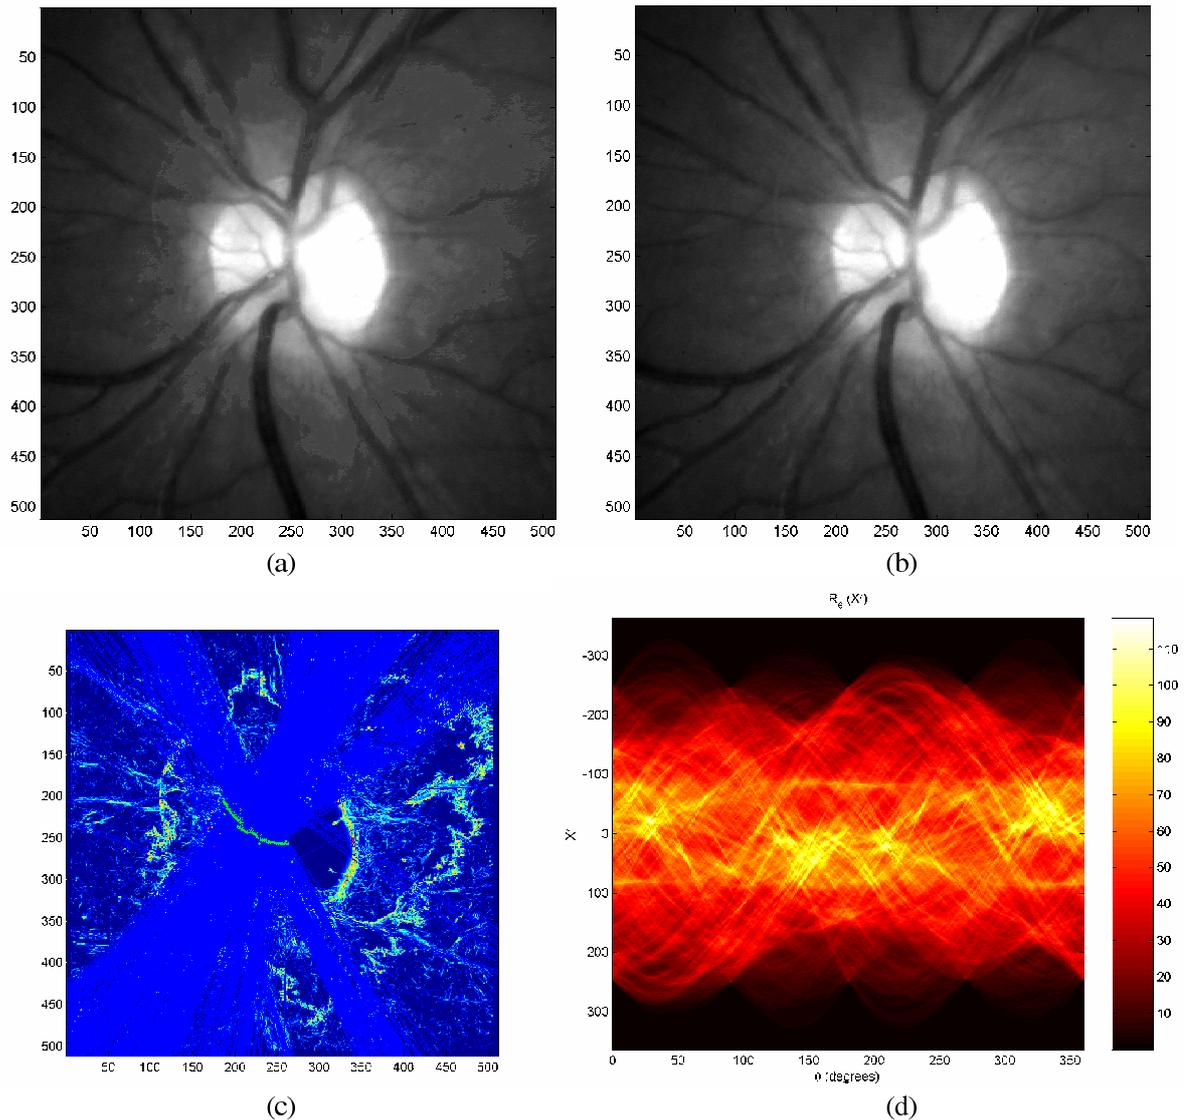


Figura 16. Aplicação da Centralização da Região de Interesse (RI) por Transformada Hough.
 (a) Imagem original e normalizada da RI. (b) Imagem Re-centralizada por Transformada Hough.
 (c) Pontos de Acumulação na aplicação da Transformada Hough na imagem filtrada por PC.
 (d) Mostra o resultado do *Hough Peak Detect* (GONZALEZ et al, 2004) dos locais de picos sobrepostos.
 Fonte: Elaborado pela autora.

Em Tisse et al (2002) é introduzida uma estratégia de detecção de contornos circulares da íris baseada na combinação dos operadores integro-diferenciais com a Transformada Hough. Consiste, primeiramente, usar uma técnica de cálculo da borda para aproximar a posição do olho na imagem global (centro da pupila) e, após, com operadores integro-diferenciais procurar os limites da pupila, o centro da íris e o limite da íris. Esta estratégia emprega decomposição de gradientes para a transformação, que é uma variante da Transformada Hough aplicada à detecção circular da forma a qual seria uma futura e interessante extensão de estudos, portanto não se aplicou esta abordagem ao presente trabalho.

A detecção automática do Disco Óptico (ou nervo óptico) em imagens de fundo de olho de baixo contraste baseadas na Transformada Hough é proposta do trabalho de Thongnuch (2006). Com o objetivo de diagnóstico de retinopatias da prematuridade é realizada uma redução dimensional do histograma da Transformada Hough Circular de 3 para 2 dimensões, baseada numa aproximação do raio do disco óptico. Primeiramente poucos círculos são aproximados pelo uso de pontos máximos do Espaço Hough. Um círculo que melhor descreve as bordas do disco óptico é escolhido e os resultados são validados por um especialista em oftalmologia (validação clínica) com base nas dimensões adquiridas pelo contorno feito à mão sobre a imagem.

A localização do disco óptico, proposta por Lalonde et al (2001) foi a construção de um algoritmo rápido e robusto de processamento de imagens para a localização e segmentação desta característica em imagens coloridas de fundo de olho de baixa resolução. A segmentação do disco óptico é uma chave de processamento em muitos algoritmos desenvolvidos para uma automatização da extração de estruturas anatômicas e detecção de lesões retiniais, caracterizadas por extração da árvore de vasos principais, detecção da mácula (ou fóvea) a qual apresenta uma distância constante do disco óptico e, finalmente, a detecção de lesões em razão de utilização de máscaras sobre a imagem do disco óptico. Neste trabalho, com a utilização de 40 imagens de variadas qualidades visuais e pigmentações de retina obtidas com pupila não-dilatada, os erros na detecção do disco óptico foram de 7% e nenhuma falsa detecção ocorreu.

1.9 Fundamentos de Transformada *Wavelet*

As *wavelets* são funções usadas para aproximar outras funções ou dados. São impressionantemente úteis em aproximar funções com descontinuidades ou mudanças abruptas de sinal. As *wavelets* preservam a descrição global e o detalhe local de uma função. As aplicações das *wavelets* incluem imagens comprimidas, tais como de raios X e até mesmo a coleção de Impressões Digitais do FBI (*Federal Bureau Investigation – USA*), incluindo dados ruidosos e se encontram aplicações em muitas áreas, incluindo a geologia, a meteorologia, a astronomia, a acústica e a econometria (ABOUFADEL et al, 2001).

O termo *wavelet* significa “ondinha”. Essa ondinha para ser admitida como *wavelet* deve apresentar alguma oscilação e cair rapidamente à zero. Esta propriedade, de admissibilidade, é a mesma que se coloca sobre uma função para que ela seja transformável via *wavelet* (GRASSI, 2004).

As funções *wavelets* tratam de sinais variantes no tempo e com comportamento não linear, buscam encontrar um conjunto de *wavelets*-filhas (construídas por dilatação/compressão e translações da *wavelet*-mãe) que melhor represente o sinal analisado. Uma *wavelet* comprimida caracteriza-se por captar mudanças rápidas (altas frequências), já uma *wavelet* alongada caracteriza-se por captar mudanças lentas (baixas frequências) num determinado sinal. Exemplos de *wavelet*-mãe e *wavelets*-filhas podem ser observados na Figura 17. Pesquisas objetivando agregar essas características das *wavelets* na teoria de redes neurais tem sido uma proposta bem interessante, pois ao invés de tratar o sinal com uma *wavelet* convencional as *wavelets*-filhas são combinadas linearmente (GRASSI, 2004).

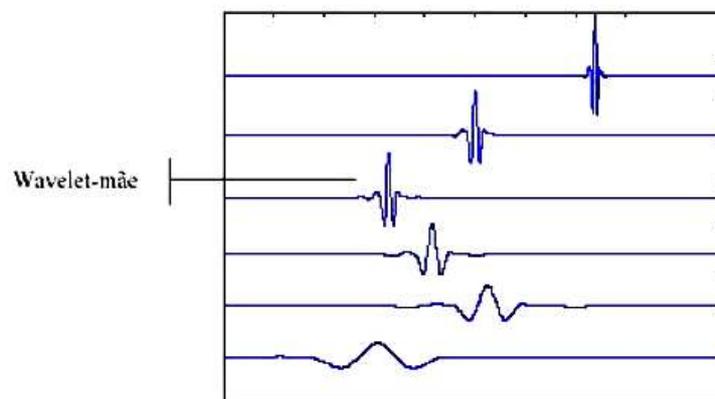


Figura 17. *Wavelet*-mãe *Symmlet* 8, em Diferentes Escalas e Localizações.
Fonte: OLIVEIRA, 2002.

Quando uma imagem digital pode ser visualizada ou processada em múltiplas resoluções, a Transformada Discreta *Wavelet* (TDW) é a ferramenta matemática adequada para a tarefa. Além de ser uma estrutura eficiente, altamente intuitiva para a representação e armazenamento de imagens em múltiplas resoluções, a TDW fornece a introspecção poderosa em uma imagem espacial e em características da frequência. A Transformada Fourier, por outro lado, revela somente as características de frequência de imagem (GONZALEZ et al, 2004).

A análise *Wavelet* está transformando-se numa ferramenta comum para análise de variações localizadas de energia dentro de séries num determinado momento. Decompor uma série temporal no espaço tempo-freqüência, pode determinar ambos os modos dominantes de variação e como aquelas modalidades variam tempo (TORRENCE & COMPO, 1998).

Os processos matemáticos que envolvem *wavelets* podem ser realizados com dados discretos ou contínuos, sendo que os procedimentos básicos são:

- A compactação de sinais: Transformada *Wavelet* (TW);
- A descompactação dos sinais: Transformada Inversa;
- Análise de energia do sinal, permitindo a confiabilidade/integridade dos dados na descompactação;
- Abordagem dos sinais num espaço vetorial e escalar, MRA (*Multiresolution Analysis*) – o coração da análise *wavelet*, pois sinais discretos são sintetizados de uma baixa resolução de sinal para uma adição sucessiva de detalhes para criar versões de alta resolução;
- *Threshold*, o método que realiza a filtragem do sinal, retirando ruídos quantitativamente (WALKER, 1999).

A TW pode apresentar vários níveis de compactação e, dependendo do sinal, deve-se atentar ao fato de que nem sempre, quanto maiores forem os níveis de compactação, melhor será o sinal. Além do mais, existem variadas TW na literatura e, conforme o tipo de aplicação, obtém-se resultados diferentes, cabendo analisar quais são os resultados melhores.

Toda TDW decompõe um sinal discreto em dois subsinais com a metade do seu tamanho. Para cada decomposição são gerados dois conjuntos, sendo cada um deles de tamanho da metade da dimensão do sinal original ($n/2$), como pode ser visualizado na Figura 18. O primeiro conjunto corresponde ao emprego dos filtros digitais de passa-baixa os quais produzem os sinais *scalings* (ou aproximação) a^1 . O segundo conjunto corresponde ao emprego dos filtros de passa-alta, que produzem os sinais *wavelets* (ou detalhamento) d^1 . O ruído do sinal estará mais concentrado nessa segunda metade como pode ser visto na Figura 19 (b) e, dependendo da aplicação, esta parte pode ser descartada ou não (FUGAL, 2007).

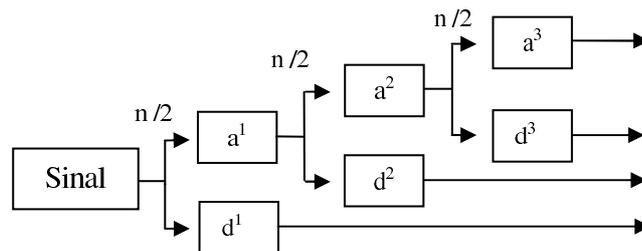


Figura 18. Análise ou Compactação de Sinal, em Vários Níveis, por Banco de Filtros *Wavelet*.
Fonte: Elaborado pela autora.

Processando os sinais de aproximação a^1 novamente, como dados de entrada com o mesmo banco de filtros, gera-se assim outro conjunto de sinais de aproximação e de detalhe com um nível de resolução inferior. Porém é desejável que o sinal, que se pretende compactar, seja da forma 2^n , ou de valor par, já que este sinal, é sempre reduzido à metade em cada nível de compactação (WALKER, 1999).

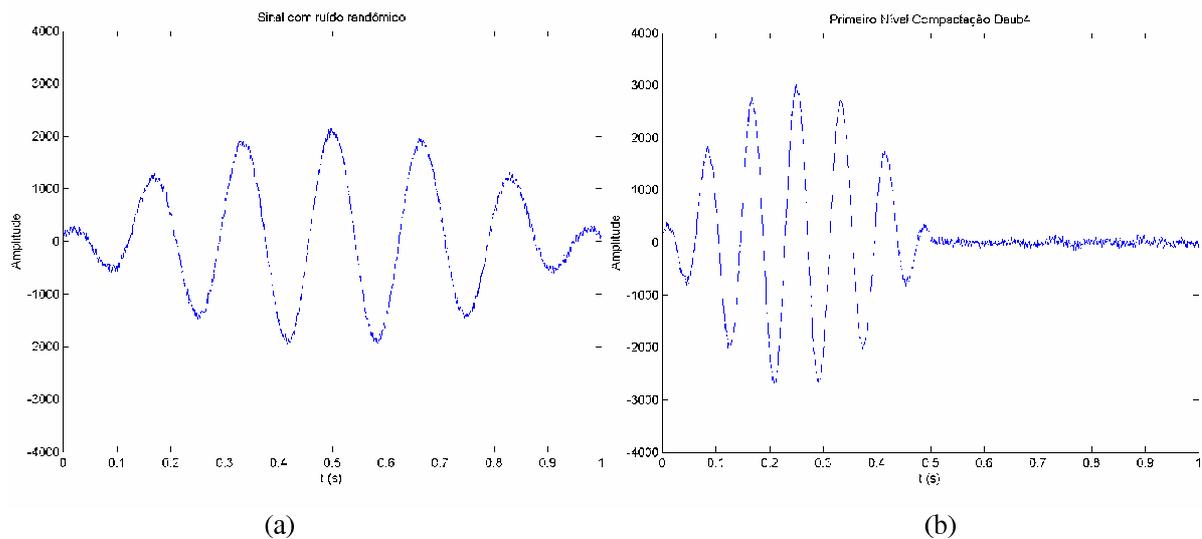


Figura 19. 1º Nível de Compactação Daub4 do Sinal Gerado pela Equação $g(x) = 20x^2(1-x)^4 \cos(12\pi x)$ para 1024 valores no intervalo (0,1), (a) Sinal adicionado de ruído randômico e (b) Sinal ruidoso no 1º Nível de Compactação Daub4.

Fonte: Elaborado pela autora.

1.9.1 Transformada *Wavelet*, de 1-D a 2-D

As idéias essenciais sobre transformação *wavelet* bidimensionais ou em várias dimensões são similares aos princípios aplicados aos sinais unidimensionais (WALKER, 1999). Assim, faz-se necessária alguma explanação das idéias básicas de Transformadas

Discretas *Wavelets* unidimensionais. A Transformada *Wavelet* Haar 1-D pode ser executada em vários estágios ou níveis e fora elaborada por Alfred Haar em 1909. O primeiro nível é o mapeamento H_1 definido pela Equação 13:

$$f \xrightarrow{H_1} (a^1 \mid d^1) \quad (13)$$

de um sinal discreto f para seu primeiro *trend* a^1 e primeiro detalhamento d^1 . Um exemplo considerado por WALKER (1999) é o seguinte, apresentado pela Equação 14:

$$(4,6,10,12,8,6,5,5) \xrightarrow{H_1} (5\sqrt{2}, 11\sqrt{2}, 7\sqrt{2}, 5\sqrt{2} \mid -\sqrt{2}, -\sqrt{2}, \sqrt{2}, 0) \quad (14)$$

O mapeamento H_1 na Equação 14 tem uma inversa. Esta inversa mapeia a transformação do sinal $(a^1 \mid d^1)$ retornando ao sinal f (reconstruindo o sinal), via seguinte fórmula da Equação 15:

$$f = \left(\frac{a^1 + d^1}{\sqrt{2}}, \frac{a^1 - d^1}{\sqrt{2}}, \dots, \frac{a^{N/2} + d^{N/2}}{\sqrt{2}}, \frac{a^{N/2} - d^{N/2}}{\sqrt{2}} \right) \quad (15)$$

Uma das propriedades mais importantes na Transformada *Wavelet* é a conservação da energia dos sinais em cada um dos níveis. Por energia de um sinal f entende-se que é a soma dos quadrados de seus valores, que é definida pela Equação 16.

$$\mathcal{E}_f = f_1^2 + f_2^2 + \dots + f_N^2 \quad (16)$$

E a Transformada *Wavelet* de Haar apresenta esta propriedade, sendo que a maior parte da energia do sinal se concentra nos subsinais a^1 onde ocorrem a maior parte das flutuações de sinais. Assim, o 2º nível de compactação Haar do sinal f ocorrerá somente sobre os sinais a^1 , como pode ser observado na Equação 17 sobre o exemplo citado anteriormente na Equação 14.

$$(a^2 \mid d^2 \mid d^1) = (16, 12 \mid -6, 2 \mid -\sqrt{2}, -\sqrt{2}, \sqrt{2}, 0) \quad (17)$$

E o 3º nível de compactação Haar, sobre o exemplo na Equação 14, do sinal f tem como resultado a Equação 18:

$$(a^3 | d^3 | d^2 | d^1) = (14\sqrt{2} | 2\sqrt{2} | -6,2 | -\sqrt{2}, -\sqrt{2}, \sqrt{2}, 0) \quad (18)$$

Na obra publicada por WALKER (1999) é apresentada a acumulação de 90% da energia total de f no subsinal a^2 com dados compactados a $\frac{1}{4}$ do comprimento de f . Entretanto a acumulação da energia no 3º nível de transformação é de 87,89% com dados compactados a $\frac{1}{8}$ do comprimento de f . Nota-se que ocorre um fenômeno interessante ao nível de estudos de Teoria Quântica, pois ao tentar-se comprimir a energia em intervalos cada vez menores é inevitável o escape de alguma energia para fora.

Uma exemplificação da compactação Daub4 utiliza coeficientes para o cálculo dos termos *scalings* (subsinais *trends*) e *wavelets* (subsinais de detalhamento). Os quatro termos dos coeficientes da função *scaling*, na compactação Daub4, são apresentados no conjunto de coeficientes do Quadro 1 que são provenientes de citações em Kaplan (2001) & Walker (1999):

$\alpha_0 = \frac{1+\sqrt{3}}{4\sqrt{2}}$	$\alpha_1 = \frac{3+\sqrt{3}}{4\sqrt{2}}$	$\alpha_2 = \frac{3-\sqrt{3}}{4\sqrt{2}}$	$\alpha_3 = \frac{1-\sqrt{3}}{4\sqrt{2}}$
---	---	---	---

Quadro 1. Coeficientes *Scaling* de Daub4
Fonte: WALKER, 1999.

Uma importante propriedade destes sinais *scaling* é que eles todos tem energia 1, Equação 19, e satisfaz outra identidade conforme mostrada na Equação 20 (WALKER, 1999):

$$\alpha_0^2 + \alpha_1^2 + \alpha_2^2 + \alpha_3^2 = 1 \quad (19)$$

$$\alpha_0 + \alpha_1 + \alpha_2 + \alpha_3 = \sqrt{2} \quad (20)$$

Já os quatro termos dos coeficientes da função *wavelet* são definidos na Daub4 conforme os coeficientes apresentados no Quadro 2 (KAPLAN, 2001) & (WALKER, 1999), que estão relacionados aos valores descritos no Quadro 1:

$\beta_0 = \alpha_3$	$\beta_1 = -\alpha_2$	$\beta_2 = \alpha_1$	$\beta_3 = -\alpha_0$
----------------------	-----------------------	----------------------	-----------------------

Quadro 2. Coeficientes *Wavelets* de Daub4.
Fonte: WALKER, 1999.

Também ocorre que o somatório dos sinais *wavelets* têm energia 1, e satisfaz outra identidade, tal como generalizado no caso Haar 1-D em que $\frac{1}{\sqrt{2}} - \frac{1}{\sqrt{2}} = 0$, conforme mostram as Equações 21 e 22:

$$\beta_0^2 + \beta_1^2 + \beta_2^2 + \beta_3^2 = 1 \quad (21)$$

$$\beta_0 + \beta_1 + \beta_2 + \beta_3 = 0 \quad (22)$$

A matriz-exemplo, Equação 23, dos coeficientes para o cálculo da Transformada *Wavelet* Daub4, pode ser representada para um sinal s_n com oito elementos discretos ($n = 0..8$) da seguinte forma (KAPLAN, 2001):

$$\begin{array}{cccccccc}
 \alpha_0 & \alpha_1 & \alpha_2 & \alpha_3 & 0 & 0 & 0 & 0 \\
 \beta_0 & \beta_1 & \beta_2 & \beta_3 & 0 & 0 & 0 & 0 \\
 0 & 0 & \alpha_0 & \alpha_1 & \alpha_2 & \alpha_3 & 0 & 0 \\
 0 & 0 & \beta_0 & \beta_1 & \beta_2 & \beta_3 & 0 & 0 \\
 0 & 0 & 0 & 0 & \alpha_0 & \alpha_1 & \alpha_2 & \alpha_3 \\
 0 & 0 & 0 & 0 & \beta_0 & \beta_1 & \beta_2 & \beta_3 \\
 \alpha_2 & \alpha_3 & 0 & 0 & 0 & 0 & \alpha_0 & \alpha_1 \\
 \beta_2 & \beta_3 & 0 & 0 & 0 & 0 & \beta_0 & \beta_1
 \end{array} \cdot \begin{array}{c} s_0 \\ s_1 \\ s_2 \\ s_3 \\ s_4 \\ s_5 \\ s_6 \\ s_7 \end{array} \quad (23)$$

O sinal é representado por um vetor e os coeficientes da Transformada *Wavelet* Daub4 por uma matriz quadrada, com coeficientes *scalings* e *wavelets* em linhas intercaladas e transladadas a cada duas colunas, de dimensão igual ao número de linhas do vetor. Procedese com a operação de multiplicação entre matrizes, obtendo como resposta outro vetor, no qual *scalings* e *wavelets* estarão intercalados. Separam-se os *scaling signals* para a primeira metade do intervalo e os *wavelets signals* para a segunda parte do intervalo estudado, num determinado período (KAPLAN, 2001).

Este sinal poderá se reduzir pela metade tantas vezes quanto for repetido o processo da multiplicação, com a matriz de coeficientes reduzida à metade, conforme descrito anteriormente, sempre utilizando os valores de *scalings* para novas compactações, desde que o número de pontos da matriz inicial seja potência de base dois. Diferente da Transformada *Wavelet* de Haar, quando os coeficientes chegam ao final da linha, eles são automaticamente recolocados no início da mesma linha, tal como ocorre, nas duas últimas linhas da matriz da Equação 23 (KAPLAN, 2001).

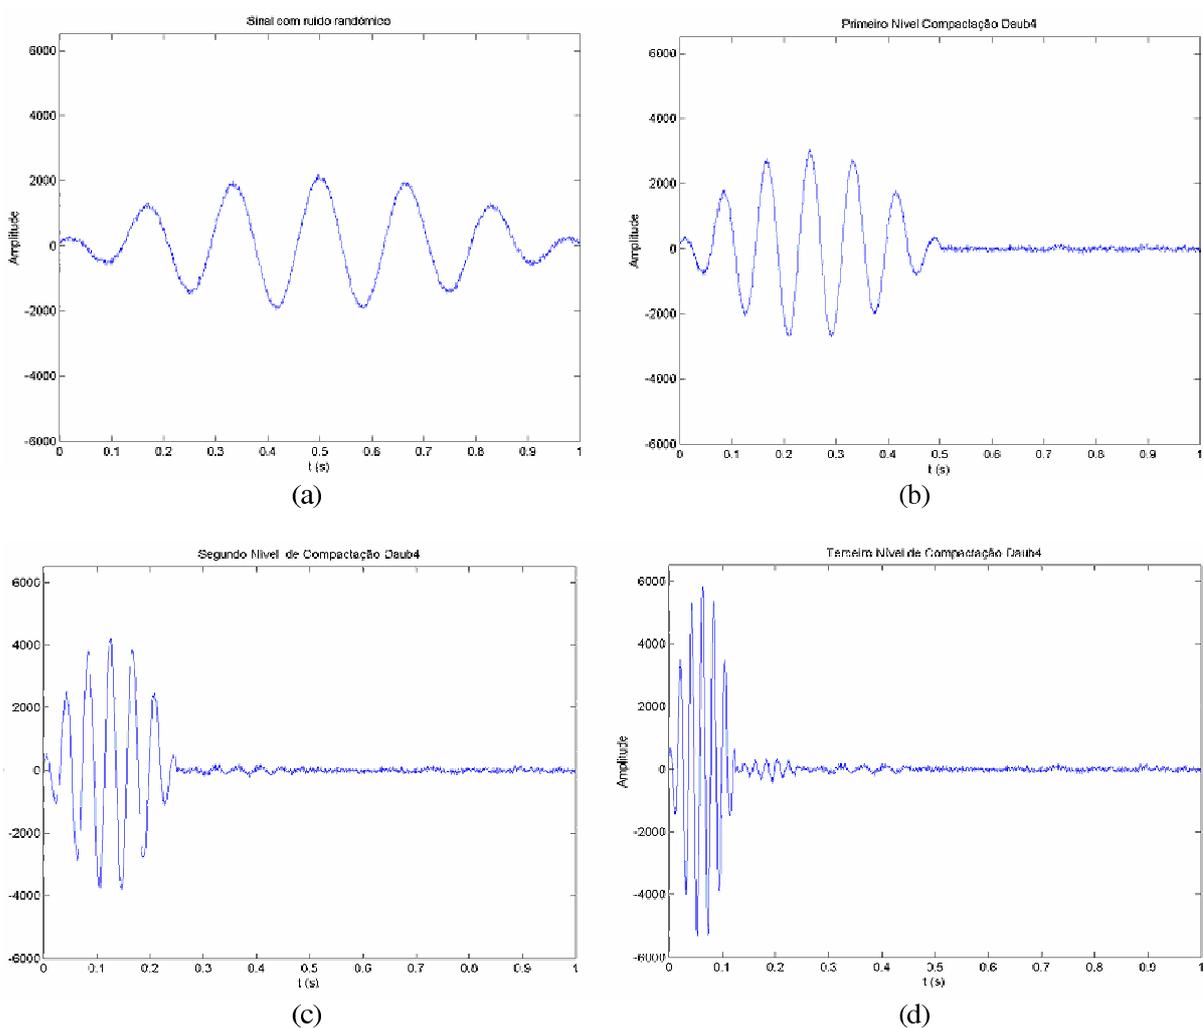


Figura 20. Compactação até o 3º nível Daub4 do Sinal Gerado pela Equação $g(x) = 20x^2(1-x)^4 \cos(12\pi x)$ para 1024 valores no intervalo (0,1),

- (a) Sinal adicionado de ruído randômico, (b) 1º Nível de Compactação Daub4 de (a)
 (c) 2º Nível de Compactação Daub4 de (a), (d) 3º Nível de Compactação Daub4 de (a).

Fonte: Elaborado pela autora.

A utilização dos coeficientes *scalings* e *wavelets* se aplica iterativamente somente sobre os sinais *scalings* obtidos da compactação anterior. Assim, obtém-se a 2ª e a 3ª

compactação do sinal, sendo que neste último, o sinal significativo está concentrado a 1/8 dos pontos iniciais do domínio, conforme pode ser visto na Figura 20. O que também se observa é que a amplitude do sinal aumenta sensivelmente em relação ao nível de compactação anterior.

Para a realização do *threshold*, existem variadas técnicas. Conforme o sinal e o ruído, algumas se aplicam bem como, por exemplo, a proposta de “eliminação” ou “fatiamento”, tal como mostrado na Figura 21, de um determinado intervalo da imagem tanto para *scalings* quanto para *wavelets signals* conforme proposto por (WALKER, 1999). A Figura 21 permite, também, comparar o sinal ruidoso e reconstruído.

Assim, a Transformada *Wavelet* pode ser usada para analisar séries temporais que contém sinais não-estacionários. Para ser admissível como uma *wavelet*, esta função deve estar centralizada em zero e localizada tanto nos espaços de tempo quanto de frequência (TORRENCE & COMPO, 1998). Temos $\psi(t)$, *wavelet*-mãe, $\psi(t) \in L^2(\mathfrak{R})$ e suas operações de escalonamento (a), parâmetro de escala idêntico à escala em mapas cartográficos e deslocamento (b), na obtenção das *wavelets*-filhas, definidas pela Equação 24 (OLIVEIRA, 2002):

$$\psi_{a,b}(t) = \psi_a(t-b) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \text{ com } \{\psi(t)\} \rightarrow \{\psi_{a,b}(t)\}_{(\forall a, a \neq 0)(\forall b \in \mathfrak{R})} \quad (24)$$

Visando garantir a isomeria, todas as *wavelets* têm a mesma energia, apresentada na Equação 25, já que há um ajuste na amplitude do sinal escalonado (OLIVEIRA, 2002):

$$\|\psi(t)\|^2 = \|\psi_{a,b}(t)\|^2. \quad (25)$$

O termo $|a|^{-\frac{1}{2}}$ é um fator de normalização da energia do sinal e $\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right)$, $a \neq 0$ é uma transformada afim, então, uma *wavelet* $\psi_{a,b}(t)$ é definida por um mapeamento afim unitário. Assim, estas *wavelets* são versões transladadas (b) e dilatadas ($a > 1$) ou comprimidas ($a < 1$) de uma mesma onda protótipo, chamada *wavelet*-mãe $\psi(t)$ (OLIVEIRA, 2002).

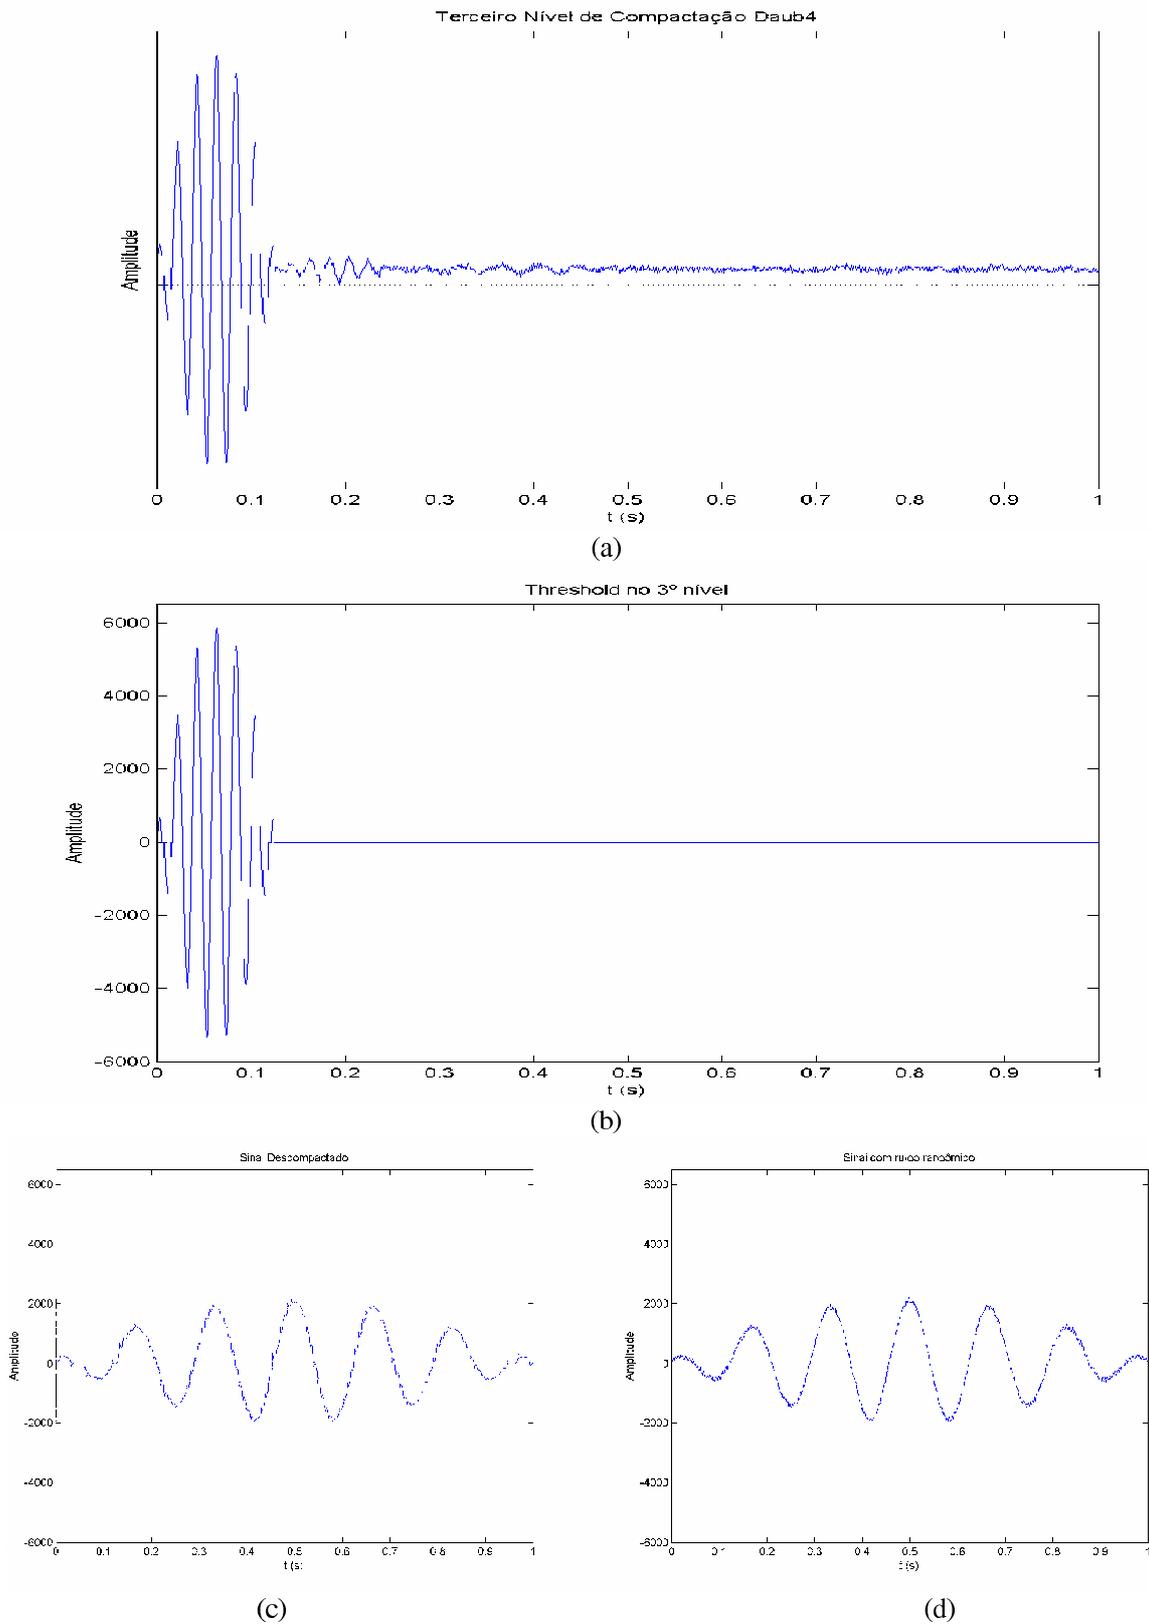


Figura 21. Análise da Eliminação de Ruídos de um Sinal Compactado até o 3º Nível de Compactação Daub4 em (a) com a proposta de fatiamento, (b) Sinal “fatiado”, (c) Sinal Descompactado que pode ser comparado ao original em (d).

Fonte: Elaborado pela autora.

Para a obtenção de uma TW bidimensional, o primeiro passo consiste em aplicar uma Transformada *Wavelet* 1D a cada linha de f , produzindo uma nova imagem. O segundo passo é aplicar à nova imagem obtida no primeiro passo, a mesma Transformada *Wavelet* 1D a cada uma de suas colunas. Isso produz uma matriz, Equação 26, com as subimagens (WALKER, 1999):

$$f \rightarrow \begin{bmatrix} h^1 & | & d^1 \\ - & & - \\ a^1 & | & v^1 \end{bmatrix} \quad (26)$$

onde cada subimagem h^1 , d^1 , a^1 e v^1 possui $\frac{m}{2}$ linhas e $\frac{n}{2}$ colunas. Podem-se visualizar os efeitos destes filtros na Figura 22:

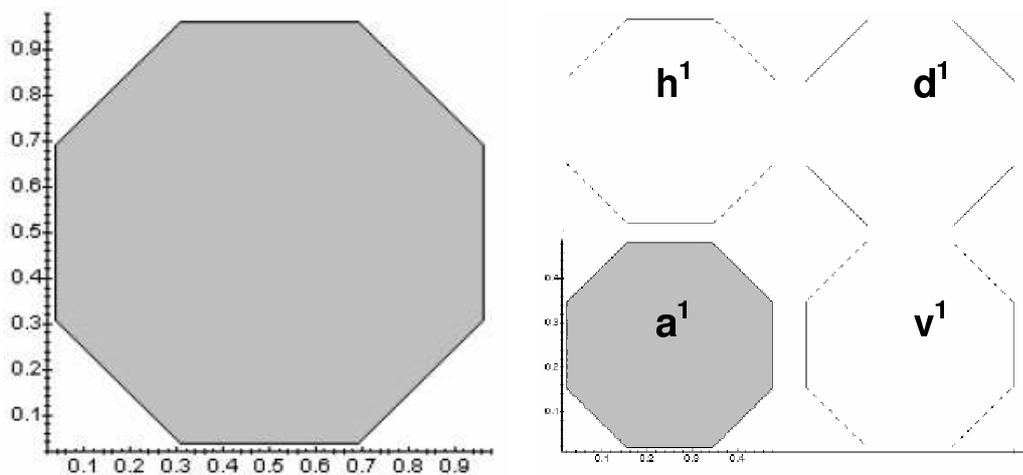


Figura 22. Octógono com as Devidas Compactações e Detecções de Bordas.
Fonte: PAZOS, 2006.

1.9.2 Banco de Filtros Bivariados de Transformada *Wavelet* de Haar e Daub4

As *Wavelets*, como uma alternativa à análise de Fourier, tem permitido pesquisadores estudarem imagens e outros sinais em diferentes resoluções. O algoritmo que utiliza filtros bivariados opera com matrizes $2^n \times 2^n$, derivadas das funções Haar 1-D por vias de produto tensorial. Estes filtros transformam uma matriz em outra semelhante, com a idéia de que as

entradas na nova matriz pode ser um rearranjo da informação que terá ajuda com a aplicação na análise de manuscritos no trabalho de Lytle & Yang (2006). Simplesmente, os filtros bivariados são quatro filtros de Haar, como podem ser vistos no Quadro 3, que se apresentam do seguinte modo:

$H = \begin{bmatrix} \frac{1}{2} & \frac{1}{2} \\ \frac{1}{2} & \frac{1}{2} \end{bmatrix}$	Passa-baixa ¹
$G_V = \begin{bmatrix} \frac{1}{2} & -\frac{1}{2} \\ \frac{1}{2} & -\frac{1}{2} \end{bmatrix}$	Passa-alta vertical
$G_H = \begin{bmatrix} \frac{1}{2} & \frac{1}{2} \\ -\frac{1}{2} & -\frac{1}{2} \end{bmatrix}$	Passa-alta horizontal
$G_D = \begin{bmatrix} \frac{1}{2} & -\frac{1}{2} \\ -\frac{1}{2} & \frac{1}{2} \end{bmatrix}$	Passa-alta diagonal

Quadro 3. Conjunto de Filtros Bivariados de Transformada *Wavelet* de Haar
Fonte: LYTLE & YANG, 2006.

Após a aplicação dos quatro filtros sobre uma imagem, os resultados são dispostos numa nova matriz, como pode ser simbolizado pela Equação 27 (LYTLE & YANG, 2006) & (WALKER, 1999) e demonstrado a aplicação destes filtros em imagens retiniais na Figura 23. A maior parte da energia do sinal na imagem se concentra na parte filtrada por passa-baixa, o sinal a^1 ou Figura 23 (c), que apresenta $\frac{1}{4}$ do tamanho da imagem original, sendo possível realizar novas compactações a partir deste. Os detalhes de características de bordas verticais

¹ Geralmente filtros de passa-alta são etiquetados com H's, mas não é uma convenção.

na Figura 23(d), horizontais na Figura 23(a) ou diagonais na Figura 23(b), são apresentados nos sinais em que os filtros de passa-alta foram aplicados.

$$f \longrightarrow \begin{pmatrix} h^1 & | & d^1 \\ - & & - \\ a^1 & | & v^1 \end{pmatrix} \quad (27)$$

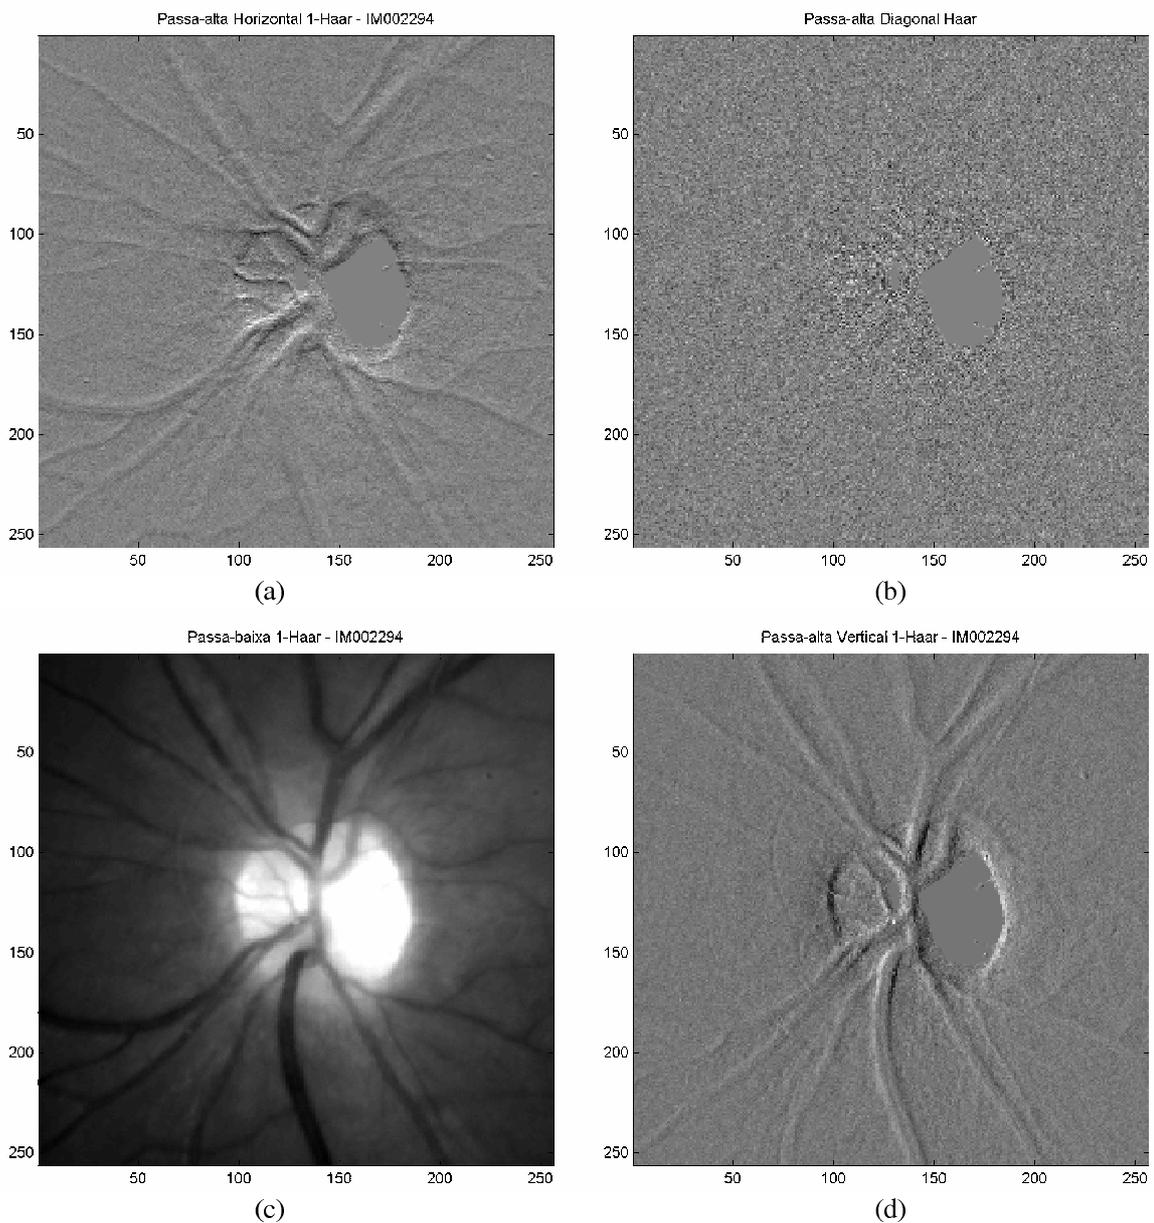


Figura 23. Resultados do 1º Nível de Compactação com Uso de Banco de Filtros Bivariados de Transformada *Wavelet* de Haar na Imagem IM002294.TIFF.

A aplicação do filtro de passa-alta horizontal é mostrada em (a), o de passa-alta diagonal em (b) e o de passa-alta vertical em (d). Já a aplicação do filtro de passa-baixa em (c) é o que concentra a maior parte da energia do sinal da imagem.

Fonte: Elaborado pela autora.

Nesta matriz cada subimagem h^l , d^l , a^l e v^l possui $\frac{m}{2}$ linhas e $\frac{n}{2}$ colunas, considerando que a matriz original é de m -linhas por n -colunas. Algumas notações são interessantes ressaltar (PAZOS, 2006):

- a^l = resultado de somar as tendências principais ao longo das linhas, seguida por somas de tendências principais ao longo das colunas (1ª transformada).
- h^l = resultado de somar as tendências principais ao longo das linhas, seguida pelas flutuações ao longo das colunas.
- d^l = resultado de somar as flutuações ao longo das linhas, seguida por somas das flutuações ao longo das colunas.
- v^l = resultado de somar as flutuações ao longo das linhas, seguida por somas de tendências principais ao longo das colunas.

Quando os filtros são aplicados novamente (ou iterativamente) sobre os dados a^1 obtém-se a transformada de 2º nível destes filtros bivariados, simbolizados na Equação 28 (LYTLE & YANG, 2006) & (WALKER, 1999) e a aplicação pode ser visualizada na Figura 24 em pseudocores do esquema HSV, alternativo à escala de cinza que não apresenta muito boa visualização dos detalhes neste nível, disponível pelo software MATLAB®. Quanto aos níveis de energia do sinal, observa-se que o mesmo conserva-se muito bem nos variados níveis de compactação Haar, sendo que no 1º nível os dados a^1 apresentam 99,97% do sinal original, enquanto que os dados compactados no 2º nível apresentam 99,92% do sinal original o que demonstra ser satisfatório em termos de processamento de sinais.

$$a^1 \rightarrow \begin{bmatrix} h^2 & | & d^2 \\ - & & - \\ a^2 & | & v^2 \end{bmatrix} \quad (28)$$

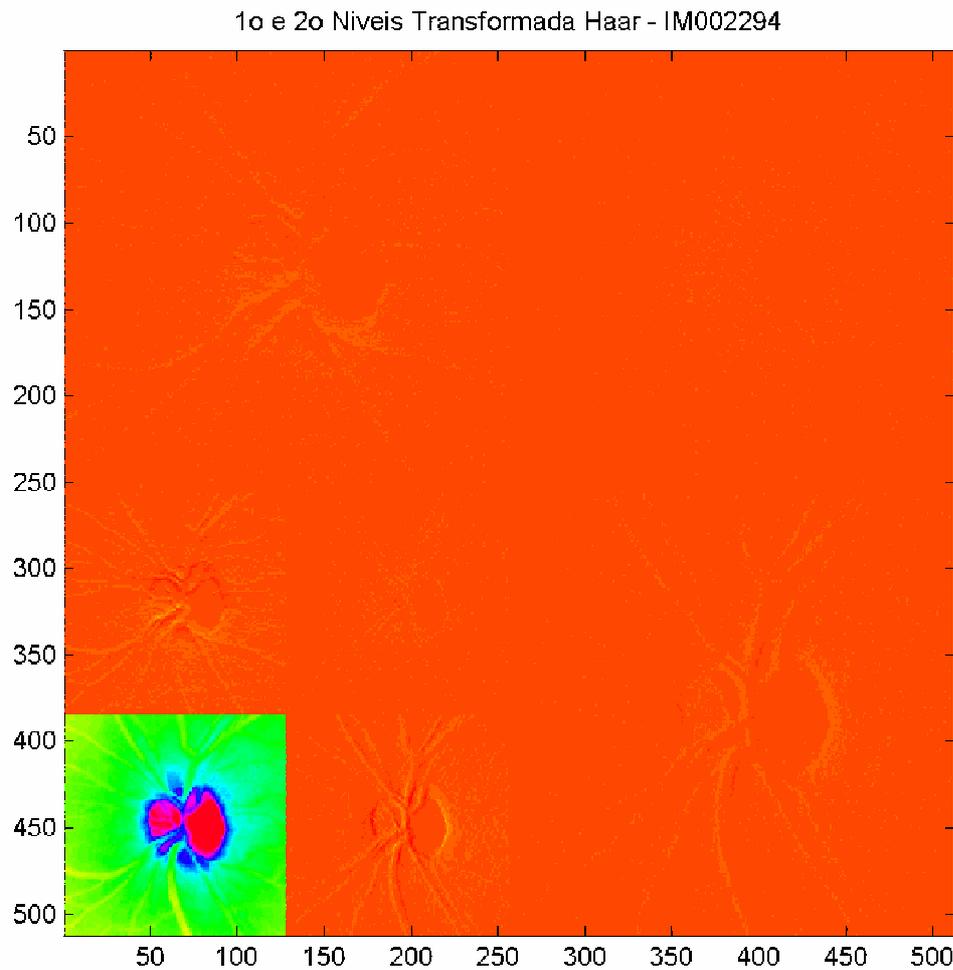


Figura 24. 1º e 2º Níveis de Compactação na Aplicação de Banco de Filtros Bivariados de Transformada *Wavelet* de Haar.

Fonte: Elaborado pela autora.

Já para a aplicação de Banco de Filtros Bivariados de Transformada *Wavelet* Daub4, os coeficientes foram organizados do modo demonstrado no Quadro 4. Os coeficientes $\alpha_1, \dots, \alpha_{15}$ são baseados nos coeficientes Daub4 unidimensionais produzidos por vias de produto tensorial, citados no trabalho de Aboufadel (2001) e mostrados no Quadro 5. A aplicação destes coeficientes, em dois níveis de compactação, em imagens, é demonstrada na Figura 25.

$D = \begin{bmatrix} \alpha_0 & \alpha_1 & \alpha_2 & \alpha_3 \\ \alpha_4 & \alpha_5 & \alpha_6 & \alpha_7 \\ \alpha_8 & \alpha_9 & \alpha_{10} & \alpha_{11} \\ \alpha_{12} & \alpha_{13} & \alpha_{14} & \alpha_{15} \end{bmatrix}$	Passa-Baixa
$G_V = \begin{bmatrix} \alpha_0 & -\alpha_1 & \alpha_2 & -\alpha_3 \\ \alpha_4 & -\alpha_5 & \alpha_6 & -\alpha_7 \\ \alpha_8 & -\alpha_9 & \alpha_{10} & -\alpha_{11} \\ \alpha_{12} & -\alpha_{13} & \alpha_{14} & -\alpha_{15} \end{bmatrix}$	Passa-Alta Vertical
$G_H = G_V^T$	Passa-Alta Horizontal
$G_D = \begin{bmatrix} \alpha_0 & -\alpha_1 & \alpha_2 & -\alpha_3 \\ -\alpha_4 & \alpha_5 & -\alpha_6 & \alpha_7 \\ \alpha_8 & -\alpha_9 & \alpha_{10} & -\alpha_{11} \\ -\alpha_{12} & \alpha_{13} & -\alpha_{14} & \alpha_{15} \end{bmatrix}$	Passa-Alta Diagonal

Quadro 4. Banco de Filtros Bivariados de Transformada *Wavelet* Daub4
Fonte: Elaborado pela autora.

$\alpha_0 = -\frac{1}{4} - \frac{1}{8}\sqrt{2}$	$\alpha_1 = \frac{1}{8}\sqrt{2}$	$\alpha_2 = \frac{1}{2} + \frac{1}{4}\sqrt{3} + \frac{1}{8}\sqrt{2}$	$\alpha_3 = \frac{1}{4} - \frac{1}{8}\sqrt{2} + \frac{1}{4}\sqrt{3}$
$\alpha_4 = 0$	$\alpha_5 = \frac{1}{2}$	$\alpha_6 = \frac{3}{4} + \frac{1}{4}\sqrt{3}$	$\alpha_7 = \frac{1}{4} + \frac{1}{4}\sqrt{3}$
$\alpha_8 = \frac{1}{2} - \frac{1}{4}\sqrt{3} + \frac{1}{8}\sqrt{2}$	$\alpha_9 = \frac{3}{4} - \frac{1}{4}\sqrt{3} - \frac{1}{8}\sqrt{2}$	$\alpha_{10} = \frac{1}{4} - \frac{1}{8}\sqrt{2}$	$\alpha_{11} = \frac{1}{8}\sqrt{2}$
$\alpha_{12} = \frac{1}{4} - \frac{1}{4}\sqrt{3}$	$\alpha_{13} = \frac{1}{4} - \frac{1}{4}\sqrt{3}$	$\alpha_{14} = 0$	$\alpha_{15} = 0$

Quadro 5. Coeficientes do Banco de Filtros Bivariados de Transformada *Wavelet* Daub4
definidos por vias de Produto Tensorial sobre os coeficientes da TDW Daub4.
Fonte: ABOUFADEL, 2001.

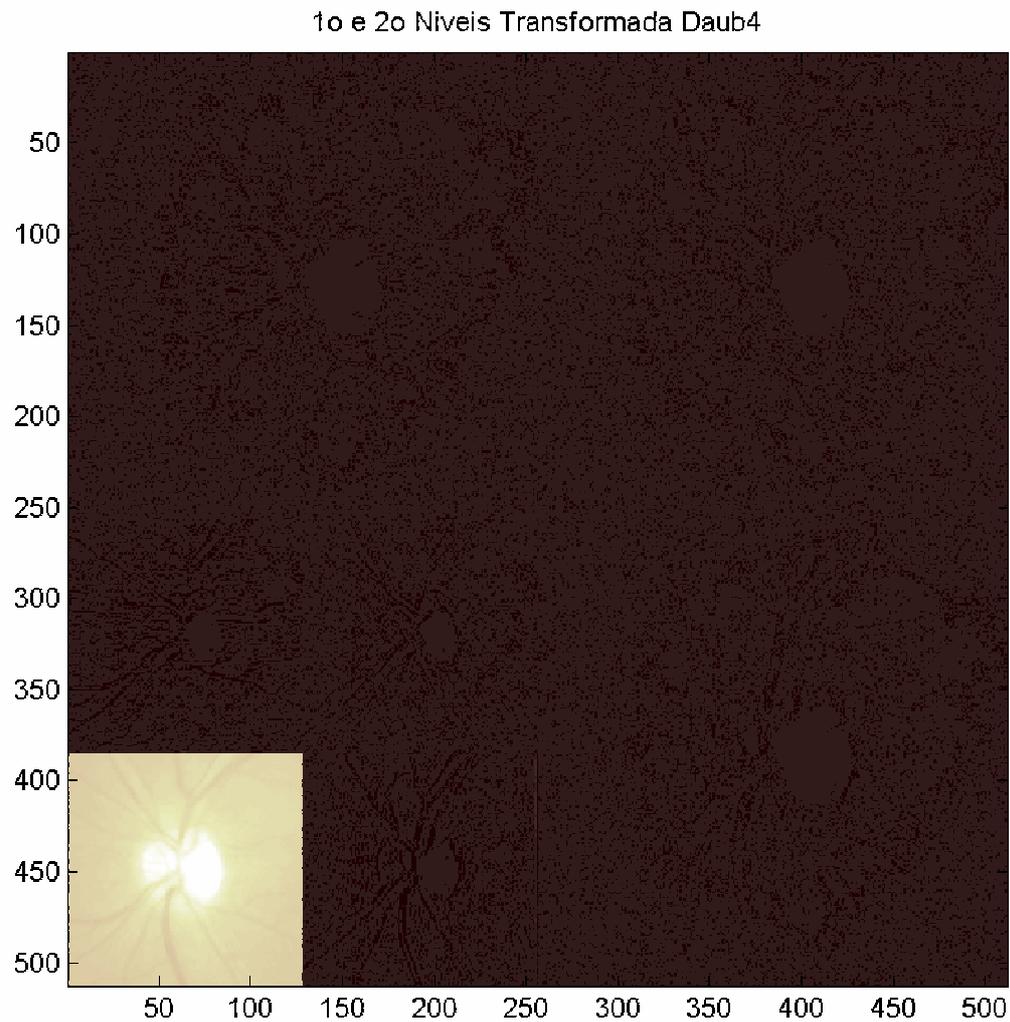


Figura 25. 1° e 2° Níveis de Compactação com Uso de Bancos de Filtros Bivariados de Transformada *Wavelet* Daub4.

Fonte: Elaborado pela autora.

Nota-se que o somatório dos coeficientes do filtro de passa-baixa Daub4 é igual a 4, enquanto que o passa-baixa Haar tem por somatório 2. Os filtros de passa-alta têm somatório zero em Haar e neste trabalho foi proposto que os filtros de passa-alta Daub4 obedecessem a este mesmo critério. O passa-alta horizontal é, simplesmente, composto pelos coeficientes do filtro passa-alta vertical transpostos. A análise da energia do sinal no 1° nível os dados a^1 obtidos via Banco de Filtros Bivariados de Transformada *Wavelet* Daub4 apresenta 99,36% do sinal original, e a energia dos dados compactados no 2° nível apresentam 99,35% do sinal original o que demonstra ser satisfatório em termos de processamento de sinais.

A diferença de processamento entre filtros Daub4 e Haar é que o primeiro apresenta um tempo computacional maior em relação ao segundo e os resultados são visíveis quanto à

filtragem, conforme pode ser visualizado na Figura 26. O resultado da aplicação de filtragem por passa-baixa Haar, apresentada na Figura 26 (a), na binarização da mesma representada na Figura 26(c) apresenta menos ruídos de imagem que a Figura 26(d), resultante da aplicação de binarização sobre a filtragem passa-baixa Daub4, representada na Figura 26 (b).

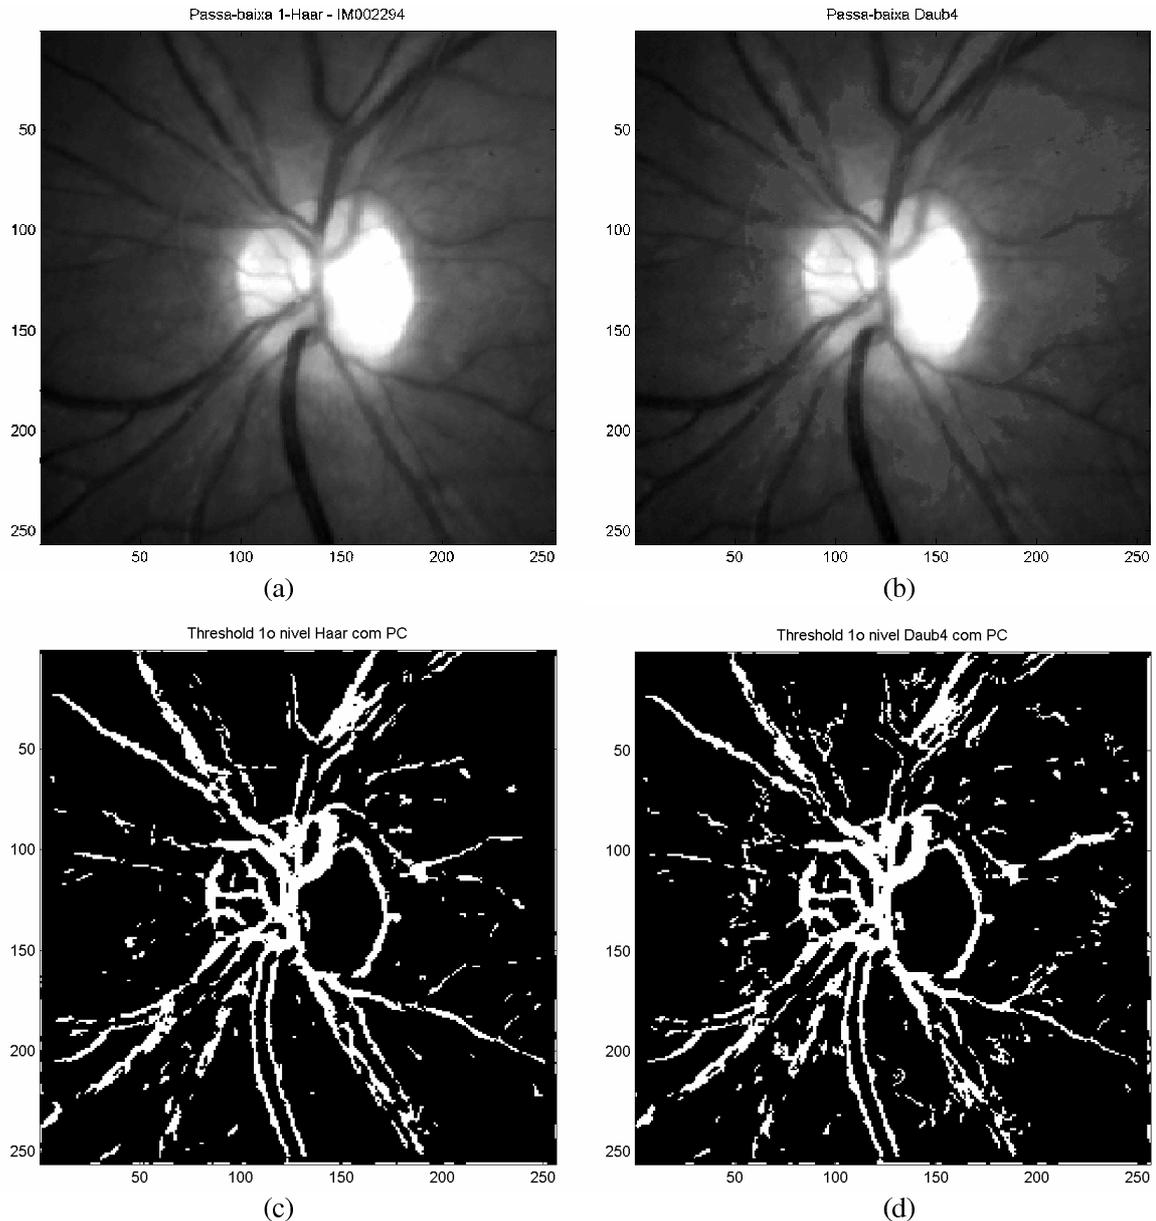


Figura 26. Comparação dos Dados a_1 no Primeiro Nível de Compactação com Uso de Banco de Filtros Bivariados de Transformada *Wavelet* de Haar e Daub4.

(a) a_1 no 1º nível de aplicação do Filtro Haar Bivariado. (b) a_1 no 1º nível de aplicação do Filtro Daub4 Bivariado. (c) Binarização, após aplicação de PC na imagem (a). (d) Binarização, após aplicação de PC na imagem (b).

Fonte: Elaborado pela autora.

O tempo computacional de processamento menor dos Bancos de Filtros Bivariados de Transformada *Wavelet* de Haar em relação aos Daub4 é devido à própria dimensionalidade do filtro, enquanto que os filtros bivariados Daub4 realizam convolução com máscara de 16 *pixels* na compactação dos dados os de Haar realizam a convolução somente com quatro, ao mesmo tempo em que a compactação em ambos os casos sempre resulta em $\frac{1}{4}$ dos dados iniciais.

1.10 Análise de Matrizes Esparsas

Matrizes Esparsas são aplicáveis em vários problemas da ciência e engenharia, tais como em programação linear e análise de estruturas. De fato, muitas matrizes são enormes e esparsas na análise de sistemas físicos e o reconhecimento deste fato faz com que a solução de sistemas lineares com milhões de coeficientes seja possível. Uma matriz é dita esparsa se ela contém uma alta taxa de elementos nulos (PENNY & LINDFIELD, 1995).

Programas de simulação de circuitos e análise de elementos finitos costumam lidar com matrizes contendo menos de 1% de elementos diferentes de zero (HANSELMAN & LITTLEFIELD, 2003). Para eliminar o desperdício de memória ao armazenar os zeros de uma matriz esparsa, podem-se armazenar apenas os seus elementos não-nulos, usando par de números (índices) que identifique a posição do elemento e seu valor. Do mesmo modo, para evitar operações envolvendo elementos nulos, alguns algoritmos especiais são aplicados no tratamento de sistemas lineares esparsos (CUNHA, 2000).

Um importante parâmetro descritivo de uma matriz esparsa é o número de elementos não nulos da matriz. Tanto a complexidade computacional de operações quanto a necessidade de armazenamento com essas matrizes é proporcional ao número de elementos não-nulos que linearmente dependem das dimensões da matriz, mas independem do produto de suas linhas por colunas (GILBERT et al, 1992).

1.11 Classificação Baseada na Aparência - PCA

Os métodos que compõem a abordagem baseada na aparência (*appearance based methods*), recebem este nome devido ao fato de não utilizarem nenhum conhecimento a priori sobre o objeto ou características específicas a serem detectadas. Nesta classe de algoritmos surgem os conceitos de aprendizado e treinamento, uma vez que as informações necessárias para realizar a tarefa de detecção são retiradas do próprio conjunto de imagens sem intervenção externa. Portanto, o algoritmo captura as informações de que precisa para detectar ou reconhecer um objeto a partir de um conjunto de imagens criando uma representação interna do objeto de interesse.

As primeiras aplicações em reconhecimento de padrões na biometria aplicavam a Correlação, pois possivelmente, era o esquema de classificação mais simples. Na Correlação, uma imagem no conjunto de teste é reconhecida (classificada) pela fixação para seu nome no ponto de fechamento no conjunto de aprendizado, onde as distâncias são medidas no espaço de imagem. Se todas as imagens são normalizadas numa média zero e variância unitária, então este procedimento é equivalente a escolher a imagem no conjunto de aprendizado que melhor correlaciona com a imagem de teste. Devido ao processo de normalização, o resultado é independente da intensidade da fonte de luz e dos efeitos de uma câmera de vídeo automática (DELAC et al, 2005) & (BELHUMEUR, 1997).

Porém o procedimento de Correlação tem severas e conhecidas desvantagens sendo que, primeiramente, se as imagens no conjunto de aprendizado e no conjunto de teste são coletadas sob condições de iluminação variadas, então o ponto correspondente no espaço de imagem pode não ser justamente agrupado. Assim, para este método trabalhar confiavelmente sobre variações luminosas, é necessário um conjunto de aprendizado densamente amostrado nas possíveis condições de luminosidade. Segundo, a correlação é um processo dispendioso computacionalmente e, para o reconhecimento, deve-se correlacionar à imagem de face teste com cada imagem no conjunto de aprendizado. Terceiro, isto requer uma grande quantidade de espaço de armazenamento o conjunto de aprendizado deve conter numerosas imagens de cada pessoa (BELHUMEUR, 1997).

Como os métodos de correlação são custosos computacionalmente e requerem um grande espaço de armazenagem das informações, é natural a procura de esquemas de redução dimensional. Uma técnica comumente utilizada para redução dimensional em visão computacional, particularmente em reconhecimento facial, é a Análise de Componentes principais (ou PCA – *Principal Component Analysis*). A técnica de PCA, aliada aos conhecimentos de métodos de “Karhunen-Loève”, realiza uma redução dimensional da projeção linear que maximiza a dispersão de todas as amostras projetadas (BELHUMEUR, 1997).

Embora alguns detalhes variem nos variados sistemas de identificação biométricos propostos por PCA, estes sistemas podem ser descritos em termos de etapas que são caracterizadas pela aprendizagem de um conjunto de vetores de característica e a procura de uma representação do subespaço que capture a estrutura dos dados. Geralmente, ao calcular a matriz de covariância do problema, os autovetores são classificados diminuindo o autovalor que faz exame somente da maioria dos representativos que correspondem aos sentidos da variação máxima. Uma vez que o subespaço é totalmente descrito por uma matriz da projeção, a classificação de um vetor característico novo é efetuada pela projeção e encontro com o vetor de treinamento mais próximo deste (GUILLAMET & VITRIÀ, 2002).

Devido à dimensionalidade elevada dos dados em imagens, similaridade e distância métrica tornam-se computacionalmente elevados e uma compactação dos dados é exigida. Assim PCA é um esquema linear muito favorável na redução dimensional que faz referência a Média Quadrática de Erros (MSE – *Mean Squared Error*) da reconstrução (GUILLAMET & VITRIÀ, 2002).

A técnica *Eigenface* é um método baseado na projeção linear do espaço de imagem em um subespaço característico dimensionalmente baixo, utilizando Análise de Componentes Principais (PCA – *Principal Component Analysis*) para a redução dimensional, proporcionando direções que maximizam o total dispersado através de todas as classes, ou seja, com todas as imagens faciais. Na escolha da projeção, que maximiza o total dispersado, o PCA retém variações não requeridas necessárias para iluminação e expressão facial. Deste modo, a projeção por PCA continua sendo muito favorável para reconstrução em base dimensional baixa. Toma-se um conjunto de imagens faciais identificadas denominadas

“Conjunto de Aprendizado” e um conjunto de imagens faciais do mesmo grupo de pessoas, o “Conjunto de Teste”, identificando cada pessoa nas imagens de Teste. A abordagem deste problema no paradigma de padrões de classificação considera cada um dos valores de *pixel*, em uma imagem exemplar, como uma coordenada num espaço dimensional alto. (BELHUMEUR, 1997).

Em Belhumeur (1997) o algoritmo de reconhecimento facial denominado *Eigenfaces* foi executado, considerando a variação da direção de luminosidade e expressão facial, numa pose fixa. E, em comparação ao *Eigenfaces*, foi executado o *Fisherfaces* um outro método de projeção que é baseado no Discriminante Linear de Fisher (*Fischer's Linear Discriminant*) técnica clássica no reconhecimento de padrões, que produz uma boa separação de classes em um subespaço dimensional baixo sempre sob severas variações de luminosidade (não somente intensidade, mas a direção e o número de fontes de luz) e expressão facial. Utilizaram 330 imagens de 5 pessoas para os testes com os algoritmos, no qual as amostras apresentavam diferentes ângulos de iluminação e divididos em subconjuntos para a análise dos resultados. O método *Eigenface* teve melhor performance ao se retirar os 3 primeiros componentes principais pois estes componentes retêm maior parte da variação de iluminação.

Mais formalmente, na técnica *Eigenface*, considere um conjunto de N amostras de imagens $\{x_1, x_2, \dots, x_N\}$, tomam-se valores em um espaço de imagem n -dimensional, e assume-se que cada imagem pertence a uma das c classes $\{X_1, X_2, \dots, X_N\}$. Também se deve considerar que uma transformação linear mapeia o espaço n -dimensional de imagem em um m -dimensional espaço de característica, no qual $m < n$. Os novos vetores de características $y_k \in \mathbb{R}^m$ são definidos pela seguinte transformação linear da Equação 29, no qual $W \in \mathbb{R}^{n \times m}$ é uma matriz com colunas ortonormais (BELHUMEUR, 1997).

$$y_k = W^T x_k \quad k = 1, 2, \dots, N \quad (29)$$

Suponha que o total da matriz de dispersão S_T é definido na Equação 30: onde c é o número de classes e $\mu \in \mathbb{R}^n$ é a média de todas as amostras de imagem, então subsequente aplicando a transformação linear W^T , a dispersão do vetor característico transformado $\{y_1, y_2, \dots, y_N\}$ é $W^T S_T W$ (BELHUMEUR, 1997).

$$S_T = \sum_{k=1}^N (x_k - \mu)(x_k - \mu)^T \quad (30)$$

No PCA, a projeção W_{opt} é escolhida para maximizar o determinante do somatório da matriz de dispersão das amostras, que é apresentado na Equação (31) onde $\{w_i \mid i = 1, 2, \dots, m\}$ é o conjunto n -dimensional de autovetores de S_T correspondendo ao m maior autovalor (BELHUMEUR, 1997).

$$\begin{aligned} W_{opt} &= \arg \max_W |W^T S_T W| \\ &= [w_1 \ w_2 \ \dots \ w_m] \end{aligned} \quad (31)$$

A desvantagem desta aplicação é que a dispersão ainda maximizada não é devida somente para dispersão no intervalo de classes que é útil para classificação, é informação supérflua, pois grande parte da variação de uma imagem para outra é devido a mudanças de iluminação. Deste modo, se PCA é mostrado com imagens faciais sob variações de luminosidade, a matriz de projeção W_{opt} conterà as componentes principais (isto é, os *Eigenfaces*) que conservam, no espaço característico projetado, a variação devida de iluminação. Conseqüentemente, os pontos no espaço projetado não irão ser bem agrupados, e pior, as classes podem estar prejudicadas na totalidade (BELHUMEUR, 1997).

As características significantes são conhecidas como *Eigenfaces*, pois elas são os autovetores (componentes principais) do conjunto de faces, não necessariamente correspondem às características como olhos, orelhas ou nariz. A operação de projeção caracteriza uma face individual por um soma ponderada das características *Eigenfaces* e, assim, no reconhecimento de uma face em particular é somente necessária uma comparação destes pesos com essas informações individuais. Algumas vantagens particulares desta técnica é que tem a capacidade de aprender e depois reconhecer novas faces de maneira não-supervisionada, além de ser fácil de implementar usando uma arquitetura de rede neural (TURK & PENTLAND, 1991).

Em linguagem da teoria da informação, o objetivo desta técnica é extrair a informação relevante em uma imagem facial, codificá-la quão fosse possível e comparar uma face codificada com uma base de dados de modelos codificados de forma similar. Uma simples técnica para extrair a informação contida numa imagem de uma face é para qualquer modo capturar a variação em uma coleção de imagens faciais, independentes de quaisquer julgamentos de características e usar esta informação para codificar e comparar imagens de face individualmente. Em termos Matemáticos, significa encontrar o componente principal da distribuição de faces, ou os autovetores da matriz de covariância do conjunto de imagens faciais, tratando uma imagem como um ponto (ou vetor) em espaço dimensional muito alto. Os autovetores são ordenados, cada um computando para uma diferente quantidade de variação dentre as imagens faciais. Estes autovetores podem dar idéia de um conjunto de características que conjuntamente caracterizam a variação em comum das imagens faciais. Cada posição da imagem contribui mais ou menos para cada autovetor, o que então pode mostrar o autovetor como uma classe de espectros faciais que podem ser chamados como *Eigenface* (TURK & PENTLAND, 1991).

Podem ocorrer quatro situações para uma imagem de entrada e seu vetor de padrão: (1) próxima ao espaço facial e perto de uma classe facial, próxima ao espaço facial e não perto de classe facial conhecida, (2) distante de um espaço facial e perto de uma classe facial, e (3) distante de um espaço facial e não próximo a uma classe facial conhecida. No primeiro caso um indivíduo é reconhecido e identificado. No segundo caso, um indivíduo desconhecido é presente. E nos dois últimos casos indica-se que a imagem não é imagem de uma face. Numa significativa distância detectada entre as imagens indica-se um falso reconhecimento. No sistema de Turk & Pentland (1991) o cálculo das *Eigenfaces* é executado em torno de 400ms num Lisp de um Sun4, utilizando-se imagens de dimensões 128x128. Em hardware de propósito especial, a versão corrente de *Eigenfaces* pode ser executada à velocidade de quadros de vídeo, cerca de 33ms.

Sobre a métrica utilizada por Turk (2001) no espaço característico é utilizada comumente a métrica L2 ou Distância Euclidiana pois é a menos dispendiosa sob o ponto de vista computacional. A Correlação é considerada o operador mais eficiente e, sob determinadas condições, maximizar a correlação é equivalente à minimização da Distância

Euclideana, então é comumente utilizada como uma métrica de aproximação de similaridades (TURK, 2001).

A imagem *Eigenface* calculada dos autovetores estende um conjunto de base com que se descreve imagens faciais. Sirovich & Kirby (1990) estimam uma limitada versão desta arquitetura em um conjunto de 115 imagens, de Homens caucasianos, digitalizadas de maneira controlada e encontraram-se aproximadamente 40 *Eigenfaces* que eram suficientes para uma boa descrição do conjunto de imagens faciais. Com RMS (*Root Mean Square*) *pixel-by-pixel* de erros na representação foi tido de 2%. Assim as *Eigenfaces* são adequadas para descrever imagens faciais sob condições muito controladas de luminosidade.

Delac (2005) também considera o algoritmo que usa mais de uma imagem por classe no treinamento, a habilidade de um algoritmo em conservar a medida de reconhecimento quando o número de classes usado no treinamento é reduzido. O trabalho tem foco na definição de aptidões de generalização como parte constituinte do algoritmo de reconhecimento de imagens que não fazem parte do processo de treinamento. Para isso utiliza três métodos de subespaços de projeção de reconhecimento facial: PCA, ICA (*Independent Component Analysis*) e LDA (*Linear Discriminant Analysis*). As métricas utilizadas foram L1 (*Manhattan Distance*), L2 (Distância Euclideana) e C (*Cosine Distance*) e o algoritmo de *Nearest Neighbour* é aplicado no estágio de associação das informações. As imagens foram pré-processadas utilizando Transformações espaciais, Equalização de histograma e ajuste de valores para o intervalo de 0 a 255 níveis de cinza e após foram redimensionadas para 60 x 50 *pixels*. A base de dados utilizada foi FERET, que consiste de 3816 imagens de 1201 classes (diferentes pessoas), sendo decidido três imagens por classe no treinamento, que é o mínimo que o LDA requer para trabalhar corretamente. Assim, foram escolhidas da base, 130 classes de três imagens e outras 130 classes de quatro imagens para a realização dos testes.

No trabalho de Bianchi (2006) em imagens faciais são aplicadas Transformadas *Wavelets* e após técnicas de PCA, baseada no trabalho de Turk & Pentland (1991), com a finalidade de extração de características para a comparação das imagens. Primeiramente padroniza as imagens, redimensionando para 128×128 *pixels*, aplica a Transformada *Wavelet* sobre a base de imagens resultando em sub-imagens com menor resolução espacial, sendo que as imagens processadas com os coeficientes de aproximação são guardados como vetores de

característica das imagens (assinatura da imagem). Uma matriz de covariância é gerada, calculam-se os autovetores a partir dos autovalores, realiza-se a projeção das imagens no novo espaço gerado (espaço de faces). Projetam-se as médias de classes neste novo subespaço e então a Distância Euclidiana entre cada imagem da base, que foi projetada neste novo subespaço PCA, com a média das classes que também foram projetadas neste novo subespaço PCA é comparada com cada classe e no caso a que for menor será então considerada a imagem mais similar àquela imagem consulta.

2 METODOLOGIA

Para viabilizar a pesquisa alguns passos foram seguidos e serão descritos no decorrer deste capítulo. Este trabalho começou com uma consistente pesquisa bibliográfica com a coleta de informações sobre teoria de sinais aplicados ao processamento de imagens retiniais, processos clássicos com a imagem e, na aplicação dos estudos, foi necessário adquirir um banco de imagens retiniais.

Assim, a pesquisa orientada sob o ponto de vista de Processamento de Sinais com aplicações estendidas a imagens com uso do software MAPLESOFT[©], tendo como ponto de partida a teoria *Wavelet* unidimensional com a finalidade de extensão aos estudos de análise em duas dimensões (imagens). A decisão quanto aos pré-processamentos de imagens foi sendo delineada com aplicação de conceitos clássicos no Processamento de Imagens e os passos para a filtragem de imagens foram definidos via resultados obtidos com o software NEATVISION (WHELAN, 2003).

Por análise dos processos realizados com os softwares foi eleito o MATLAB[®] para os experimentos, pois o mesmo demonstrou uma performance de tempo consideravelmente melhor que outros, além de que apresenta comandos de leitura e gravação de dados/resultados que possam ser visualizados por outros softwares tradicionais de imagens ou dados.

2.1 As Imagens

Inicialmente imagens coloridas de retinas foram utilizadas para os testes, com base nos arquivos enviados de professores médicos aos estudantes residentes de oftalmologia, um grupo de discussão² e transferência de arquivos em site. As discussões eram realizadas em torno de doenças retiniais e, por conseguinte, muitas imagens se tornavam impróprias para a intenção de reconhecimento de padrões devido a degradação intensa do padrão vascular

² Grupo que transferia arquivos e realizavam análises e discussões das variadas retinopatias do site YAHOO (www.yahoo.com.br).

presente devido às patologias analisadas. Além disso, os arquivos de transferência eram de formato de processador de textos, sendo necessária uma cópia prévia da tela, seguido de salvamento em formato de imagem por software específico.

Os testes iniciais podem ser visualizados na Figura 27 com os devidos passos elaborados sobre as mesmas. Estes testes consistiam em localizar o Nervo Óptico (NO) sobre uma imagem colorida, representada pela Figura 27(a), tomando-se o plano *Red* da mesma para a localização do NO, que está demonstrado na Figura 27(b), por meio de uma binarização através do limiar de OTSU(1979). Então se define a Região de Interesse (RI) sobre o plano *Green*, representado na Figura 27(c), com dimensão de 64x64 *pixels*. Após normaliza-se a RI de uma média e uma variância (ANDRYSIAK & CHORÁS, 2005), como demonstrado na Figura 27(d). Para o realce das características vasculares aplica-se a Congruência de Fase (*Phase Congruency* - PC), que é demonstrada pela Figura 27(e). Então estas imagens foram processadas por Banco de Filtros Bivariados de Transformada *Wavelet* de Haar, na Figura 27(f), e Daub4, na Figura 27(g), o qual se nota que, em imagens de baixa resolução, a compactação torna-se imprópria em consideração aos detalhes a serem detectados.

A aquisição das imagens definitivas para a realização dos processos foi por vias de um banco de dados de uma empresa especializada em diagnóstico de doenças retiniais, a qual manifestou interesse em não se declarar doadora das informações e também manifestou interesse em preservar sigilo da identificação dos indivíduos analisados. As imagens foram armazenadas em 2 DVD-R (*Digital Video Disc – Recording*) e estão salvas em formato TIF (*Tagged Image File Format*), com aproximadamente 1300 Kb de informação armazenada em cada imagem e em formato JPG (*Joint Photographic Experts Group*) com aproximadamente 130 Kb de informação armazenada em cada imagem deste formato.

Nestes dados, há imagens de variados tipos: coloridas, *red-free* e “blocos-resumo” das análises. A preferência por imagens *red-free* foi pelo fato de imagens de captura em sistemas de automação e detecção de características em aparelhos biométricos (tanto de seres humanos quanto de bovinos) apresentam imagens obtidas por luz infravermelha que são apresentadas em escala de cinza. As imagens *red-free* apresentaram melhor contraste em relação a outras, como foi discutido no Capítulo 1.1, pois as mesmas apresentam o padrão vascular mais nítido

e um forte contraste do nervo óptico em relação a outros elementos da retina. Este contraste facilita a detecção da Região de Interesse (RI), que se faz em torno do Nervo Óptico (NO).

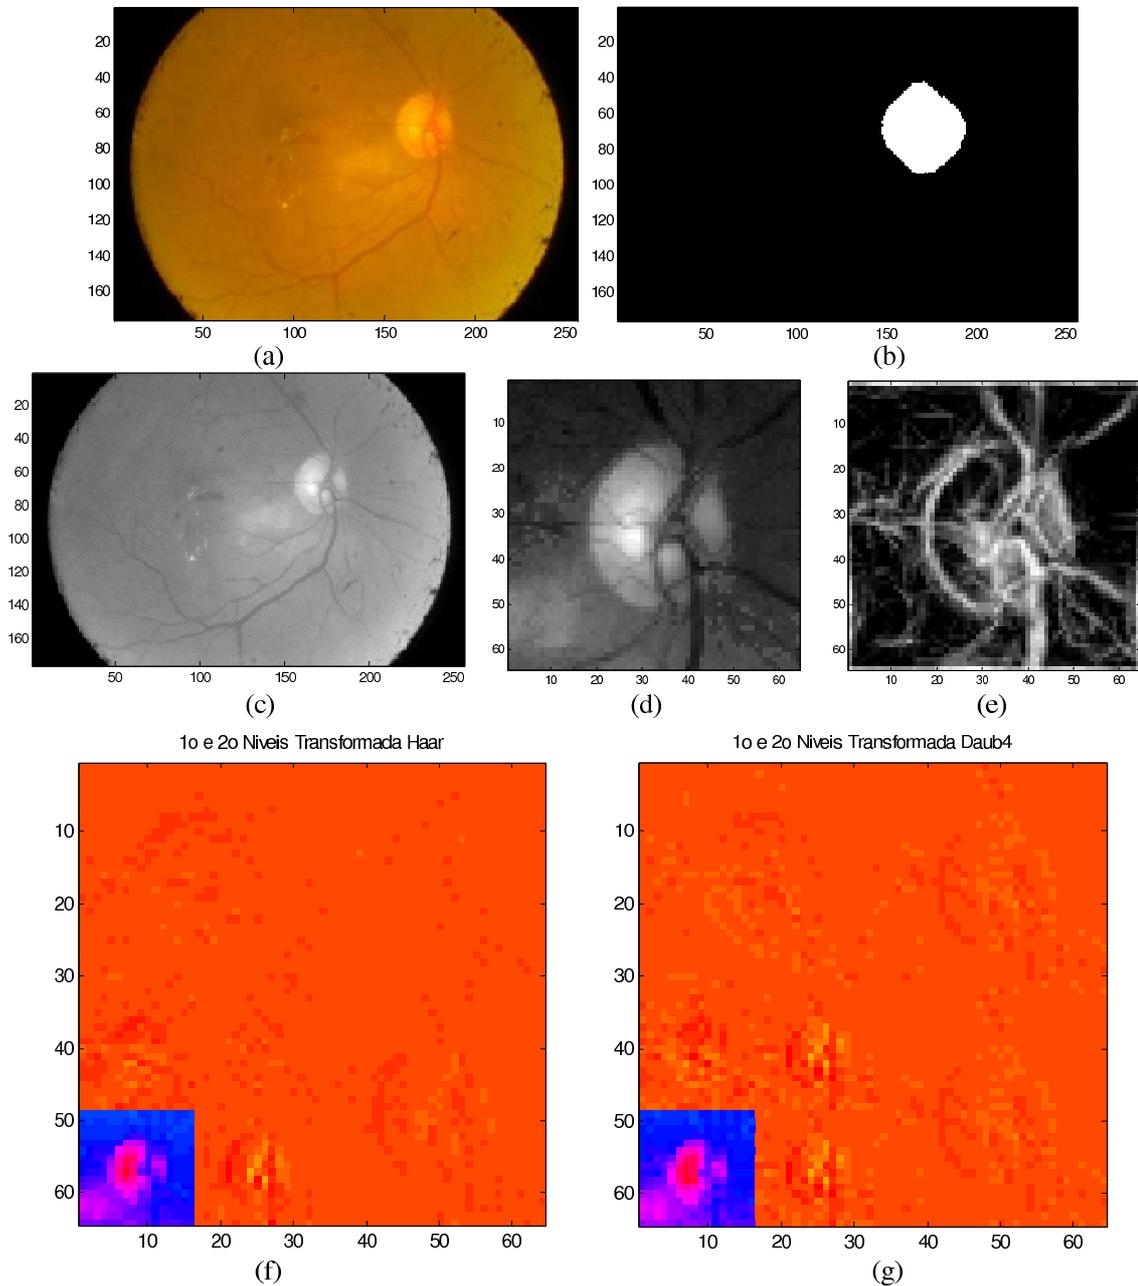


Figura 27. Testes Iniciais Sobre Imagem Originalmente Colorida do Grupo de Discussões.
 (a) Imagem Original Colorida. (b) Localização da RI. (c) Imagem Plano *Green*. (d) RI normalizada.
 (e) Aplicação de PC. (f) Aplicação de 2 níveis de compactação com Banco de Filtros Bivariados de Transformada *Wavelet* de Haar.
 (g) Aplicação de 2 níveis de compactação com Banco de Filtros Bivariados de Transformada *Wavelet* Daub4.
 Fonte: Elaborado pela autora.

Devido a problemas de iluminação e contraste de imagens, doenças retiniais que degeneram drasticamente o padrão vascular e o fato de que nem todas as imagens deste banco

de dados apresentam o Nervo Óptico, realizou-se uma triagem das imagens a serem analisadas pelo algoritmo de detecção de características para identificação de indivíduos. Visualmente, selecionaram-se várias imagens de um mesmo paciente, pois apareciam dentre as imagens salvas os “blocos-resumo” de variadas imagens que se supõe serem da mesma pessoa, como pode ser visualizado na Figura 28.



Figura 28. Seleção de Imagens Retinais de um Mesmo Paciente e os Respetivos “Blocos-Resumo” representados por IM000942.TIF e IM000901.TIF.

Fonte: Elaborado pela autora.

Logo, para o trabalho desta dissertação sobre um sistema de reconhecimento biométrico por retinas com fins de rastreabilidade, foram adotadas imagens de retinas humanas, de característica *red-free* para os testes definitivos, as quais são compostas por um único plano de tons de cinza em 256 níveis (*8 bits*), dimensões 1320x1032 *pixels*, em formato TIF ou JPG, resolução 96 dpi (*dots per inch*), criadas pelo software IMAGEnet97/2.00, provinda de retinógrafo fixo da marca TOPCON.

2.2 O Esquema do Sistema de Rastreabilidade Aliada à Identificação de Indivíduos

A identificação biométrica de indivíduos é uma área de constante e rápido desenvolvimento e é necessária atenção quanto à escolha do método, que ele não incorra em perda de dados da identificação, pois daí ele perde a possibilidade de ser rastreado ou a certificação do mesmo (EUCLIDES, 2002).

Um esquema simplificado da identificação dentro de um sistema de rastreabilidade de animais é representado na Figura 29. Inicialmente, a imagem retinal do animal é capturada por hardware específico, conforme Passo A da Figura 29. Após processos de localização do NO, normalização e aplicação de Congruência de Fase, seguida de Transformada Hough, sobre a RI para centralizar corretamente a imagem sobre o NO é o que representa o Passo B, da Figura 29. Já o Passo C, da Figura 29, representa a aplicação do Banco de Filtros Bivariados de Transformada *Wavelet* de Haar em dois níveis de compactação sobre a RI seguida de uma filtragem por Congruência de Fase. Os dados são arquivados em forma binarizada, inicialmente no Conjunto de Teste, conforme Passo D da Figura 29, para o confronto com o Conjunto de Treinamento e Classificação, descrito no Passo E da Figura 29, aliado aos outros métodos de identificação na rastreabilidade que podem estar associados ao sistema: tatuagens, brincos de identificação, dentre outros. Caso o indivíduo for reconhecido pelo sistema, Passo F1 da Figura 29, os dados binarizados são arquivados ao conjunto de treinamento. Caso ocorrer o não reconhecimento pelo sistema, Passo F2 da Figura 29, é realizada uma nova coleta do material. Caso o animal ainda não conste no cadastro será necessário criar um novo registro no sistema e, por conseguinte, a devida coleta de imagens aliada às informações dos outros métodos utilizados no sistema de rastreabilidade.

Num primeiro momento se buscou um banco de imagens de imagens de retinas bovinas/bubalinas, já que a empresa norte-americana *Optibrand*® divulga que realizou pesquisas no Brasil. Não foram encontradas informações sobre o banco de imagens e, frente à inacessibilidade dessas informações, retinas humanas capturadas por oftalmologistas foram aproveitadas nos testes.

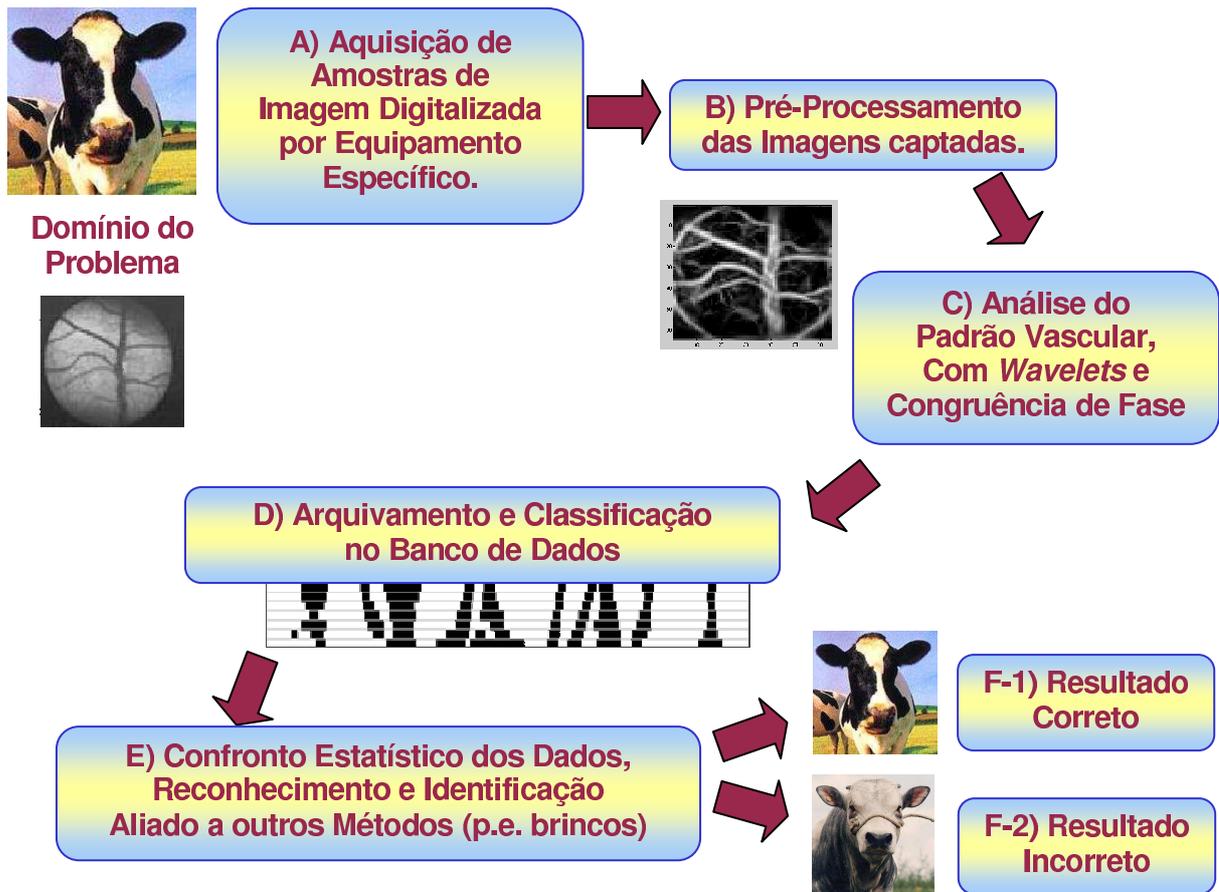


Figura 29. Esquema da Implantação do Sistema de Identificação Biométrica Dentro do Sistema de Rastreabilidade Bovina.

Fonte: Elaborado pela autora.

2.3 O Processo de Identificação Biométrica

Durante as pesquisas em artigos sobre processos específicos com imagens, a aplicação de Congruência de Fase foi uma alternativa de realce das imagens muito boa e a Transformada Hough também se mostrou bastante útil na detecção do centro da imagem (ou confirmação do mesmo), mesmo que seus processos demandam um custo computacional muito alto para o processo.

A aplicação dos procedimentos clássicos em imagens (binarização, filtragens) aliados com estes específicos foram uma alternativa para uma delimitação da região a ser analisada para a classificação nas imagens retiniais.

A primeira metodologia completa para visão computacional foi proposta por Marr (1982) que definiu como “um processo que produz uma descrição, a partir de imagens do mundo externo, que é útil ao visualizador”. A palavra “processo” refere-se ao mapeamento das diferentes representações de uma cena, obtidas a partir das matrizes dos valores de intensidade de brilho aos diferentes padrões que descrevem a cena.

Assim ocorre um encadeamento de diferentes tarefas no sistema, divididas em três níveis de acordo com o seu propósito: baixo, médio e alto. Ocorre uma redução progressiva da quantidade de informações manipuladas, à medida que se passa por níveis crescentes de abstração. No processamento de baixo nível, os dados de entrada são a representação, na forma de valores numéricos, associados a cada *pixel* da imagem original. No processamento de nível médio este conjunto de valores produz como resultado uma lista de características. O processamento de alto nível produz, a partir destas características, uma interpretação do conteúdo da imagem (MARR, 1982).

Um esquema do processo realizado neste trabalho de identificação de indivíduos pela retina, sob o ponto de vista da Visão Computacional, é descrito na Figura 30. No processamento de baixo nível tem-se a manipulação dos níveis de cinza da imagem *red-free*, apresentada na Figura 30(a) e adquirida do banco de dados (IM000106.TIF), seguindo-se há a detecção da RI, delimitada em dimensão de 512×512 *pixels*, utilizando-se binarização e operações morfológicas de erosão e dilatação binárias em torno do NO, culminando com uma centralização preliminar da RI e normalização dos níveis de cinza. A filtragem por Congruência de Fase, descrita na Figura 30(b), e Transformada Hough são aplicadas na centralização (ou confirmação das coordenadas do centro) sendo que a imagem resultante desta fase está representada na Figura 30(c). Maiores Detalhes desta fase estão descritos na Figura 31.

No processamento de nível médio são realizadas as compactações por Banco de Filtros Bivariados de Transformada *Wavelet* de Haar, reduzindo as dimensões em dois níveis de compactação apresentada na Figura 30(d). Através dos níveis de compactação percebe-se que a imagem binarizada do 1º nível de compactação, Figura 30(e), apresenta maiores ruídos que a imagem binarizada da 2º compactação na Figura 30(f). Logo a imagem mais ideal foi a binarizada proveniente do 2º nível de compactação do filtro bivariado *Wavelet* de Haar que, a

princípio visualmente é a que é mais adequada para os procedimentos de reconhecimento de padrões.

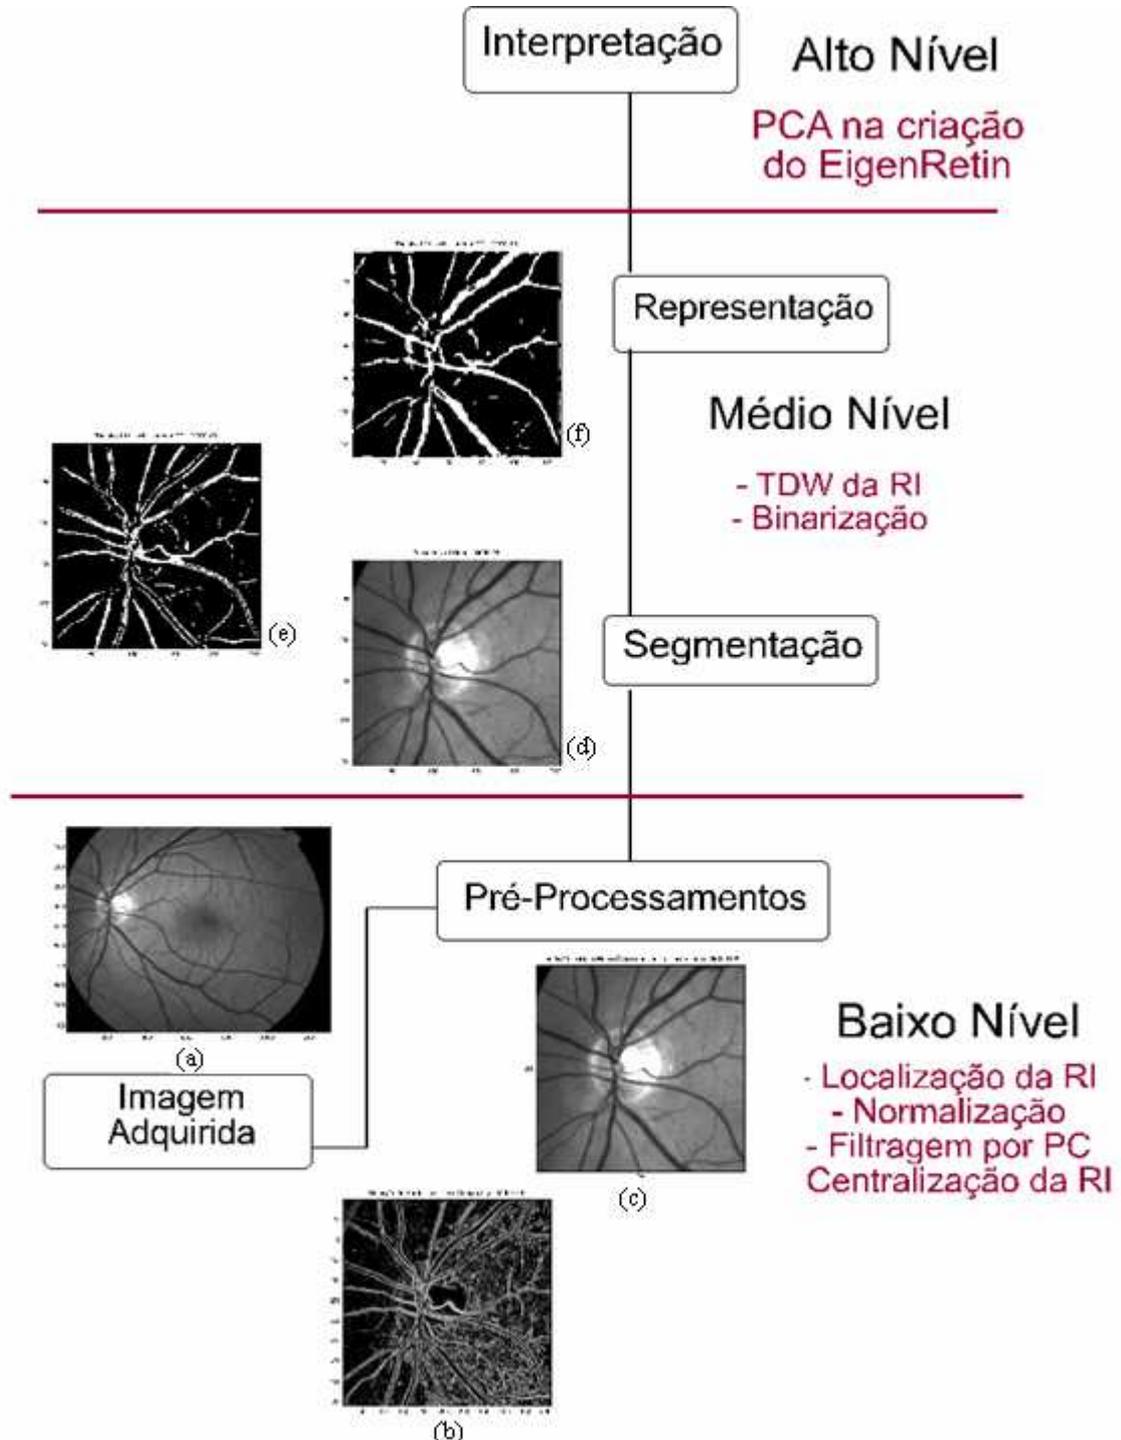


Figura 30. Estrutura do Sistema de Identificação pela Retina, Sob o Ponto de Vista da Visão Computacional.
Fonte: Elaborado pela autora.

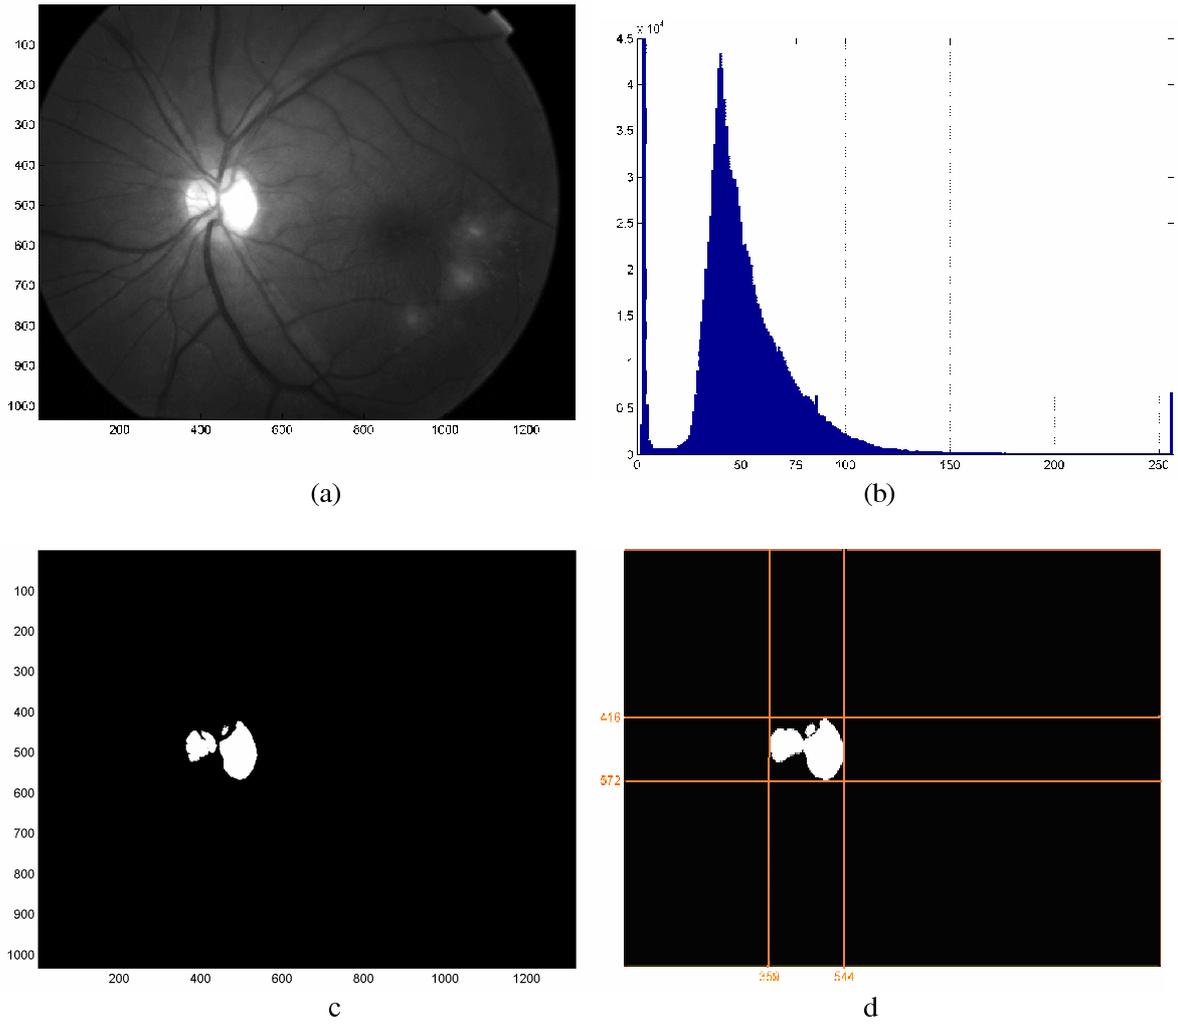
Os dados dos arquivos processados, tanto das RI originais quanto dos níveis de compactação e imagens binarizadas, incluindo tempos de processamento, foram salvos para

os testes posteriores de classificação. O processo de alto nível envolve o reconhecimento das imagens binarizadas na Figura 30(f), que reduz a dimensionalidade das imagens por Análise de Componentes Principais (PCA) no qual a imagem de entrada, presente no Conjunto de Teste é comparada com o Conjunto de Treinamento que realiza a identificação.

Devido a diferenças de luminosidade no momento da captura das imagens, ou seja, num ambiente sem luz controlada, há a necessidade alterações/ajustes na fase de teste no valor do Limiar de Otsu citado por GONZALEZ (2004) que lança uso da análise do histograma de níveis de cinza da imagem, representado na Figura 31(b), no qual se nota que há maior quantidade de *pixels* escuros (menores níveis de cinza) da Figura 31(a). Na detecção desta característica foi necessário multiplicar o valor do limiar ($th_{Otsu} = 76$) por um fator, por testes de variados valores de foi fixado o fator de 2,8; sendo que se o limiar ultrapassasse o fixado em 245, o mesmo receberia este valor. A imagem binarizada por este procedimento se apresenta na Figura 31(c). Sobre esta imagem binarizada aplica-se a remoção de *pixels* brancos isolados (GONZALEZ et al, 2004), seguindo o processo com operações binárias iterativas sendo compostas de duas erosões seguidas de sete dilatações, todas com Elemento Estruturante em cruz 3×3 . Assim a região de *pixels* brancos é ampliada e uniformizada, conforme Figura 31(d) e delimita-se uma região retangular inicial.

Então, em torno desta região, que abrange o NO se define o centro preliminar e delimita-se um quadrado de 512×512 *pixels* sobre a região em escala de cinza para os procedimentos posteriores definindo-se assim a RI. Em algumas imagens houve significativas diferenças na detecção da RI quando se utilizou a Transformada Hough na definição das coordenadas do centro, já em outras imagens apenas se confirmou essas coordenadas de centro da RI.

Melhores resultados, tanto na detecção de coordenadas centrais quanto à detecção de características numa binarização posterior foram obtidas através da aplicação do algoritmo de Congruência de Fase. Já a normalização em torno da Média e Variância, proposta no Capítulo 1.6, também interfere nos resultados tanto na aplicação da Congruência de Fases quanto nas compactações via Banco de Filtros Bivariados de Transformada *Wavelet* de Haar.



c

d

Figura 31. Imagem, Histograma e Limiarização.

(a) Imagem IM002294.TIF do banco de imagens.

(b) Histograma indicando toda a distribuição dos níveis de cinza e $th_{OSU} = 76$.

(c) Imagem limiarizada com $th_{OSU} \times 2,8$.

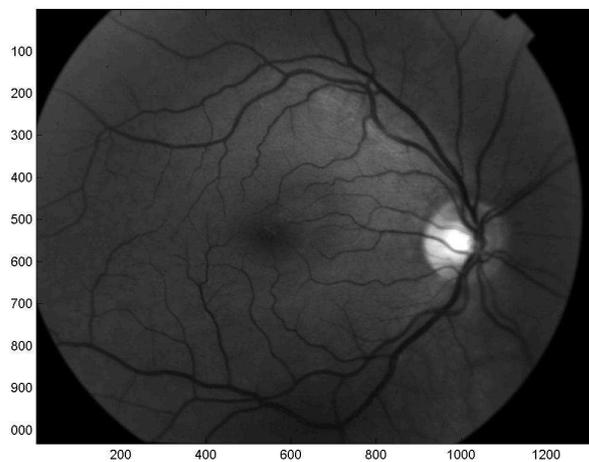
(d) Delimitação das coordenadas iniciais em torno do Nervo Óptico.

Fonte: Elaborado pela autora.

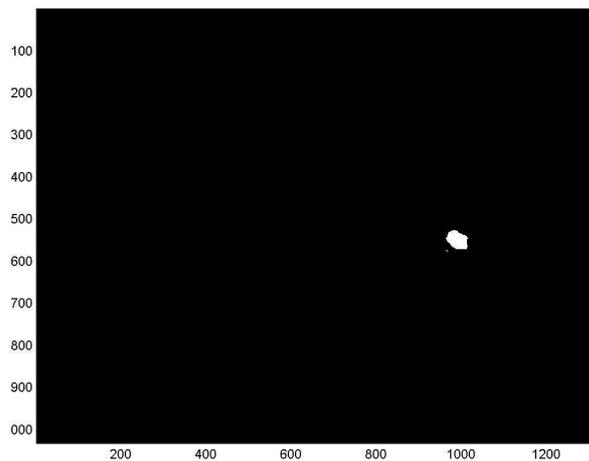
3 RESULTADOS

3.1 Processamento Padrão

Para o confronto dos resultados foi necessário padronizar o processamento das imagens em baixo e médio nível, representado no Fluxograma da Figura 32, sendo que o nível alto corresponderá à proposta *Eigenretina*, descrita no item 3.3 desta dissertação.



(a)

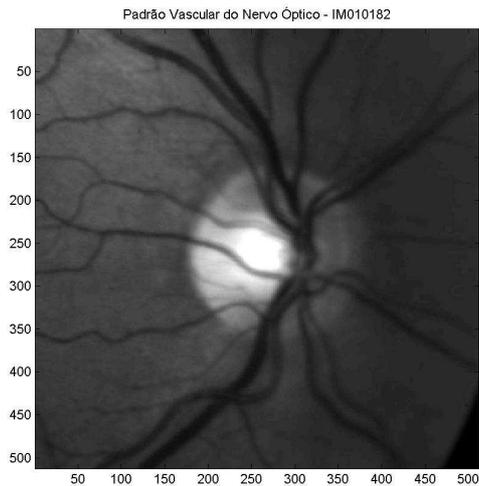


(b)

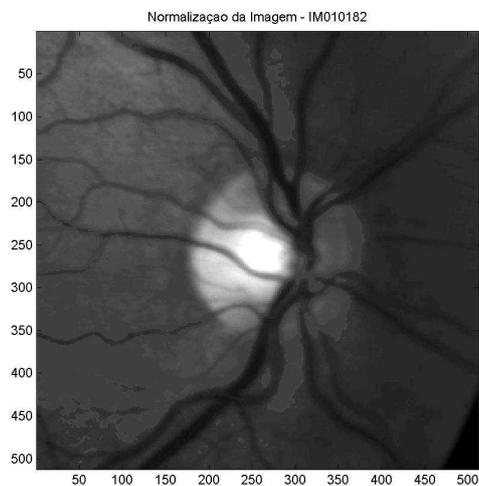
1. Imagens *red-free* (a) selecionadas para a formação do Conjunto de Treinamento, três amostras de cada indivíduo, mais uma imagem para o Conjunto de Teste, sendo que cada um dos exemplares passará pelo processamento descrito por este fluxograma.



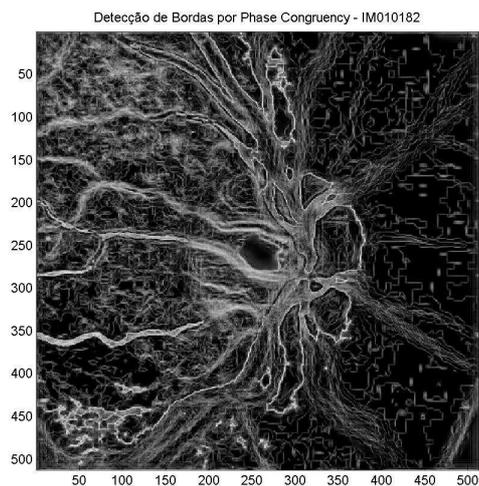
2. Delimitação da RI (Região de Interesse) através de binarização da imagem via limiar de Otsu (GONZALEZ et al, 2004) multiplicado por 2.8; caso o valor ultrapassa 245 o limiar é definido com este valor. Operações de morfologia binária, tais como remoção de *pixels* isolados, duas erosões seguidas de sete dilatações com EE em cruz 3×3 são aplicados iterativamente, obtendo-se (b). Define-se o centro das coordenadas de uma região retangular inicial sobre os *pixels* brancos apresentados.



(c)



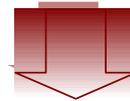
(d)



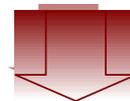
(e)



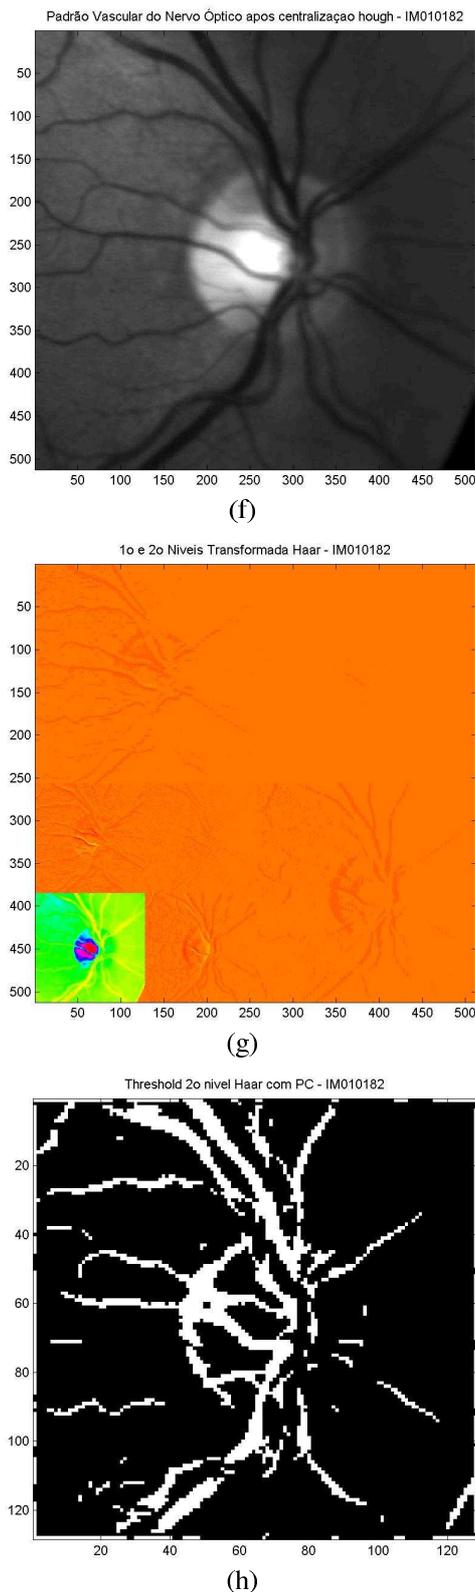
3. Com base nas coordenadas do centro, se define uma RI preliminar (c) sobre a imagem *red-free* com dimensões de 512×512 pixels.



4. Normaliza-se a região (d) a uma média e variância conforme descrito no Capítulo 1.6.



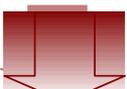
5. Aplica-se Congruência de Fase (e) sobre a imagem normalizada com a finalidade de detectar maior quantidade de características possíveis da imagem.




6. Re-centraliza (ou confirmam-se as coordenadas do centro da imagem) via Transformada Hough. O resultado é demonstrado em (f).



7. Realizam-se dois níveis de compactação (g) com Banco de Filtros Bivariados de Transformada *Wavelet* de Haar, reduzindo a imagem a 1/16 de área em relação a RI original.



8. Binariza-se (h) a região compactada via limiar de Otsu. Arquia-se a imagem em formato JPG para posterior uso no Conjunto de Treinamento ou no Conjunto de Teste.

Figura 32. Fluxograma do Processamento Padrão das Imagens Retinais para Classificação.

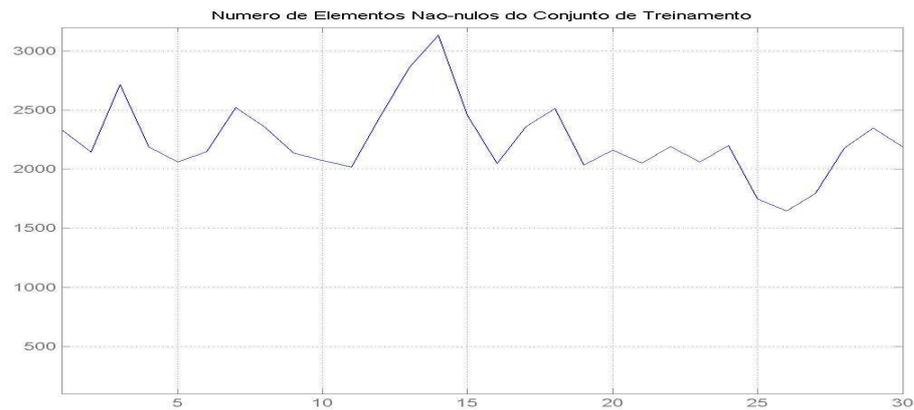
Fonte: Elaborado pela autora.

Foram processadas 40 imagens para a proposta de classificação dos dados via *Eigenretina*, que trata-se de uma Análise Espectral de Retinas e o termo criado nesta dissertação é derivado das pesquisas realizadas anteriormente em biometria no mundo (*Eigenfaces*, *Fisherfaces*), sendo que para cada indivíduo foram necessários três exemplares para o Conjunto de Treinamento e uma amostra para o Conjunto de Teste. O tempo computacional de processamento médio de cada imagem nesta fase de tratamento e extração das feições foi de 374,725s no MATLAB®, com um mínimo de 90,672s e um máximo de 826,531s, em um computador AMD Duron processor 1.29GHz e 512 Mb de memória RAM.

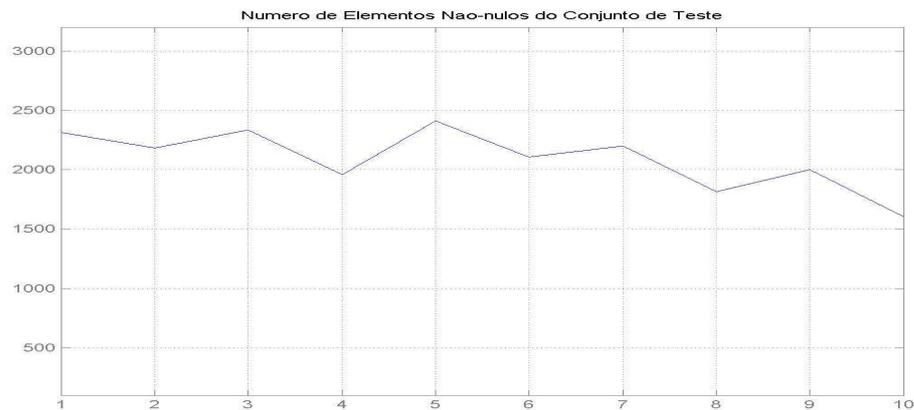
3.2 Análise de Matrizes Esparsas

Paralelamente ao *Eigenretina* foi considerada a análise de matrizes esparsas, já que a imagem binarizada é uma matriz de 262144 elementos e com grande quantidade de elementos nulos. A análise está demonstrada na Figura 33 o qual trata as 10 imagens de teste e seus valores de elementos não nulos, na Figura 33(b), em comparação com as 30 imagens do Conjunto de Treinamento que apresentam valores que são semelhantes entre si, Figura 33(a).

Realizando-se uma comparação entre as matrizes de imagens binarizadas, verificam-se os elementos que não-coincidem para então serem comparadas. O algoritmo de comparação consiste em tomar as 40 matrizes, de duas em duas e verificar a existência de *pixels* não-coincidentes. Uma baixa taxa de *pixels* não coincidentes indica a classificação como imagem de um mesmo indivíduo, ao limitar-se ao valor de 2300 elementos não-coincidentes, que significa 10% de elementos desiguais. Assim, foram realizadas as comparações com as quatro amostras de cada indivíduo, apresentadas na Tabela 2, e deduziu-se que se trata de uma boa classificação, porém não classifica todos os indivíduos ao não reconhecer os indivíduos 3, 7 e 8 as quais apresentaram na comparação mais de 2300 elementos não coincidentes nas matrizes de análise, como pode ser visualizado na Tabela 1 os valores de *pixels* não-coincidentes dos indivíduos classificados corretamente.



(a)



(b)

Figura 33. Análise de Matrizes Esparsas do Conjunto de Treinamento em (a) e do Conjunto de Teste em (b).
Fonte: Elaborado pela autora.

Matriz 1 de Índice:	Matriz 2 de Índice:	Comparativo do N° de Elementos Não-Coincidentes entre as matrizes	Classificou corretamente como Indivíduo
1	2	843	1
1	31	1690	1
2	31	1459	1
4	32	289	2
10	12	1962	4
13	14	1263	5
13	15	2181	5
13	35	2201	5
14	15	2294	5
15	35	1026	5
18	36	1981	6
26	27	1740	9
29	40	1066	10

Tabela 1. Valores de *Pixels* Não-Coincidentes Entre as Imagens.

Fonte: Elaborado pela autora.

Pode-se fazer uma relação do número da imagem, Tabela 2, correlacionando com o número de elementos não nulos representando os *pixels* significativos da classificação. Com base nestes dados é que foram construídos os gráficos da Figura 33.

Índice no Comparativo de <i>pixels</i> não-coincidentes	Número de Guia no Conjunto de Treinamento/Teste	Índice da Imagem no Banco de Dados	Número de elementos não nulos da Imagem Binarizada
1	1 (Treinamento)	IM0000365.TIF	2334
2	2 (Treinamento)	IM0000366.TIF	2146
3	3 (Treinamento)	IM0000369.TIF	2315
4	4 (Treinamento)	IM0000378.TIF	2186
5	5 (Treinamento)	IM0000380.TIF	2060
6	6 (Treinamento)	IM0000382.TIF	2147
7	7 (Treinamento)	IM0000385.TIF	2523
8	8 (Treinamento)	IM0000386.TIF	2356
9	9 (Treinamento)	IM0000388.TIF	2135
10	10 (Treinamento)	IM0000866.TIF	2072
11	11 (Treinamento)	IM0000867.TIF	2017
12	12 (Treinamento)	IM0000869.TIF	2448
13	13 (Treinamento)	IM0000954.TIF	2860
14	14 (Treinamento)	IM0000955.TIF	3135
15	15 (Treinamento)	IM0000957.TIF	2457
16	16 (Treinamento)	IM0001598.TIF	2047
17	17 (Treinamento)	IM0001599.TIF	2361
18	18 (Treinamento)	IM0001600.TIF	2512
19	19 (Treinamento)	IM0002292.TIF	2036
20	20 (Treinamento)	IM0002294.TIF	2162
21	21 (Treinamento)	IM0002295.TIF	2051
22	22 (Treinamento)	IM0002398.TIF	2190
23	23 (Treinamento)	IM0002399.TIF	2061
24	24 (Treinamento)	IM0002400.TIF	2201
25	25 (Treinamento)	IM0002583.TIF	1746
26	26 (Treinamento)	IM0002584.TIF	1647
27	27 (Treinamento)	IM0002586.TIF	1793
28	28 (Treinamento)	IM0002599.TIF	2178
29	29 (Treinamento)	IM0002600.TIF	2347
30	30 (Treinamento)	IM0002598.TIF	2189
31	Indivíduo: 1 (Teste)	IM0000367.TIF	2315
32	Indivíduo: 2 (Teste)	IM0000379.TIF	2183
33	Indivíduo: 3 (Teste)	IM0000387.TIF	2335
34	Indivíduo: 4 (Teste)	IM0000868.TIF	1957
35	Indivíduo: 5 (Teste)	IM0000956.TIF	2413
36	Indivíduo: 6 (Teste)	IM0001597.TIF	2108
37	Indivíduo: 7 (Teste)	IM0002296.TIF	2199
38	Indivíduo: 8 (Teste)	IM0002397.TIF	1813
39	Indivíduo: 9 (Teste)	IM0002585.TIF	2002
40	Indivíduo: 10 (Teste)	IM0002601.TIF	1602

Tabela 2. Correspondência da Legenda Utilizada para Matrizes Esparsas e os Conjuntos de Teste (10 indivíduos) e Treinamento (triplicada de cada indivíduo).

Fonte: Elaborado pela autora.

3.3 O Confronto dos Dados via Proposta *Eigenretina*

Artigos que tratam de métodos variados de identificação biométrica, tais como reconhecimento de íris e faces, foram pesquisados com a finalidade de adquirir e aprofundar os conhecimentos envolvidos nesta pesquisa. O desenvolvimento e estudo do algoritmo *Eigenfaces* por Turk & Pentland (1991) fora considerado um dos mais importantes para a biometria do século 20, sendo o mais citado em trabalhos que envolvem classificação dos dados para o reconhecimento de indivíduos. Adaptá-lo para o reconhecimento de imagens retiniais foi uma boa opção, pois o processo é consideravelmente rápido além de ser clássico, pois é baseado na Análise de Componentes Principais (PCA).

O método de *Eigenfaces* proposto por Turk & Pentland (1991) que é baseado na “Transformada de Karhunen Loève (KLT)”, trata-se de classificação obtida por Análise de Subespaços Lineares mais precisamente a Análise de Componentes Principais (PCA), e é motivada pelo trabalho anterior de Kirby & Sirovich (1990) devido a sua eficiência na representação de imagens.

Segundo Turk & Pentland (1991), as imagens de faces não se encontram distribuídas de forma aleatória em um espaço de alta dimensionalidade, portanto elas podem ser descritas de alguma forma em um espaço de dimensão menor. De acordo com esta idéia, faz-se o uso da “Transformada de Karhunen Loève” com o objetivo de achar os vetores que melhor descrevem a distribuição de imagens dentro do espaço de imagens inteiro.

Tais vetores são denominados *Eigenfaces* devido à semelhança que possuem com as imagens de faces. Nesta dissertação o termo muito utilizado em biometria *Eigenface* foi adaptado para a denominação *Eigenretina* já que as imagens a serem processadas se referem aos padrões vasculares da retina. Para uma exemplificação dos conjuntos de experimentos, com três amostras no conjunto de treinamento e uma amostra no conjunto de teste de um total de dez indivíduos, é ilustrada uma parte na Figura 34. Neste Cenário, o tempo de processamento do *Eigenretina* referente à Figura de Teste ilustrada é em torno de 1,8s.

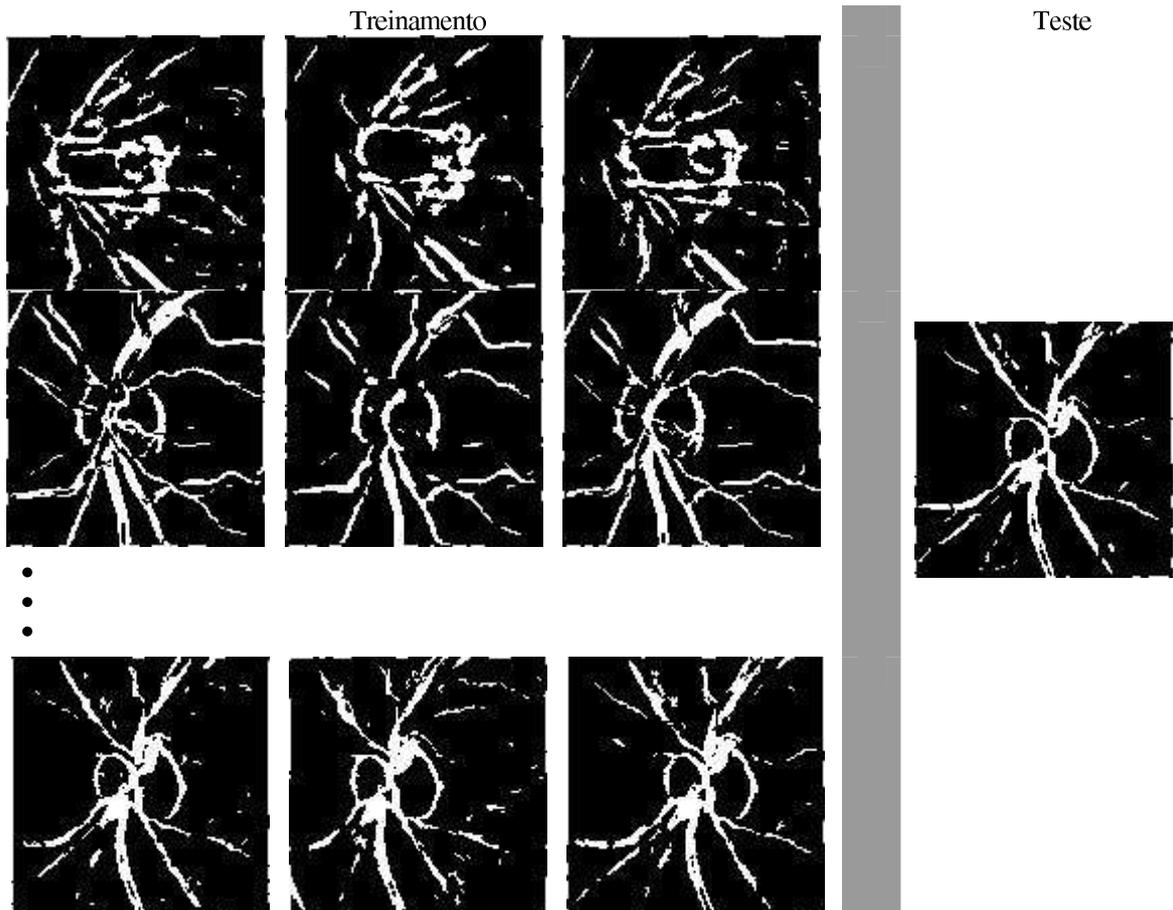


Figura 34. Cenário da Identificação Retinal I.
Fonte: Elaborado pela autora.

Primeiramente imagens em amostras triplicadas, provenientes da binarização pelos dos processos anteriormente descritos, formam um conjunto de N vetores de treinamento da matriz $X = \{x^1, \dots, x^N\}$, cuja disposição pode ser visualizada na Figura 35. Neste caso foram tomadas três imagens, de dimensão 128×128 *pixels*, de dez indivíduos dessemelhantes e estas imagens foram vetorizadas e dispostas na matriz do Conjunto de Treinamento.

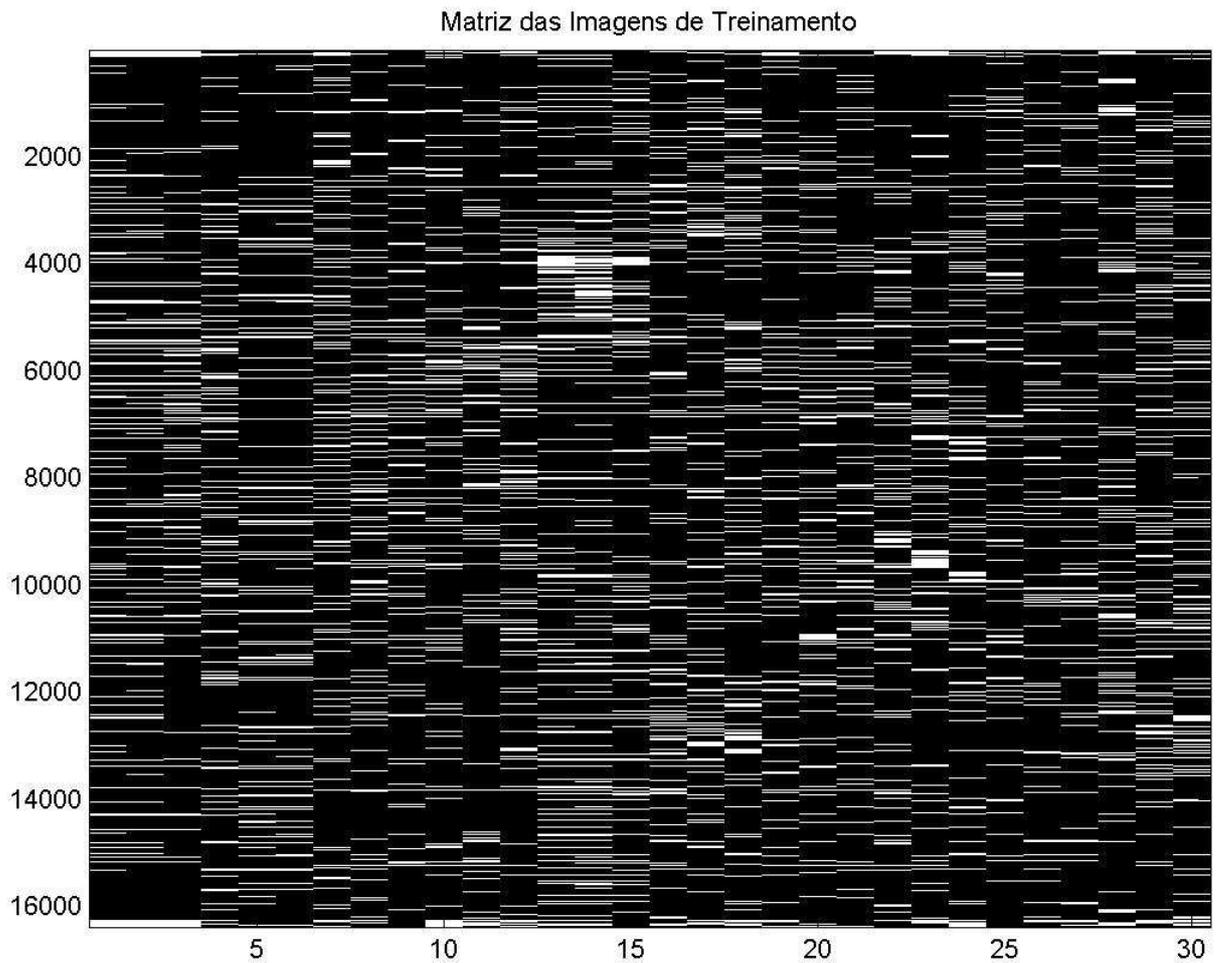


Figura 35. Matriz do Conjunto de Treinamento de Forma Vetorizada.
Fonte: Elaborado pela autora.

O *Eigenretina* utiliza o PCA para a redução dimensional a fim de encontrar vetores que dão melhor importância para a distribuição das imagens retiniais num conjunto espacial de imagens. Seja a média μ , definida pela Equação 32, e a matriz de covariância, definida pela Equação 33, a serem calculadas. Com a técnica de *Eigenfaces*, a redução dimensional é obtida ao calcular os autovalores da matriz de covariância por $L = A^T \cdot A$, em vez de $A \cdot A^T$, pois é claro que as dimensões $A \cdot A^T$ são muito maiores que $L = A^T \cdot A$. Assim, o *Eigenretina* também faz uso desta redução dimensional que diminui consideravelmente o custo computacional, sem contar que os elementos diagonais são autovalores tanto da matriz de covariância quanto de L .

$$\mu = \frac{1}{N} \sum_{i=1}^N x^i \quad (32)$$

$$\Sigma = \frac{1}{N} \sum_{i=1}^N (x^i - \mu)(x^i - \mu)^T \text{ onde } A = x^i - \mu \quad (33)$$

Estes vetores reduzidos definem o subespaço de imagens retiniais e o subespaço que será aqui denominado *RetinaSpace*, conforme pode ser ilustrado na Figura 36 (a). Classificam-se e eliminam-se os autovalores da matriz L que estão abaixo de um limiar específico, neste caso menores que 1, de modo que eles sejam autovetores não-nulos, ilustrado na Figura 36 (b).

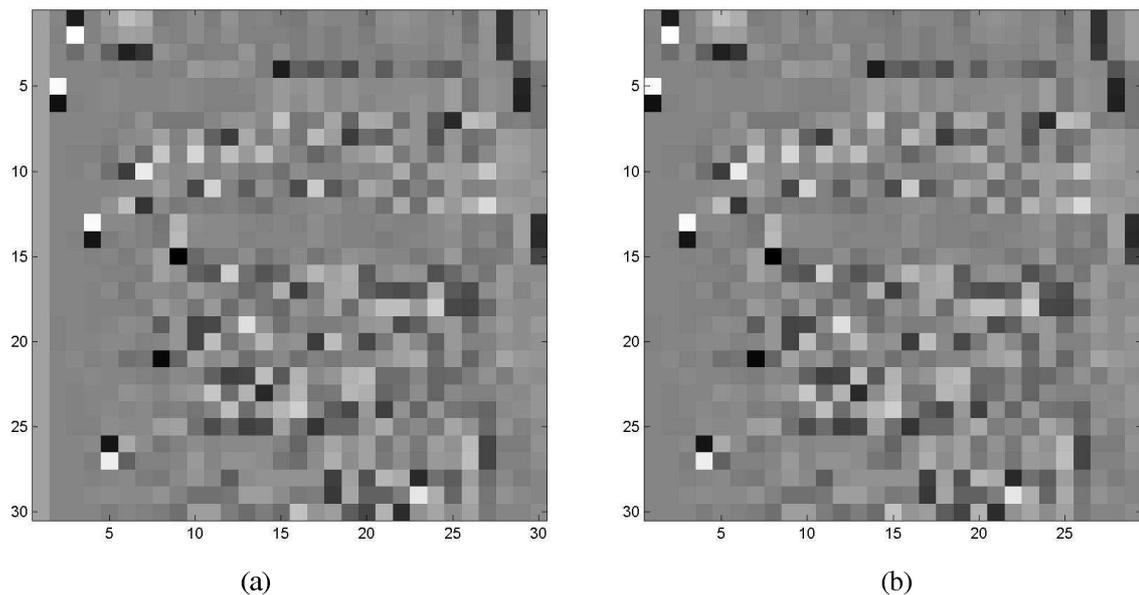
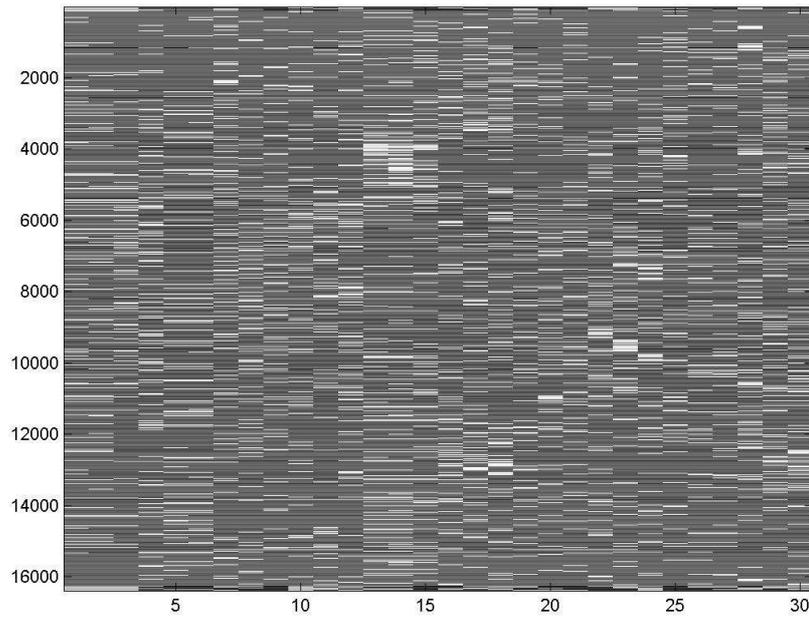


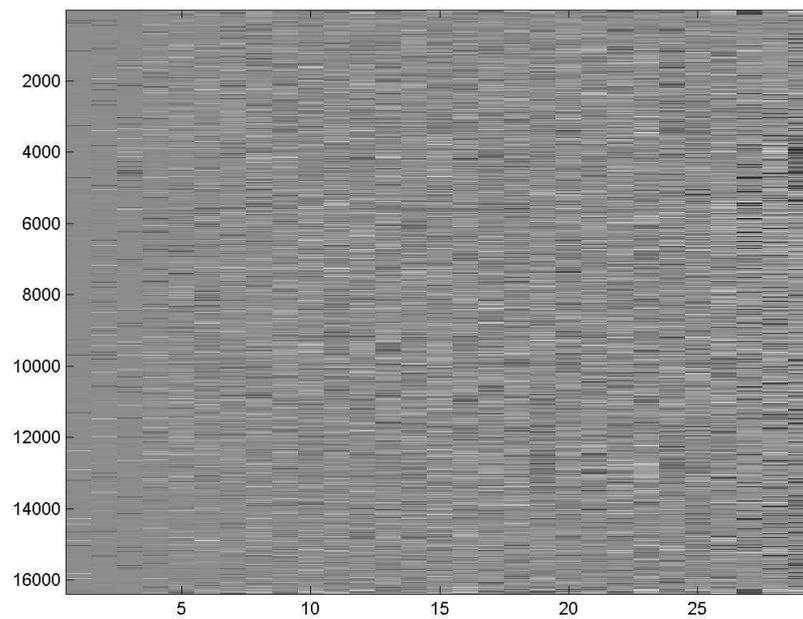
Figura 36. Representação do *RetinaSpace* dos 30 Elementos de Treinamento que são os Autovetores reduzidos das imagens originais em (a) e limiarizados em (b).

Fonte: Elaborado pela autora.

O cálculo de autovetores da matriz de Covariância são obtidos ao multiplicar A , que são os vetores de imagem centrados apresentados na Figura 37 (a), pelos L autovetores válidos que passaram pelo limiar anterior, Figura 36 (b), encontrando-se assim o *Eigenretina*, representado na Figura 37 (b).



(a)



(b)

Figura 37. Vetores de Imagens Centrados A em (a) e a Base de Vetores *Eigenretina* em (b).
 Fonte: Elaborado pela autora.

A fim de encontrar um conjunto de pesos que descrevem a contribuição de cada vetor no *RetinaSpace*, que é demonstrado na Figura 38, todas as imagens centradas A são projetadas no *RetinaSpace* pela multiplicação com a base *Eigenretina*. O vetor projetado de cada imagem terá seu correspondente vetor característico.

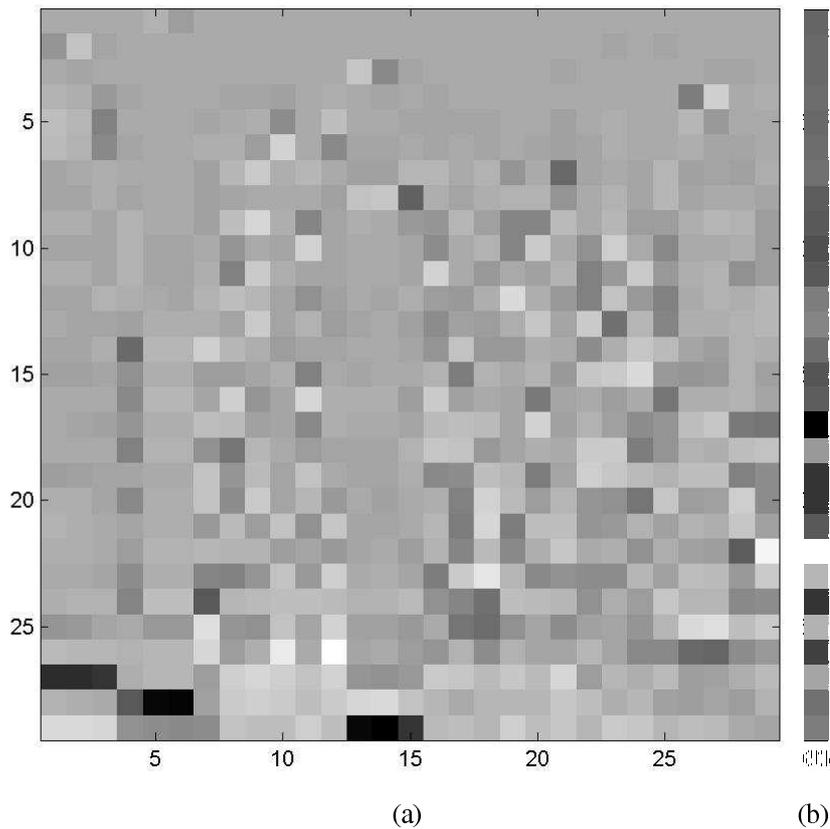


Figura 38. PCA do Conjunto de Treinamento em (a) e da Imagem de Teste n°10 em (b).
Fonte: Elaborado pela autora.

Para identificar a imagem de teste, é necessária a sua projeção no *RetinaSpace* para se obter o correspondente conjunto de pesos, ou seja, obter o Vetor Característico da Imagem de teste via execução do PCA. Por comparação de pesos da Imagem de Teste, na Figura 38 (b), com o conjunto de pesos das imagens retiniais do conjunto de treinamento, ilustrada na Figura 38 (a), a imagem de teste pode ser identificada.

Para a classificação é necessária uma métrica, e a mais comumente utilizada é a Distância Euclideana, a qual calcula as distâncias entre a Imagem de Teste Projetada e cada uma das Projeções presentes no Conjunto de Treinamento. Menores distâncias denotam a correspondência da Imagem de Teste e a Base de Treinamento.

O conjunto de 29 imagens baseadas na *Eigenretina*, que correspondem ao conjunto de treinamento, pode ser visualizado na Figura 39 e se parecem muito com as imagens *Eigenfaces* descritas em artigos de biometria, só que as imagens são de retinas.

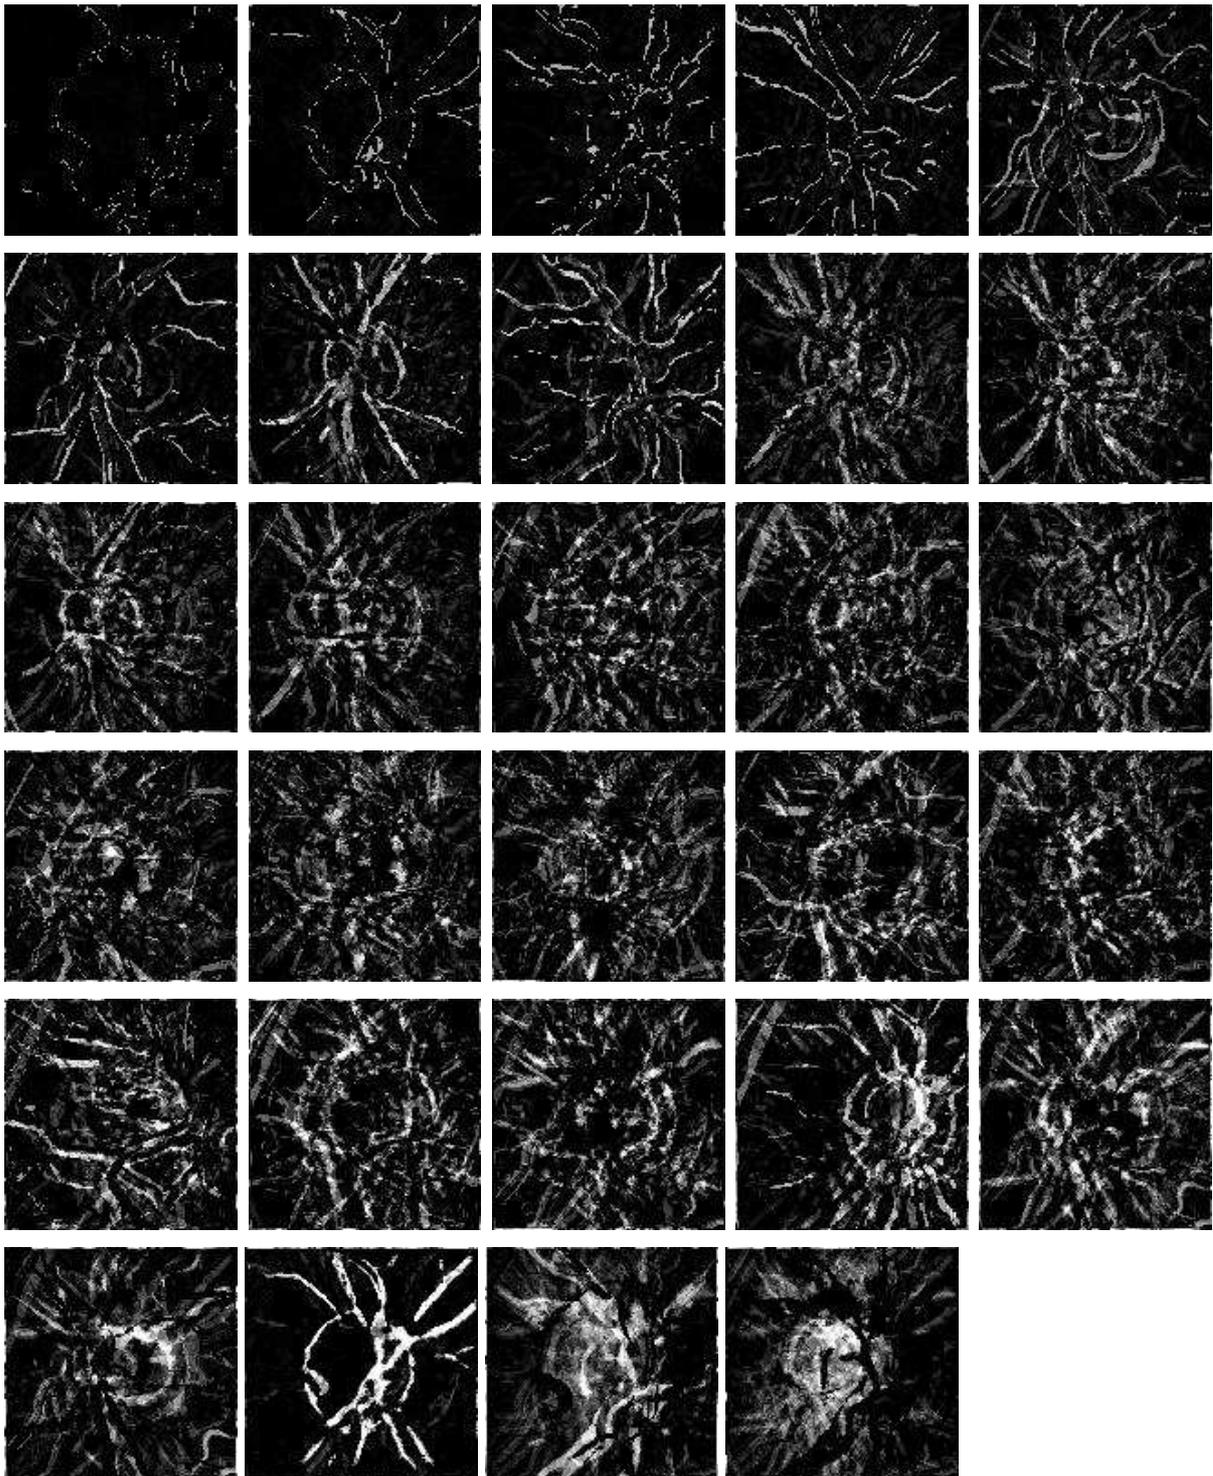


Figura 39. Reconstrução Bidimensional do Conjunto de 29 Imagens da *Eigenretina* baseadas na Figura 37 (b).

Fonte: Elaborado pela autora.

Todas as imagens foram perfeitamente reconhecidas, após permutar imagens do Conjunto de Treinamento com o Conjunto de Teste, denotando que algumas representam melhor a amostra. Maiores estudos são devidos para ajustes em grandes conjuntos de

indivíduos, sendo que neste momento somente se permitiu este em 4 amostras de cada indivíduo.

No momento esta foi a melhor proposta para a classificação, mas testes foram realizados com imagens retiniais conforme cenário demonstrado na Figura 40, em escala de cinza, provindas do 2º nível de compactação do Banco de Filtros Bivariados de Transformada *Wavelet* de Haar, apresentado na Figura 40. Conforme proposta de Bianchi (2006) o qual utilizou imagens faciais após aplicação de compactação *Wavelet* e classificação via PCA, em imagens não binarizadas, foram realizados testes, porém a classificação dos indivíduos corretamente foi de 90%. Uma ilustração do *Eigenretina* e a imagem de Teste n° 10 está apresentada na Figura 41, em pseudocores que representam os valores dos autovetores de classificação.

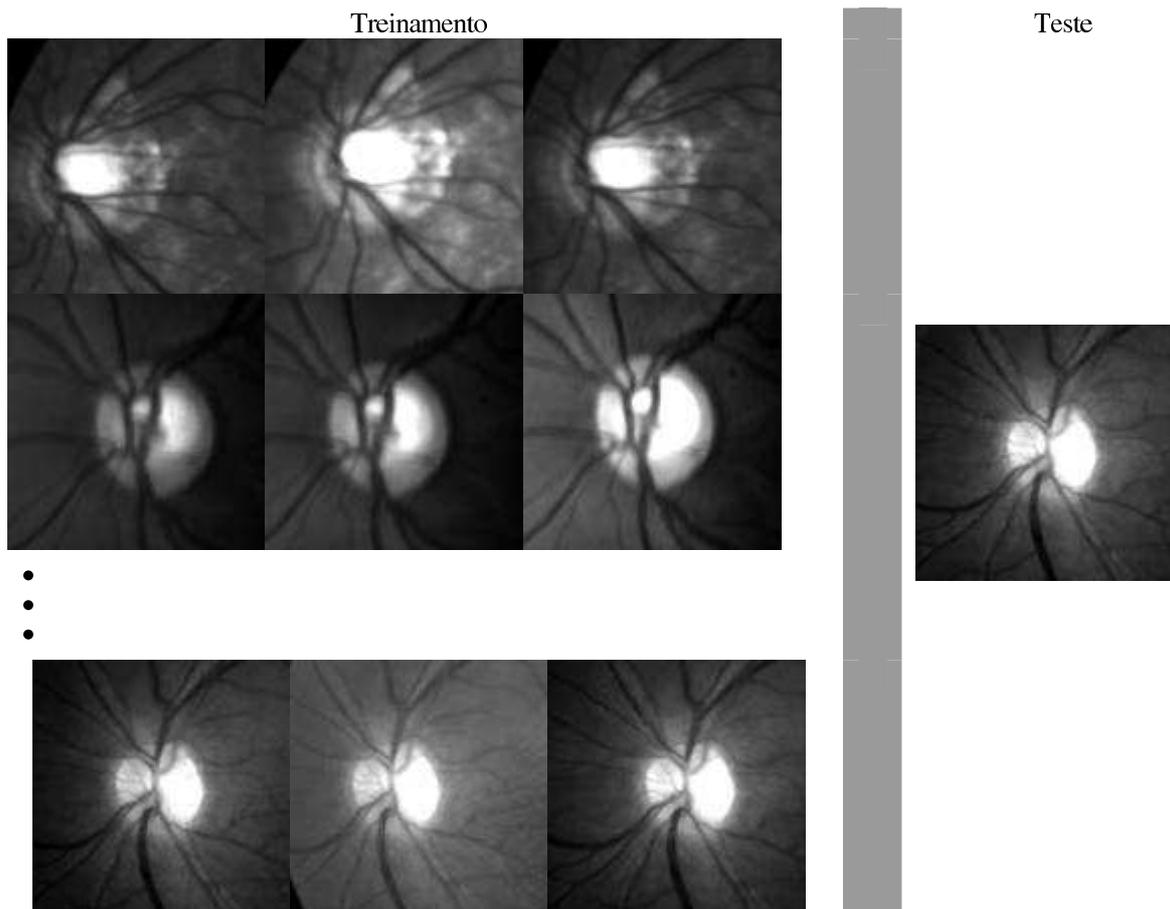


Figura 40. Cenário da Identificação Retinal II
Fonte: Elaborado pela autora.

O método de aplicação de PCA em imagens conserva, no espaço característico projetado, a variação devida de iluminação conforme citação de Belhumeur (1997) e o banco

de imagens apresenta variações de iluminação muito diversificada. Um equipamento de captura de imagem adequado, em forma de “copo”, o qual não permite a interferência de iluminação exterior nas imagens, provavelmente conduziria o algoritmo a uma classificação de 100%.

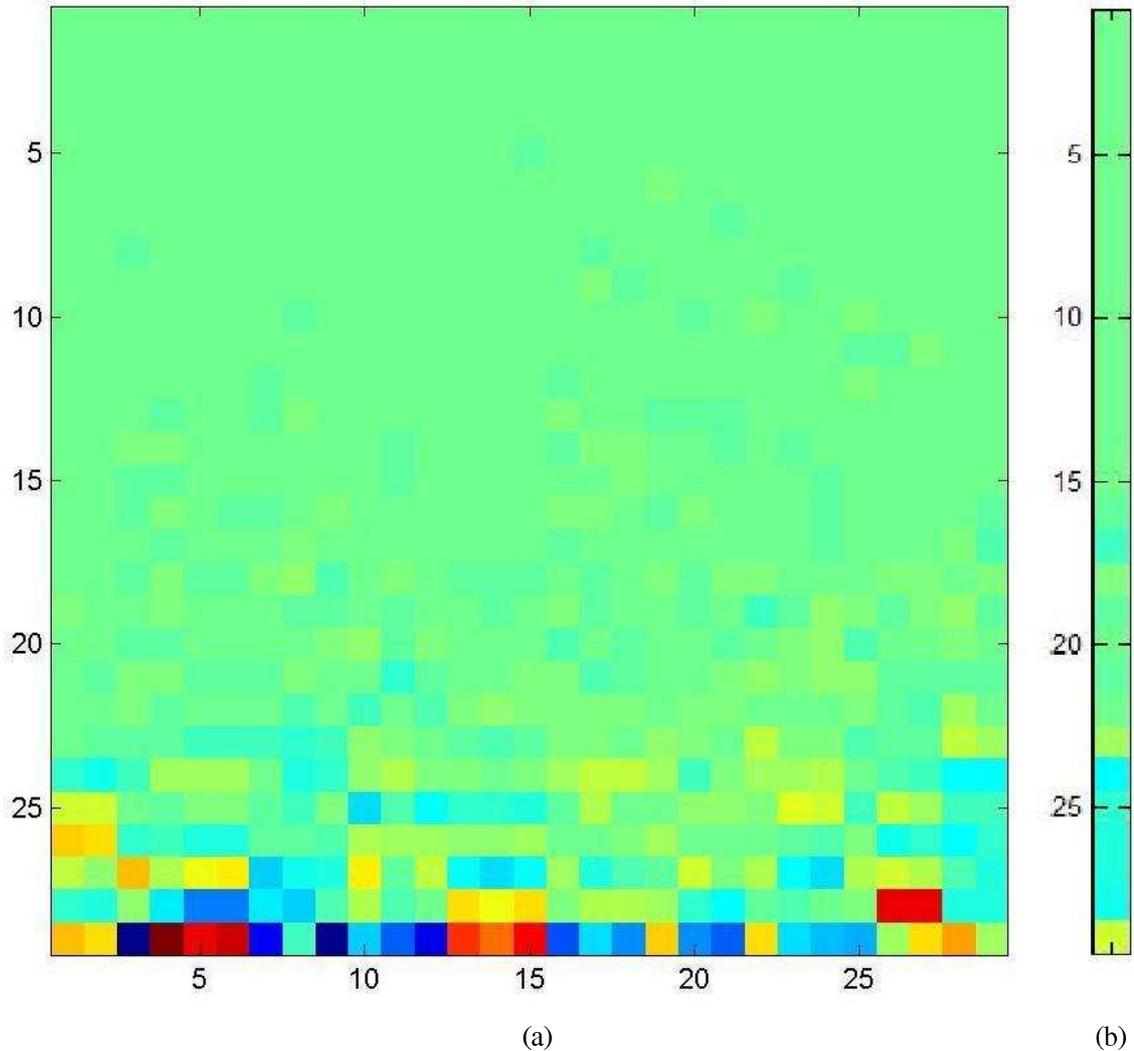


Figura 41. *Eigenretina* das Imagens Escala de Cinza em (a) e Projeção da Imagem de Teste n° 10 em (b).
Fonte: Elaborado pela autora.

Testes com outros 20 indivíduos, sendo possíveis apenas duas amostras de imagens binarizadas de cada um, foram realizados via PCA e análise de matrizes esparsas, porém não se obteve boa classificação (65% de identificação correta) já que trabalhos anteriores de Turk & Pentland (1991) e Delac (2005) demonstram que são necessários pelo menos três imagens no conjunto de treinamento e uma no conjunto de teste de cada indivíduo a ser analisada via PCA.

CONCLUSÕES

A presente dissertação apresenta a solução quanto ao processo de reconhecimento da identidade, via variados processamentos de imagens retiniais e outros procedimentos matemáticos, realizado na íntegra com os passos essenciais no reconhecimento biométrico dos padrões. Nos variados trabalhos publicados em biometria e reconhecimento de padrões, são apresentados apenas fragmentos de processos o que é distinto do presente trabalho, pois foram necessários muitos e variados testes com as imagens para, então, ser estabelecido um sistema de reconhecimento de identidade.

A resolução de uma imagem é quesito importante ao se analisar as características do padrão vascular de retinas. Uma baixa resolução resultará imagens com poucas características a serem distinguidas e, numa compactação por Banco de Filtros Bivariados de Transformada *Wavelet*, os resultados podem ser considerados impróprios do ponto de vista de identificação e reconhecimento de padrões. O suporte compacto da TW produz um banco de dados reduzido, melhorando muito o desempenho do *software* ao nível de reconhecimento já que o mesmo deve ser executado quase em tempo real.

As imagens, apesar de não apresentarem uma iluminação padrão em seu banco, podem ser classificadas via PCA quando binarizadas de modo bastante eficiente como fora demonstrado no presente trabalho de pesquisa, apesar de que estudos anteriores apontavam trabalhos de PCA, na abordagem do algoritmo *Eigenfaces*, sobre imagens em escala de cinza, de dimensões menores que as utilizadas nesta pesquisa.

Quanto à comparação dos Bancos de Filtros Bivariados de Transformada *Wavelet*, os de Haar apresentaram melhor desempenho no quesito de binarização das imagens e análise das características em relação aos filtros Daub4. Os tempos de processamento do algoritmo são consideravelmente menores em Banco de Filtros Bivariados de Transformada *Wavelet* de Haar, pois o mesmo interage sempre quatro *pixels* para os processos de convolução, enquanto que os Bancos de Filtros Bivariados de Transformada *Wavelet* Daub4 interagem com 16 *pixels* no processo de convolução, sendo um quesito importante na identificação de características em tempo real.

O modelo de Congruência de Fase na detecção de características em imagens que apresentam baixo contraste foi de fundamental importância neste trabalho, apesar de ser uma técnica custosa computacionalmente. Isso não impede a aplicação já que a Transformada Hough, também de alto custo computacional, é aplicada em verificação de imagens de íris como técnica já consagrada para este fim. A Transformada Hough, neste trabalho proporcionou significativa importância na centralização do Nervo Óptico ou a confirmação das coordenadas do centro, contribuindo para uma padronização na localização das características por imagens de retinas.

Embora o foco do trabalho foi no estudo de padrões para reconhecimento biométrico de indivíduos, muitos trabalhos podem ser gerados sobre o mesmo. Análises de padrões motivam variados trabalhos, até de identificação de espécies animais³, os quais são realizados com a finalidade de processar as imagens e aplicar as características obtidas na classificação automática, embasada nas significativas contribuições das discussões entre grupos de pesquisa.

O banco de imagens adquirido pode proporcionar futuras análises quanto a doenças retiniais ou doenças que apresentam alguma manifestação na retina, em conjunto com as significativas opiniões sobre as imagens de discussões dos profissionais da área médica⁴, possibilitando até a montagem de um sistema baseado em conhecimento para avaliação e auxílio no diagnóstico de doenças retiniais, ou de determinadas doenças que manifestam

³ Trabalho sobre Arraias de Água Doce, encontrado no ANEXO D, elaborados sobre processos clássicos com imagens nos padrões das espécies animais aliados às discussões com a doutoranda da UNICAMP-SP, Karla C. Tribuzy Bandeira.

⁴ Tal como ocorreu em virtude de contribuições do grupo de discussões do site YAHOO (www.yahoo.com.br) entre professores e residentes de oftalmologia.

alterações na retina. Aliando-se o conhecimento médico à detecção automática das características de determinadas patologias via processamento de imagens, com a observação e evolução das patologias ao longo de um determinado período, pode-se obter um sistema muito eficiente de diagnósticos e encaminhamentos a profissionais especializados de forma mais automatizada e até mesmo pode contribuir em tratamentos cirúrgicos, ou estudos em tratamentos farmacológicos, de determinadas retinopatias e variadas doenças.

Os trabalhos referentes à Transformada *Wavelet* proporcionam estudos amplos, possibilitando análises em variadas áreas, tal como a de análise dos espectros de polióis⁵, no quais os resultados em dados compactados podem proporcionar uma considerável rapidez e confiabilidade nos procedimentos a serem executados posteriormente sobre os dados.

O presente trabalho foi proposta para a construção de um software a ser embarcado em equipamento de captura de imagens sendo este o próximo passo, sendo que para tal fim é essencial a aquisição do equipamento e dispositivo de embarcação (*hardware* e *software*), com os devidos ajustes do algoritmo quanto ao tipo de imagem que o dispositivo irá capturar. Sem contar que a intenção deste trabalho contribui muito ao Brasil, que é um país destacável no quesito de produção agropecuária e industrial, o que torna este procedimento de reconhecimento biométrico de indivíduos (animais), dentro do processo de rastreabilidade de carnes, um ponto forte quanto ao controle de qualidade e confere maior valor agregado ao produto gerado por meios confiáveis e científicos, além de atender a requisitos exigidos na exportação de carnes.

⁵ Conforme trabalhos sobre análise de Transformadas *Wavelets* unidimensionais apresentados e publicados, conforme ANEXO E e ANEXO F.

REFERÊNCIAS

- ABCB – Associação Brasileira de Criadores de Búfalos. São Paulo (Brasil) <<http://www.bufalo.com.br/frigorifico/index.htm>>. Acesso em: 28 ago. 2006.
- ABOUFADEL, Edward, COX, Amanda, ZEE, Amy V. *Bivariate Daubechies Scaling Functions*. Technical Report. 30 jan. 2001. <<http://www.citebase.org/abstract?id=oai:arXiv.org:math/0103198>>. Acesso em: 12 jul. 2007.
- ANDRYSIAK, Tomasz, CHORAŚ, Michal. Image Retrieval Based on Hierarchical Gabor Filters. *AMCS: International Journal of Applied Mathematics and Computer Science*, vol. 15, n. 4, p.471-480, 2005.
- BALDI, Neila. Pecuaristas acusam governo de enviar lista errada à UE. *Gazeta Mercantil*, Caderno C, p. 6. São Paulo: 08 fev. 2008.
- BELHUMEUR, Peter N., HESPANHA, João P., KRIEGMAN, David J. Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection, *Proceedings of the Fourth European Conference on Computer Vision*, Vol. 1, Cambridge, UK, pp. 45-58, 1996 & Publication at *IEEE Trans. on PAMI*, July 1997.
- BIANCHI, Marcelo F. *Extração de características de imagens de faces humanas através de Wavelets, PCA e IMPCA*. Dissertação de Mestrado apresentada à Escola de Engenharia de São Carlos – SP: Universidade de São Paulo, 2006.
- BONATO, Vanderlei. *Estudo de Técnicas de Processamento e Reconhecimento Voltadas para a Impressão Digital e a Implementação de um Sistema de Processamento em Software e Hardware*. Monografia de Graduação do Curso de Ciência da Computação da Universidade de Santa Cruz do Sul (Brasil), dezembro, 2002.
- CUNHA, Maria C. *Métodos Numéricos*. 2. ed. rev. ampl. Campinas - SP: Editora da UNICAMP, 2000.
- DELAC, Kresimir, GRGIC, Mislav, GRGIC, Sonja. Generalization Abilities of Appearance-Based Subspace Face Recognition Algorithms. In: *12th Workshop on Systems, Signals & Image Processing*, 22-24. Chalkida, Greece, September 2005.

DAUGMAN, John. Iris Recognition - *American Scientist Magazine*, vol. 89 July 2001 <http://www.securimetrics.com/articles/PDFs/Iris_PDF_file.pdf#search=%22american%20Scientist%20Daugman%20Iris%22> Acesso em: 31 ago. 2006.

EUCLIDES, Kepler. *Rastreabilidade porteira à dentro! Brazilian Beef, Fronteira fora!* Campo Grande – M. S. (Brasil): Sala de Imprensa da EMBRAPA, 20 fev. 2002. <<http://www.cnpqg.embrapa.br/salaimprensa/2001/chip/entrevistakepler.htm>>. Acesso em: 28 maio 2006.

FACON, Jacques. *Morfologia Matemática: Teoria e Exemplos*. Editora Universitária Champagnat PUCPR: Curitiba, 1996.

FLECK, Margaret M. Some Defects in Finite-Difference Edge Finders. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. V. 14. n. 3. March, 1992. p. 337-345.

FUGAL, D. Lee. *Conceptual Wavelets in Digital Signal Processing*. 2007. E-BOOK: <<http://www.conceptualwavelets.com/>> Acesso: 14 mai. 2007.

GEARLOG – A Gadget Guide by Geeks, for Geeks. *Bluetooth for Farmers*, 26 jun. 2006. <http://www.gearlog.com/2006/06/bluetooth_for_farmers.php>. Acesso em 02 jan. 2008.

GILBERT, John R., MOLER, Cleeve, SCHREIBER, Robert. Sparse Matrices in MATLAB: Design and Implementation. *SIAM Journal of Matrix Analysis and Application*, 13(1) p. 333-356. Society for Industrial and Applied Mathematics Philadelphia, PA, USA, 1992.

GOMES, Jonas, VELHO, Luiz. *Computação Gráfica*. v. 1. Rio de Janeiro, IMPA, 1998.

GONZALEZ, Rafael C., WOODS, Richard E., EDDINS, Steven L. *Digital Image Processing Using MATLAB*. New Jersey – EUA: Pearson Prentice Hall, 2004.

GRASSI, Luiz H. M. *Identificação e Controle de Sistemas Dinâmicos Utilizando Redes Wavelets*. Dissertação do Programa de Pós-Graduação em Engenharia Mecânica da Universidade Estadual Paulista “Júlio de Mesquita Filho”. Ilha Solteira – SP, maio 2004.

GUILLAMET, David, VITRIÀ, Jordi. Determining a Suitable Metric When Using Non-Negative Matrix Factorization. *IEEE Proceedings of the 16th International Conference on Pattern Recognition (ICPR'02)*. v. 2, 2002, p. 128-131.

HANSELMAN, Duane, LITTLEFIELD, Bruce. *MATLAB 6: Curso Completo*. São Paulo: Prentice Hall, 2003.

HOOVER, Adam, KOUZNETSOVA, Valentina, GOLDBAUM, Michael. Locating Blood Vessels in Retinal Images by Piecewise Threshold Probing of a Matched Filter Response. *IEEE Transactions on Medical Imaging*. V. 19, n. 3, p. 203-210, 2000.

HUANG, Junzhou, WANG, Yunhong, CUI, Jiali, TAN, Tieniu. Noise Removal and Impainting Model for Iris Image. *IEEE ICIP'04 International Conference on Image Processing*. V. 2, p. 869-872, 24-27 Oct 2004.

KAPLAN, Ian. *The Daubechies D4 Wavelet Transform*. July 2001. <http://www.bearcave.com/misl/misl_tech/wavelets/daubechies>. Acesso em 03 nov. 2006.

KIRBY, Michael, SIROVICH, Lawrence, Application of the Karhunen-Loève procedure for the characterization of human faces. *IEEE Transactions Pattern Analysis and Machine Intelligence*, vol. 12, no. 1, pp. 103–108, Jan. 1990.

KOVESI, Peter. Image Features from Phase Congruency. *Videre: Journal of Computer Vision Research*. Summer 1999, v. 1, n. 3, The MIT (Massachusetts Institute of Technology) Press. Cambridge – MA.

KOVESI, Peter. Phase Congruency Detects Corners and Edges. *Proceedings DICTA'03*, p. 309-318, December 2003.

LALONDE, Marc, BEAULIEU, Mario, GAGNON, Langis. Fast and Robust Optic Disk Detection Using Pyramidal Decomposition and Hausdorff-based template Matching, *IEEE Transactions on Medical Imaging*, Vol. 20, No. 11, 1193-1200, 2001

LYTLE, Beverly, YANG, Caroline. Detecting Forged Handwriting with Wavelets and Statistics. *Rose-Hulman Institute of Technology Undergraduate Math Journal*. v. 7, n. 1, paper 8, 2006.

MAPLESOFT©: Software de Matemática Computacional. Maple 9.5. Waterloo Maple Inc. 1981-2004.

MARR, D. *Vision: a Computational Investigation into the Human representation and Processing of Visual Information*. New York: Freeman, 1982.

MARTINS, Fernando M., LOPES, Marcos A. Rastreabilidade no Brasil. In: *Boletim Agropecuário da Universidade Federal de Lavras*. n. 55. p. 1-72. Lavras – MG, ago. 2003.

MASEK, Libor. *Recognition of Human Iris Patterns for Biometric Identification*. Report submitted for the Bachelor of Engineering degree of the School of Computer Science and Software Engineering, University of Western Australia, 2003.

MATLAB®: *Software Matemático*. Version 6.5.0.180913a (R13) 18 jun. 2002, The MathWorks, Inc Copyright 1984-2002.

MOLZ, Rolf F. *Uma Metodologia para o Desenvolvimento de Aplicações de Visão Computacional utilizando um projeto conjunto de Hardware e Software*. Tese submetida como requisito parcial para a obtenção do grau de Doutor em Ciência da Computação. UFRGS, set. 2001.

MORRONE, Maria C., ROSS, John R., BURR, David C., OWENS, Robyn A. Mach bands are phase dependent. *Nature* 324 , 20 November 1986, p. 250-253.

MYERSCOUGH, Peter J., NIXON, Mark S. Estimating the Phase Congruency of Localised Frequencies. *IEEE International Conference on Image Processing – ICIP'04*. V. 1, 24-27 Oct. 2004, p. 275 – 278.

NEATVISION: Software de Processamento de Imagens com Manual de Instruções (*NeatVision Developers Guide*) Versão 2.1. Paul F. Whelan, Vision System Group: Dublin City University (London), 2000-2003. <www.neatvision.com>.

OLIVEIRA, Hélio M. de. *Wavelets: Entrando na Onda*. Recife: Universidade Federal de Pernambuco, 2002.

OPARA, Linus U. Traceability in agriculture and food supply chain: a review of basic concepts, technological implications, and future prospects. *Journal of Food, Agriculture & Environment*. Vol. 1(1). p.101-106. WFL Publisher Science and Technology: Finland, 2003. <<http://www.world-food.net/scientificjournal/2003/issue1/pdf/Agriculture/V1N1A101-106traceability.pdf>>. Acesso em: 9 abr. 2007.

OTSU, Nobuyuki. A Threshold Selection Method from Gray-Level Histogram. *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-9, n. 6, pp. 62-66, January 1979.

OWENS, Robyn. *Feature Detection Via Phase Congruency*. Computer Vision IT412 – Department of Computer Science. University of Edinburgh (Scotland – UK) out.,1997. <http://homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL_COPIES/OWENS/LECT7/>. Acesso em: 27 dez. 2006.

PAZOS, Rubén E. *Processamento de Sinais* 241106. <http://rpanta.com/downloads/material/241106_RPP_DSP07.pdf>. Acesso em: 01 dez. 2006.

PENNY, John, LINDFIELD, George. *Numerical Methods Using MATLAB*. Bodmin – Cornwall – Great Britain: Ellis Horwood Limited, 1995.

PRALL, Guy. Rastreabilidade da carne suína – Avanços Tecnológicos. *Seminário Internacional sobre Produção, Mercado e Qualidade da Carne de Suínos*. 8-9 de maio de 2002. Florianópolis-SC, Brasil. <[ww.cnpsa.embrapa.br/down.php?tipo=publicacoes&cod_publicacao=514](http://www.cnpsa.embrapa.br/down.php?tipo=publicacoes&cod_publicacao=514) ->. Acesso em: 19 abr. 2007.

ROSS, Arun A. *Information Fusion in Fingerprint Authentication*. Dissertation submitted for the degree of Doctor of Philosophy, Department of Computer Science & Engineering. Michigan State University: USA, 2003.

SISBOV – BRASIL (Sistema Brasileiro de Identificação e Certificação de Origem Bovina e Bubalina). Instrução Normativa Nº 1, de 10 de Janeiro de 2002 pelo MAPA (Ministério da Agricultura, Pecuária e Abastecimento). Publicado no D.O.U de 10/01/2002, seção 1, pág. 6.<<http://www.fundepecpr.org.br/in012002.asp>> Complementado pela Instrução Normativa Nº 21, de 26 de Fevereiro de 2002 <<http://www.boidecorte.com.br/scripts/informativo/normasisbov.asp>>. Acesso em: 28 ago. 2006.

SHEPARD, Kim, WING, Brad, MILES, Chris, BLACKBURN, Duane. *Iris Recognition*. National Science and Technology Council (NSTC) – Committee on Technology – Committee on Homeland and National Security – Subcommittee on Biometrics (EUA), last updated 31 march 2006. <<http://www.biometriccatalog.org/NSTCSubcommittee/Documents/Iris%20Recognition.pdf>>. Acesso em: 15 abr. 2006.

SOARES, João V. B. ; LEANDRO, João J. G. ; CESAR JUNIOR, R. M. ; JELINEK, H. F. ; CREE, M. J. *Retinal Vessel Segmentation Using the 2-D Morlet Wavelet and Supervised Classification*. v.2, 11 may 2006, Cornell University Library – Ithaca, NY – EUA. <http://arxiv.org/PS_cache/cs/pdf/0510/0510001.pdf>. Acesso em: 11 jun. 2006.

SOARES, João V. B. *Segmentação de Vasos Sangüíneos em Imagens de Retina Usando Wavelets e Classificadores Estatísticos*. Dissertação apresentada ao Instituto de Matemática e Estatística da Universidade de São Paulo para obtenção do grau de Mestre em Ciências. São Paulo, jul. 2007.

THONGNUCH, Viranee, UYYNONVARA, Bunyarit. Automatic Detection of Optic Disc From Fundus Images of ROP Infant Using 2D Circular Hough Transform, *ISBME2006 – 2nd International Symposium on Biomedical Engineering*, November 8-10, 2006, Bangkok - Thailand, pp.328-330.

TISSE, Christel-loïc, MARTIN, Lionel, TORRES, Lionel, ROBERT, Michel. Person Identification Technique Using Human Iris Recognition. *15th International Conference on Vision Interface*, May 27-29, Calgary, Canada, 2002.

TORRENCE, Christopher, COMPO, Gilbert P. A Pratical Guide to Wavelet Analysis. *Bulletin of the American Meteorological Society*. Vol. 79, n. 1, Jan. 1998.

TURK, Mattew A. A Random Walk Through Eigenspace. *IEICE Transactions on Information and Systems.*, vol. E84-D, n. 12, p. 1586-1595. December 2001.

TURK, Matthew A., PENTLAND, Alex P. Eigenfaces for Recognition, *Journal of Cognitive Neuroscience*, Vol. 3, No. 1, pp. 71-86, Massachussets Institute of Tecnology – USA, Winter 1991.

US PATENT 6053865 Issued on April 25, 2000. *Retinal Disease Analyzer*. Inventors: Akihiro Sugiyama, Tkuya Moriyama, Hiroshi Ichiki. Assignee: Kabushiki Kaisha Topcon. <<http://www.patentstorm.us/patents/6053865-description.html>>. Acesso: 19 jan. 2007.

VERNON, David. *Machine Vision*. Prentice Hall International: UK, 1991.

WALKER, James S. *A Primer on Wavelets and Their Scientific Applications*. Boca Raton-Florida (USA): Chapman & Hall, 1999.

ZANA, Frédéric, KLEIN, Jean-Claude. A Multi-Modal Registration Algorithm of Eye Fundus Images Using Vessels Detection and Hough Transform. *IEEE Transactions on Medical Imaging*. V. 18, N. 5, p. 419-428, May 1999.

ZMUDA, Michael A., TAMBURINO, Louis A. Efficient Algorithms for the Soft Morphological Operators. *IEEE Transactions on Pattern Analisys and Machine Intelligence* Vol. 18 . N. 11. p. 1142-1147. November 1996.

**UNIVERSIDADE DE SANTA CRUZ DO SUL
PROGRAMA DE PÓS-GRADUAÇÃO EM
SISTEMAS E PROCESSOS INDUSTRIAIS – MESTRADO
ÁREA DE CONCENTRAÇÃO EM
CONTROLE E OTIMIZAÇÃO DE PROCESSOS INDUSTRIAIS**

Eloisa Marciana Kolberg Theisen

**CONFIABILIDADE NO PROCESSO DE RASTREABILIDADE
POR MEIO DE ANÁLISE DE IMAGENS RETINAIS**

Santa Cruz do Sul, março de 2008.