

Universidade Federal do Maranhão
Centro de Ciências Exatas e Tecnologia
Curso de Pós-Graduação em Engenharia de Eletricidade

*Metodologia Computacional para Detecção
Automática de Estrabismo em Imagens
Digitais através do Teste de Hirschberg*

João Dallyson Sousa de Almeida

São Luís
2010

Universidade Federal do Maranhão
Centro de Ciências Exatas e Tecnologia
Curso de Pós-Graduação em Engenharia de Eletricidade

*Metodologia Computacional para Detecção
Automática de Estrabismo em Imagens
Digitais através do Teste de Hirschberg*

João Dallyson Sousa de Almeida

Dissertação apresentada ao Curso de
Pós-Graduação em Engenharia de Eletricidade da UFMA
como parte dos requisitos necessários para obtenção do
grau de Mestre em Engenharia Elétrica.

**São Luís
2010**

Almeida, João Dallyson Sousa de

Metodologia Computacional para Detecção Automática de Estrabismo em Imagens Digitais através do Teste de Hirschberg/
João Dallyson Sousa de Almeida. - São Luís, 2010.

100f.:il.

Orientador: Aristófanês Corrêa Silva; Co-Orientador: Jorge Antonio Meireles Teixeira

Dissertação (Mestrado) - Curso de Pós-Graduação em Engenharia de Eletricidade, Universidade Federal do Maranhão, 2010

1. Processamento de imagem médica. 2. Modelo de reconhecimento - Estrabismo - Diagnóstico. 3. Funções geoestatísticas. I . Título.

CDU 004.932:61

**METODOLOGIA COMPUTACIONAL PARA DETECÇÃO
AUTOMÁTICA DE ESTRABISMO EM IMAGENS DIGITAIS
ATRAVÉS DO TESTE DE HIRSCHBERG**

João Dallyson Sousa de Almeida

Dissertação aprovada em 12 de fevereiro de 2010.


Prof. Aristófanes Corrêa Silva, Dr.
(Orientador)


Prof. Jorge Antonio Meireles Teixeira, Dr.
(Co-orientador)


Profa. Asla Medeiros e Sá, Dra.
(Membro da Banca Examinadora)


Prof. Anselmo Cardoso de Paiva, Dr.
(Membro da Banca Examinadora)

*“A humildade é fundamental para
quem de fato busca o conhecimento”.*

desconhecido

À Sarah, família e amigos, pelo apoio e companheirismo.

Agradecimentos

Em primeiro lugar, a Deus, Rei e Criador de todas as coisas;

À minha família, pela ajuda, incentivo e carinho constantes;

À minha noiva Sarah, pelo carinho, apoio, paciência, compreensão e revisões;

Ao professor orientador Dr. Aristófanês Corrêa Silva, pela confiança, contribuições seguras, auxílio e dedicação. Aos professores co-orientadores Dr. Jorge Antonio Meireles Teixeira e Dr. Anselmo Cardoso Paiva, pelo auxílio e conselhos que me ajudaram a concluir este trabalho;

Aos colegas da UFMA, Stelmo Magalhães, Geraldo Braz e Osvaldo Silva pelo apoio durante a pesquisa;

Aos colegas do NTI e do ministério Átrios pelo companheirismo;

A todos os professores e funcionários do Departamento de Pós-Graduação de Engenharia de Eletricidade da UFMA, pela competência e profissionalismo;

A todos que, direta ou indiretamente, contribuíram para a realização deste trabalho;

Aos professores da banca examinadora.

RESUMO

O estrabismo é uma patologia que afeta cerca de 4% da população provocando problemas estéticos, reversíveis a qualquer idade, e alterações sensoriais irreversíveis, modificando o mecanismo da visão. O teste de Hirschberg é um dos tipos de exames existentes para detectar tal patologia. Sistemas de Detecção e Diagnóstico auxiliados por computador (*Computer Aided Detection/Diagnosis*) estão sendo usados com relativo sucesso no auxílio aos profissionais de saúde. No entanto, o emprego cada vez mais rotineiro de recursos de alta tecnologia, no auxílio diagnóstico e terapêutico em oftalmologia, não é uma realidade dentro da subespecialidade estrabismo. Sendo assim, o presente trabalho tem como objetivo apresentar uma metodologia para detectar automaticamente o estrabismo em imagens digitais através do teste de Hirschberg. Para tal, o estudo está organizado em quatro fases: localização da região dos olhos, localização precisa dos olhos, localização do limbo e do brilho, e identificação do estrabismo. A metodologia apresenta resultados de 100% de sensibilidade, 91,3% de especificidade e 94% de acerto na identificação do estrabismo comprovando a eficiência das funções geoestatísticas na extração de textura dos olhos e do cálculo da alinhamento entre os olhos em imagens digitais adquiridas a partir do teste de Hirschberg.

Palavras-Chave: Processamento de Imagens, Reconhecimento de Padrões, Estrabismo, método de Hirschberg, Máquina de Vetores de Suporte, Funções Geoestatísticas.

ABSTRACT

Strabismus is a pathology that affects about 4% of the population causing aesthetic problems, reversible at any age, and irreversible tensorial alterations, modifying the vision mechanism. Hirschberg's test is one of the available exams to detect such pathology. Computer Aided Diagnosis and Detection Systems have been used with relative success to help health professionals. Nevertheless, the increasingly application of high technology resources to help diagnosis and therapy in ophthalmology is not a reality in the Strabismus sub-specialty. This way, the present work has the objective of introducing a methodology for automatic detection Strabismus in digital images through Hirschberg's test. For such, it is organized in four stages: finding the region of the eyes, precise location of the eyes, limb and bright, and identification of Strabismus. The methodology presents results of 100% of sensibility, 91,3% of specificity and 94% of match in the identification of Strabismus, improving the efficiency of the geostatistical functions in the extraction of the texture of the eyes and of the calculations of the alignment between eyes in digital images acquired from Hirschberg's test.

Keywords: Image Processing, Pattern Recognition, Strabismus, Hirschberg's test, Support Vector Machine, Geostatistical Functions.

Lista de Tabelas

| | | |
|-----|--|----|
| 4.1 | Quantidade de características selecionadas pela análise discriminante <i>stepwise</i> por medida geoestatística. | 79 |
| 4.2 | Parâmetros C e γ estimados pelo <i>grid.py</i> para as amostras de treinamento. | 79 |
| 4.3 | Resultados da classificação no MVS para as imagens de pacientes. | 80 |
| 4.4 | Resultado do processamento das 40 imagens de pacientes para verificação do alinhamento dos olhos comparados à análise do especialista. | 86 |
| 4.5 | Matriz de decisão utilizada para comparar as repostas do especialista com as da metodologia. (considerando os 40 pacientes). | 87 |
| 4.6 | Matriz de decisão utilizada para comparar as repostas do especialista com as da metodologia desconsiderando os pacientes para os quais o teste de Hirschberg não funciona. | 87 |

Lista de Figuras

| | | |
|------|--|----|
| 1.1 | Objetivo da metodologia proposta. | 16 |
| 2.1 | Estrutura externa do olho humano. | 20 |
| 2.2 | Exemplo de estrabismo. | 23 |
| 2.3 | Representação anatômica muscular do olho. Fonte: (JUNQUEIRA 2009). | 24 |
| 2.4 | Tipos de estrabismo. (a) Esotropia (ET), (b) Exotropia (XT), (c) Hipotropia (HoT) e (d) Hipertropia (H). Fonte: (MERCK 2009) . | 24 |
| 2.5 | Simulação do teste de Hirschberg. Fonte: (TECHS 2009) | 28 |
| 2.6 | Etapas do Processamento de Imagens Digitais. Adaptado de (GONZALEZ and WOODS 1992) | 30 |
| 2.7 | Esquema para realce de detalhes ocultos em imagens em níveis de cinza com diferença de iluminação. Fonte: (MELO et al. 2005) . . | 32 |
| 2.8 | Exemplo de utilização do filtro homomórfico (a) imagem original, (b) imagem após a filtragem homomórfica. | 33 |
| 2.9 | Exemplo de utilização da equalização do histograma (a) imagem original, (b) imagem após a equalização do histograma. | 33 |
| 2.10 | Esquema de omissão de pontos de mínima intensidade quando a direção do gradiente é de 45° | 36 |
| 2.11 | Aplicação do método de Canny numa imagem de olho. (a) imagem original, (b) imagem pós detecção de bordas. | 36 |
| 2.12 | Etapas de detecção de objetos em imagens pela TH. | 38 |
| 2.13 | Aplicação da TH no círculo transformado do espaço x, y (à esquerda) para o espaço de parâmetros (à direita). | 38 |
| 2.14 | Espaço de acumulação. | 39 |
| 2.15 | Exemplos de texturas. | 39 |

| | | |
|------|---|----|
| 2.16 | Características do semivariograma: Alcance, Patamar e Efeito pepita | 41 |
| 2.17 | Definição do vetor distância. | 42 |
| 2.18 | Parâmetros utilizados para cálculo das funções geoestatísticas. Fonte: (CAMARGO 1998). | 43 |
| 2.19 | (a) amostras correlacionada, (b) amostras não-correlacionadas. . . | 44 |
| 2.20 | Hiperplano ótimo. | 50 |
| | | |
| 3.1 | Aquisição da fotografia da face do paciente. | 60 |
| 3.2 | Etapas da Metodologia proposta pelo trabalho | 61 |
| 3.3 | Etapas de detecção da região dos olhos | 62 |
| 3.4 | Máscaras utilizadas no filtro homomórfico (a) máscara do passa- alta, (b) máscara do passa-baixa. | 63 |
| 3.5 | Etapas de localização dos olhos. | 63 |
| 3.6 | Distâncias e direções dos <i>lags</i> . Adaptada: (CAMARGO 1998). . . | 65 |
| 3.7 | Fluxo de atividades realizadas durante a etapa de classificação desde a base de características originais, estimação de parâmetros e reconhecimento de padrão. Adaptada: (BRAZ JUNIOR 2008) . | 66 |
| 3.8 | Aplicação do método de Canny (a) imagem de olho localizada 30 x 30, (b) imagem de olho reescalada para 120 x 120, (c) detecção de bordas. | 69 |
| 3.9 | Aplicação da TH no círculo transformado do espaço x, y (à esquerda) para o espaço de parâmetros à direita. | 70 |
| 3.10 | Paciente com olhos entreabertos. | 70 |
| 3.11 | Cálculo do alinhamento. | 73 |
| | | |
| 4.1 | Região dos olhos detectadas corretamente (ORL). | 77 |
| 4.2 | Falha na detecção da região dos olhos (ORL). | 77 |
| 4.3 | Detecção automática da região dos olhos dos pacientes. | 77 |
| 4.4 | Localização dos olhos realizada corretamente | 80 |
| 4.5 | Falha na localização dos olhos. | 80 |
| 4.6 | Regiões de olhos classificadas como não-olhos. | 81 |
| 4.7 | Exemplos de imagens em que a localização dos olhos foi realizada corretamente. | 81 |
| 4.8 | Exemplos de imagens em que metodologia falhou. | 81 |

| | | |
|------|--|----|
| 4.9 | Análise da Figura 4.8a. (a) Imagem de saída do vetor de acumulação após aplicação da TH na imagem da região dos olhos. (b) Candidato a olho direito classificado erroneamente como não-olho no MVS. | 82 |
| 4.10 | Análise da Figura 4.8b. (a) Imagem de saída do vetor de acumulação após aplicação da TH na imagem da região dos olhos. (b) e (c) candidatos a olhos direito e esquerdo, respectivamente, classificados corretamente como não-olho no MVS. | 82 |
| 4.11 | Análise da Figura 4.8c. (a) Imagem de saída do vetor de acumulação após aplicação da TH na imagem da região dos olhos. (b) Candidatos a olho direito classificados corretamente como olho. (c) candidatos a olho esquerdo classificados erroneamente como olho na MVS. | 82 |
| 4.12 | Análise da Figura 4.8d. (a) Imagem de saída do vetor de acumulação após aplicação da TH na imagem da região dos olhos. (b) Candidatos a olho esquerdo classificado erroneamente como olho pela MVS. | 83 |
| 4.13 | Exemplos de imagens nas quais a metodologia acertou na localização do limbo. | 83 |
| 4.14 | Imagem na qual a metodologia falhou na localização do limbo. . . | 84 |
| 4.15 | Exemplos de imagens nas quais a metodologia acertou na localização do brilho. | 84 |
| 4.16 | Imagens em que a aplicação do teste de Hirschberg falhou na identificação de paciente normal. (a) Olho direito. (b) Olho esquerdo. | 87 |
| 4.17 | Imagens em que a aplicação do teste de Hirschberg falhou na identificação de paciente estrábico. (a) Olho direito. (b) Olho esquerdo. | 88 |
| 4.18 | Imagens em que a metodologia falhou na localização precisa do limbo. (a) e (b) OD e OE do paciente 2. (c) e (d) OD e OE do paciente 30. | 89 |

Lista de Siglas

| | |
|------|---|
| ADL | - Análise Discriminante Linear |
| CAD | - <i>Computer-Aided Detection</i> |
| CADx | - <i>Computer-Aided Diagnosis</i> |
| EMA | - <i>Erro Médio Absoluto</i> |
| ET | - Esotropia |
| FN | - Falso Negativo |
| FP | - Falso Positivo |
| HT | - Hipertropia |
| HoT | - Hipotropia |
| IEEE | - <i>Instituto de Engenheiros Elétricos e Eletrônicos</i> |
| MVS | - Máquina de Vetores de Suporte |
| OD | - Olho direito |
| OE | - Olho esquerdo |
| OMS | - Organização Mundial de Saúde |
| ORL | - Banco de imagens de faces |
| PCA | - Análise de Componente Principal |
| RP | - Reconhecimento de Padrões |
| TH | - Transformada de Hough |
| VC | - Vetor de Características |
| VN | - Verdadeiro Negativo |
| VP | - Verdadeiro Positivo |
| XT | - Exotropia |

Sumário

| | | |
|----------|--|-----------|
| 1 | Introdução | 8 |
| 1.1 | Trabalhos Relacionados | 11 |
| 1.2 | Objetivos | 16 |
| 1.2.1 | Objetivos Específicos | 16 |
| 1.3 | Contribuição | 17 |
| 1.4 | Organização do Trabalho | 18 |
| 2 | Fundamentos Teóricos | 19 |
| 2.1 | O Olho | 19 |
| 2.2 | Visão Binocular | 21 |
| 2.3 | O Estrabismo | 22 |
| 2.3.1 | Método de Hirschberg | 26 |
| 2.4 | Métodos Computacionais de Auxílio ao Diagnóstico | 28 |
| 2.5 | Processamento de Imagens Digitais | 29 |
| 2.5.1 | Filtragem Homomórfica | 31 |
| 2.5.2 | Equalização do Histograma | 32 |
| 2.5.3 | Método de Canny | 33 |
| 2.5.4 | Transformada de Hough | 36 |
| 2.5.5 | Análise de Textura | 38 |
| 2.6 | Funções geoestatísticas para Extração de Textura | 40 |
| 2.6.1 | Semivariograma | 41 |
| 2.6.2 | Semimadograma | 43 |
| 2.6.3 | Covariograma | 43 |
| 2.6.4 | Correlograma | 44 |

| | | |
|----------|---|-----------|
| 2.7 | Seleção de Características usando Análise Discriminante Linear <i>Stepwise</i> | 45 |
| 2.8 | Reconhecimento de Padrões | 47 |
| 2.8.1 | Máquina de Vetores de Suporte | 48 |
| 2.8.2 | Similaridade | 52 |
| 2.9 | Validação de Resultados | 52 |
| 2.10 | Resumo | 54 |
| 3 | Materiais e Métodos | 56 |
| 3.1 | <i>Software</i> e <i>Hardware</i> utilizados | 56 |
| 3.2 | Pacientes | 57 |
| 3.2.1 | Protocolo de Aquisição | 57 |
| 3.2.2 | Aquisição das imagens | 59 |
| 3.3 | Metodologia Proposta | 60 |
| 3.3.1 | Detecção da Região dos Olhos | 61 |
| 3.3.2 | Localização dos Olhos | 63 |
| 3.3.3 | Localização do Limbo e do Brilho | 68 |
| 3.3.4 | Detecção do Estrabismo | 71 |
| 3.3.5 | Validação de Resultados | 74 |
| 3.4 | Resumo | 74 |
| 4 | Resultados e Discussão | 76 |
| 4.1 | Detecção da Região dos Olhos | 76 |
| 4.1.1 | Testes com o Banco ORL | 76 |
| 4.1.2 | Testes com as imagens de pacientes | 77 |
| 4.2 | Localização dos Olhos | 78 |
| 4.2.1 | Testes com o Banco ORL | 78 |
| 4.2.2 | Testes com as imagens de pacientes | 78 |
| 4.3 | Localização do Limbo e do Brilho | 83 |
| 4.4 | Detecção do Estrabismo | 85 |
| 5 | Conclusão | 90 |
| 5.1 | Trabalhos Futuros | 92 |

CAPÍTULO 1

Introdução

Estrabismo, ou vesgueira, é uma anomalia dos olhos em que eles perdem o paralelismo entre si. Enquanto um olho fixa um ponto frontal, o outro volta-se para um dos lados ou mesmo para cima ou para baixo. Dessa forma, o cérebro recebe duas imagens com focos diferentes, em vez de duas imagens que se fundem numa única. Existem diversos tipos de estrabismo; o olho afetado pode estar desviado em direção ao nariz (estrabismo convergente), para o lado (estrabismo divergente), para cima ou para baixo (estrabismo vertical). Pode haver uma combinação de desvio horizontal e vertical num mesmo paciente, como exemplo, em direção ao nariz e para cima.

O estrabismo é uma das alterações oftalmológicas mais comuns na infância. E, da interação binocular anormal, pode advir uma das formas de ambliopia¹; aliás, o estrabismo é a principal causa de ambliopia, especialmente nas esotropias², porque a fóvea do olho desviado irá rivalizar com as imagens do campo visual temporal da retina do olho fixador, que é bem mais forte que os estímulos que partem do campo visual nasal.

A ambliopia é a principal causa de baixa de visão (que não inclui apenas acuidade visual, mas também percepção espacial, movimento, cores e contrastes) em crianças, afetando cerca de 2 a 4% da população. É também a principal causa

¹A ambliopia é uma disfunção oftálmica caracterizada pela redução ou perda da visão num dos olhos, ou mais raramente em ambos, sem que o olho afetado mostre qualquer anomalia estrutural.

²Estrabismo em que o olho estrábico se desvia em direção da linha media da face, ou seja, o olho desviado gira em direção ao interior.

monocular de deficiência visual, em qualquer idade.

A ambliopia é definida como uma baixa de acuidade visual uni ou bilateral, sem alterações anatômicas na estrutura ocular ou das vias ópticas, levando a uma visão de 0,6 ou menos em ambos os olhos, ou a uma diferença de duas linhas de visão ou mais, entre os dois olhos, com a melhor correção visual. Von Grafe dizia que: “ambliopia é a condição em que o médico não vê nada e o paciente vê muito pouco” (AHRQ 2004, LIFESPAN 2008, OLERF 2008, NOORDEN and CAMPOS 2001, DIAZ and DIAS 2000).

Uma ambliopia não tratada trará baixo rendimento escolar, com dificuldade no aprendizado e, por conseguinte, contribuirá, tardiamente, para a formação de uma baixa auto-estima.

De certo, a ambliopia representa um importante problema de ordem sócio-econômica, ainda mais se considerar que ela aumentará o risco, em até três vezes, de cegueira bilateral futura, por aumentar a chance de lesão traumática no olho são, em crianças e adultos jovens. E nos idosos, a causa principal seria a associação de ambliopia em um dos olhos à degeneração macular relacionada à idade no outro (AHRQ 2004, NOORDEN and CAMPOS 2001, CHUA and MITCHELL 2004).

Pesquisas realizadas pela Organização Mundial da Saúde (OMS) no final do século passado indicaram que em 2000 teríamos cerca de 45 milhões de pessoas cegas no mundo e o triplo com baixa visão, isto é, incapazes de desempenhar grande número de tarefas cotidianas devido à deficiência visual. Os mesmos cálculos indicaram que, se iniciativas de alcance mundial e regional não forem tomadas, em 2020 existirão no mundo 75 milhões de pessoas cegas e mais de 225 milhões de portadores de baixa visão. O Brasil tem 1,1 milhão de cegos e cerca de 4 milhões de deficientes visuais (SBO 2009).

Segundo a OMS: “a cada cinco segundos uma pessoa fica cega no nosso mundo, e uma criança fica cega a cada minuto. O custo econômico da cegueira no mundo é estimado em US\$ 28 bilhões por ano”. Entre 60 e 75% dos casos de cegueira e baixa de visão são evitáveis e/ou curáveis (SBO 2009). O tratamento precoce do estrabismo evita a diminuição da visão e até mesmo a cegueira legal do olho amblíope.

De uma maneira geral pode-se dizer que o componente motor do estrabismo, ou seja, o aspecto estético do desvio, pode ser tratado em qualquer época

da vida; ainda que os desvios antigos costumem ser de tratamento mais trabalhoso, devido a alterações secundárias que podem se unir à perturbação motora inicial. Porém, as perturbações sensoriais são mais arraigadas e têm um período curto da vida do indivíduo em que são passíveis de tratamento, fase de plasticidade do sistema visual, que dura até cerca dos nove anos de idade. Assim sendo, como a principal complicação sensorial de um desvio é, conforme já referido, a ambliopia estrabísmica, deve-se implementar o seu tratamento tão logo um estrabismo com características ambliogênicas seja detectado (AHRQ 2004, LIFESPAN 2008, OLERF 2008, NOORDEN and CAMPOS 2001, DIAZ and DIAS 2000).

Para diagnosticar o estrabismo são realizados exames de acuidade visual, fundo de olho ou fundoscopia, verificação externa dos olhos (córnea, esclera, conjuntiva, íris, cristalino etc.) e exame de motilidade realizado através do *Cover Test* e do teste de Hirschberg que consiste basicamente em incidir um pequeno foco de luz para dentro dos olhos do paciente observando se o reflexo em cada olho está localizado no mesmo lugar em cada uma das córneas. Além desses exames, existem aparelhos denominados de sinoptóforos eletrônicos que medem o estrabismo através da projeção de duas imagens separadas e dissimilares na mesma posição do espaço.

O objetivo do uso do processamento digital de imagens consiste em melhorar o aspecto visual de certas feições estruturais para o analista humano e fornecer outros subsídios para a sua interpretação, inclusive gerando produtos que possam ser posteriormente submetidos a outros processamentos. A evolução da tecnologia de computação digital, bem como o desenvolvimento de novos algoritmos para lidar com sinais multidimensionais está permitindo uma gama de aplicações cada vez maior.

O processamento de imagens na medicina representa um conjunto de técnicas computacionais, que aplicadas podem prover auxílio ao diagnóstico, planejamento de tratamentos, simulação de cirurgias, compressão de imagens em bancos de exames, recuperação de exames por conteúdo de imagens, auxílio à pesquisa em medicina, educação médica, dentre outros.

Sistemas de detecção e diagnóstico auxiliado por computador (respectivamente CAD - *Computer-Aided Detection* e CADx - *Computer-Aided Diagnosis*) têm

sido propostos com o objetivo de auxiliar o especialista, indicando áreas suspeitas, bem como anormalidades mascaradas. Esses sistemas têm sido desenvolvidos por vários grupos de pesquisa, visando auxiliar, por exemplo, na detecção e diagnóstico precoce do câncer de mama (GUPTA and UNDRILL 1995) (MEERSMAN *et al.* 1998) (KINOSHITA *et al.* 2004). Essa categoria de sistema vem ganhando cada vez mais espaço na medicina moderna.

O emprego cada vez mais rotineiro de recursos de alta tecnologia, no auxílio diagnóstico e terapêutico em oftalmologia, não é uma realidade dentro da subespecialidade estrabismo. Assim, não é fácil se conseguir médicos com experiência nesta subárea fora dos grandes centros urbanos, o que dificulta, sobremaneira, o diagnóstico precoce de estrabismos com pequeno ângulo de desvio e sua diferenciação com pseudoestrabismos.

Atentos a esta problemática, o estudo em questão visa desenvolver uma metodologia capaz de, pela análise automatizada de imagens, capturados com alguns cuidados técnicos mínimos, e por uma câmera fotográfica digital comum, determinar, com boa sensibilidade, o risco de um paciente ter estrabismo.

Este trabalho tem por objeto avaliar a eficácia do uso de técnicas de processamento de imagens e reconhecimento de padrões para verificação automática de estrabismo baseado em fotografias digitais de faces. As medidas geoestatísticas semivariograma, semimadograma, covariograma e correlograma são usadas em conjunto com as técnicas de processamento de imagens (método de Canny e transformada de Hough), seleção de características (Análise Discriminante *stepwise*) e reconhecimento de padrões (Máquina de Vetor de Suporte) para verificar e avaliar se uma pessoa é estrábica, usando como referência o método de Hirschberg.

1.1 Trabalhos Relacionados

O campo que envolve o uso de ferramentas computacionais para auxílio ou acompanhamento do diagnóstico médico em estrabismo ainda é visto como muito recente. Entretanto, algumas ferramentas já foram ou estão sendo desenvolvidas para que profissionais da área médica possam tomar decisões confiáveis a respeito de patologias da visão.

Em (JOLSON *et al.* 1992) foi desenvolvido um equipamento chamado de *Trophometer* para medir a posição e o movimento ocular usando processamento de imagem de computador, para auxílio médico do diagnóstico de forias e tropias. Foi utilizada a técnica de *moving window thinning* para detecção de bordas da pupila e do limbo e a Transformada de Hough foi aplicada para localizar a pupila.

Em (HELVESTON *et al.* 2001) foi proposto um método utilizando telemedicina para tratamento de estrabismo em locais sem especialistas de estrabismos. Para tal, utilizava câmeras digitais fotográficas para aquisição das imagens dos pacientes pelos oftalmologistas e computadores para envio das imagens por *e-mail* para serem analisadas por estrabólogos³ e em seguida receberem o diagnóstico e o plano de tratamento traçados pelo grupo de especialistas.

Os autores em (SOUZA *et al.* 2004), propuseram uma rede neural artificial do tipo *backpropagation* para planejar a estratégia cirúrgica em pacientes portadores de estrabismo sensorial, com desvio horizontal.

Em (EENWYK *et al.* 2008) os autores desenvolveram um sistema de vídeo automático de baixo-custo utilizando imagens de foto-refração e técnicas de inteligência artificial para investigação automática de ambliopia. Obtendo acurácia de 77% para a abordagem utilizando árvore de decisão.

No trabalho (LIBRALÃO *et al.* 2005) os autores descreveram uma abordagem para a avaliação dos vícios refrativos do olho humano (miopia, hipermetropia e astigmatismo) por meio de técnicas de Aprendizado de Máquina. Tais vícios foram diagnosticados a partir da análise de imagens do olho adquirida pela técnica de Shack-Hartmann, as quais foram pré-processadas usando análise de histograma e informações espaciais. Em seguida foram utilizadas as técnicas de análise de componente principal (PCA) e a transformada *wavelet* de Gabor. E por fim, as características extraídas pela etapa anterior foram analisadas pelas Máquinas de Vetores Suporte.

No sentido de se tentar dar mais fidedignidade ao método de Hirschberg, algumas variações ao método vêm sendo implementadas, lançando-se mão do auxílio do computador, por meio de fotos ou vídeos digitais ou digitalizados. Porém, nestes experimentos tem-se trabalhado com flashes compostos por LED's

³Médico com especialidade no tratamento do estrabismo.

dispostos de forma circular, ou fotografias realizadas em sala especialmente preparadas para este fim, onde se administra até a intensidade da luz ambiente, para se ter controle, por exemplo, da dilatação pupilar. Ou seja, não parece algo fácil de ser reproduzido em qualquer consultório oftalmológico. Além do que, todos estes métodos estão sujeitos a variações em decorrência do tamanho pupilar (ISHIZAKI *et al.* 1993, QUICK and BOOTHE 1992, MILLER *et al.* 1993).

Laboratórios de pesquisa de motilidade ocular utilizam rastreadores oculares ou dispositivos magnéticos, para mensurar desvios e movimentações oculares, mas, embora muito precisos, são métodos caros e difíceis de se aplicar na prática, em uma situação real (QUICK and BOOTHE 1992).

Existe também o relato de aparelhos que nada mais são do que sinoptóforos eletrônicos (testa a percepção simultânea de 2 imagens separadas e dissimilares projetadas na mesma posição do espaço) utilizados para aferição de estrabismo ou algum outro dispositivo que trabalhe com as mesmas bases do sinoptóforo. Basicamente funcionariam como qualquer sinoptóforo óptico comum, porém, as imagens para fixação seriam geradas eletronicamente em vídeo e a mensuração também seria feita pelo computador (SUBHARNGKASEN 2003). No entanto, sinoptóforos são aparelhos difíceis de serem manuseados por alguém sem especialidade em motilidade ocular, não são pequenos (equivalem ao espaço ocupado por uma lâmpada de fenda, necessitando também de mesa elétrica ajustável em altura, apoio para o queixo etc) e nem fáceis de serem transportados. Além de só poderem ser aplicados a pacientes colaborativos. E, o principal, caíram em desuso já há algumas décadas, por avaliarem o desvio em um universo bastante especial, quase de laboratório, distante da realidade do dia-a-dia do paciente.

Outra forma mais recente de se fazer triagem para ambliopia é usando filtros polaróide para detecção de supressão (POTT *et al.* 2003), mas este método também requer o uso de materiais especiais, que normalmente o médico, não interessado em estrabismo ou oftalmopediatria, não terá.

Diferentemente dos equipamentos utilizados atualmente nos consultórios oftalmológicos, apresentados na revisão de literatura, este trabalho objetiva o estudo e criação de uma maneira fácil, ágil e barata de se avaliar de forma automatizada a possibilidade de alguém ter estrabismo, para que seja acessível a oftalmologistas generalistas ou não subespecializados em estrabismo, utilizando-se

de máquina fotográfica digital e um computador, portátil ou não, com o *software* de detecção de estrabismo, implementado seguindo a metodologia proposta neste trabalho.

Para desenvolver um método capaz de auxiliar o especialista na detecção de estrabismos necessita-se, inicialmente, da localização dos olhos. Neste sentido, diversos trabalhos tem sido desenvolvidos para localizar automaticamente os olhos em imagens digitais. Em (KIM and KIM 2008) apresentam um método para detecção de olhos em imagens faciais utilizando momento Zernike com máquinas de vetores suporte (MVS). Neste, os padrões olho e não-olho são representados em termos da magnitude do momento Zernike e classificados pelo MVS. O momento Zernike é invariante à rotação, ou seja, permite detectar olhos se a face estiver rotacionada. A propriedade ortogonal do polinômio de Zernike possibilita cada momento ser único e independente da informação de uma imagem. O método alcança taxa de acerto de 94,6% para detecção de olhos de imagens de face da base ORL.

Com objetivo semelhante, os autores em (PENG *et al.* 2005) utilizam-se do método baseado em *template* para localizar o centro da íris obtendo taxa de acerto de 95,2% para as imagens sem óculos da base da ORL. Para tal, combina as vantagens de duas técnicas existentes: métodos baseados em características e métodos baseado em *templates*. Os autores usam o método baseado em característica para encontrar as duas regiões amplamente fora dos olhos, seguido do método baseado em *template* para localizar o centro da íris dentro dessas sub-regiões na face.

Em (TAKEGAMI *et al.* 2003) é desenvolvido um algoritmo de auto-calibração para detectar a posição do olhar usando o ângulo de rotação de uma imagem de elipse da pupila aplanada. A Transformada de Hough para elipse é utilizada através dos parâmetros do algoritmo de auto-calibração para detectar a forma da pupila. Para detectar a direção do olhar com alta precisão é necessário diferenciar direção do olho de direção do olhar. A direção do olho é definida como uma direção geométrica do globo ocular enquanto a direção do olhar é a detecção do olhar fixo ao longe. Nesse algoritmo o centro de curvatura da córnea é usado indiretamente e a pupila é aproximada robustamente usando Transformada de Hough. Este método permite detectar a direção do olhar sempre quando a posição da cabeça

é movida em relação a câmera.

Em (WANG *et al.* 2005) é utilizado um classificador probabilístico para localizar a região dos olhos. A detecção do olho é realizada através da extração de características usando *Nonparametric Discriminant Analysis* (NDA) e classificador *AdaBoost*. Para tal foram utilizados 500 pares de imagens de olhos da base FERET obtendo uma taxa global de acerto de 94,5%.

Os autores (JIAO and HE 2007) propuseram um método para monitoramento de fadiga de motorista em tempo real. Foram utilizadas câmeras equipadas com infravermelho para adquirir vídeo de imagens do motorista e separar a região dos olhos do restante da face mais facilmente. Utiliza características como: movimento de pálpebras, olhar, cabeça, e expressões faciais. Foi desenvolvido um modelo probabilístico utilizando dois *templates*, um retangular e outro inserido no centro do *template* retangular, baseado nas sugestões visuais para predizer a fadiga. O método obteve taxa de acerto de 96,4% na localização do brilho da pupila.

Em (WANG and YANG 2008) é desenvolvido um método de detecção de olhos em faces usando imagens em níveis de cinza, *template matching* binário e máquina de vetores suporte (MVS). O método está dividido em duas etapas principais: localização dos pares de olhos e detecção precisa do olho. Inicialmente a imagem é melhorada, utilizando filtro homomórfico, e binarizada. Todos os candidatos a pares de olhos são reescalados para um tamanho fixado e enviados para um classificador MVS que verifica os candidatos e obtém os pares reais dos olhos. Este obteve taxa de detecção precisa dos olhos de 96,8% para 1521 imagens do banco de faces BioID.

Já em (MOTWANI *et al.* 2004) é apresentado um método de detecção de olhos em faces usando *Wavelets* e Redes Neurais *Back Propagation*. As entradas da Rede Neural são os coeficientes máximos da vizinhança da *Wavelet*. A saída da rede é a classificação em regiões de olho ou não-olho. Os resultados obtidos para o banco de imagens de face ORL foi de 88% de acerto.

Em (SOUZA Jr. *et al.* 2009) é proposto um método para identificação de pessoas através da análise da textura da íris usando as funções geoestatísticas semivariograma e correlograma. O método obteve taxa de sucesso de 98,14% utilizando um banco de dados de íris denominado CASIA.

1.2 Objetivos

Este trabalho visa desenvolver uma metodologia computacional baseada no método de Hirschberg, usando técnicas de Processamento de Imagem, Visão Computacional e Reconhecimento de Padrões, capaz de determinar automaticamente, com boa sensibilidade, a possibilidade de um paciente ter estrabismo. A Figura 1.1 representa o objetivo da metodologia proposta sendo aplicada, por exemplo, para triagem de pacientes do Sistema Único de Saúde (SUS).

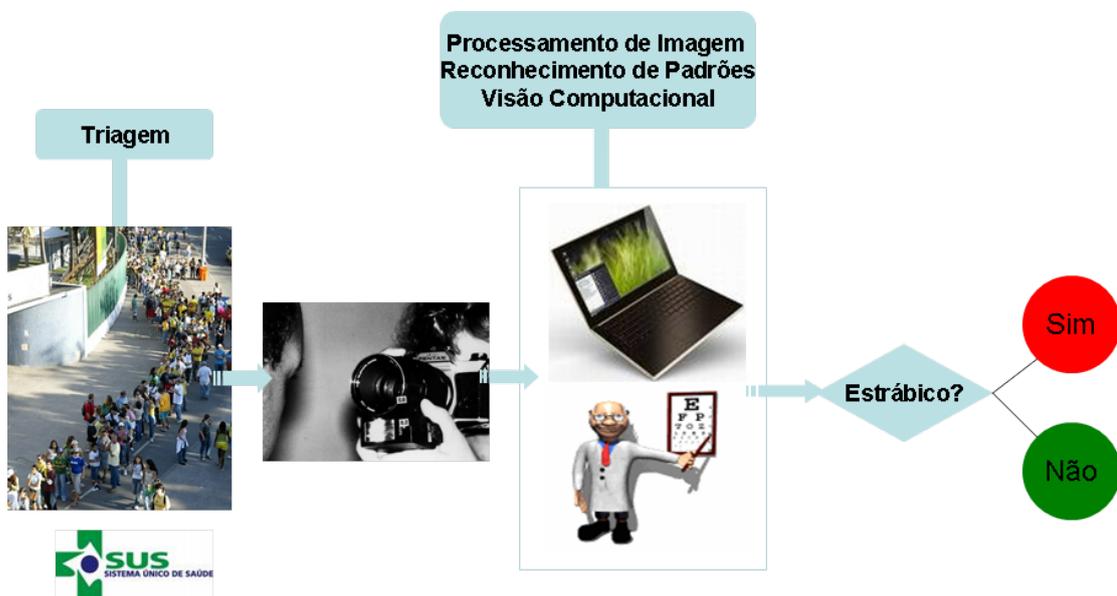


Figura 1.1: Objetivo da metodologia proposta.

1.2.1 Objetivos Específicos

No sentido de alcançar o objetivo geral pretendido, buscar-se-á atingir os seguintes objetivos específicos:

- Estudar os conceitos de estrabismo;
- Desenvolver um método de localização dos olhos para viabilizar a identificação do estrabismo;
- Estudar as técnicas de Processamento Digital de Imagens para extração de características de textura de imagens de região dos olhos aplicando as

funções geoestatísticas (semivariograma, semimadograma, covariograma e correlograma);

- Estudar o método de Hirschberg utilizado pelos especialistas na detecção do estrabismo;
- Analisar e estudar técnicas de reconhecimento de padrões, em especial Máquina de Vetores de Suporte, para classificação de padrões obtidos;
- Estudar técnicas de seleção de características, em especial Análise Discriminante Linear;
- Comparar os resultados obtidos pela metodologia proposta com os diagnosticados pelos especialistas.

1.3 Contribuição

As principais contribuições deste trabalho são:

- Utilização de funções geoestatísticas (Semivariograma, Semimadograma, Covariograma e Correlograma) para extrair características da região dos olhos. Atualmente, muitos trabalhos estão utilizando, com sucesso, esse tipo de funções para extrair informações das mais diversas imagens (SILVA *et al.* 2004).
- Desenvolvimento de um método para localização automática dos olhos utilizando funções geoestatísticas e máquinas de vetores suporte.
- Criação de uma metodologia de auxílio na identificação automática de estrabismo em imagens digitais.

A qualidade dos resultados obtidos a partir deste trabalho poderão tornar possível a incorporação do presente método em uma ferramenta para a área médica, que possa servir como uma segunda opinião para o especialista durante a etapa de identificação de estrabismo assistido por computador.

1.4 Organização do Trabalho

O restante da dissertação está organizada como segue:

No Capítulo 2, é exposta a fundamentação teórica necessária para a compreensão do presente trabalho. Serão descritos os conceitos correlatos aplicados ao estudo do estrabismo como, a anatomia dos olhos, o método de Hirschberg, a causa, consequência e tipos de estrabismo. São descritas as técnicas de processamento de imagens (filtragem homomórfica, equalização do histograma, método de Canny e a transformada de Hough), as funções geoestatísticas (semivariograma, semimadograma, correlograma e covariograma), técnica de seleção de características usando Análise Discriminante *stepwise* além da técnica de classificação denominada Máquina de Vetor de Suporte e da medida de similaridade através do erro médio absoluto.

O Capítulo 3 descreve as quatro fases (detecção de região dos olhos, localização dos olhos, localização do limbo e do brilho, e identificação do estrabismo) que compõem a metodologia utilizada para detectar o estrabismo em imagens digitais baseado no teste de Hirschberg.

No Capítulo 4 são apresentados e discutidos os resultados obtidos através da metodologia proposta. O Capítulo 5 apresenta a conclusão sobre o trabalho, mostrando a eficiência dos métodos utilizados e apresentando sugestões para trabalhos futuros.

Fundamentos Teóricos

Este capítulo apresenta a fundamentação teórica utilizada no desenvolvimento deste trabalho e necessária para compreensão das técnicas utilizadas para alcançar os objetivos esperados pelo mesmo. Aborda-se o estrabismo, o teste de Hirschberg, processamento de imagens, métodos de análise de textura baseado em medidas geoestatísticas, dentre elas: semivariograma, semimadograma, covariograma e correlograma, método de classificação e reconhecimento de padrão utilizando Máquina de Vetor de Suporte, seleção de características usando Análise Discriminante *stepwise* e técnicas de validação de resultados.

2.1 O Olho

Os olhos são órgãos fotossensíveis complexos que atingem alto grau de evolução, permitindo uma análise minuciosa quanto à forma dos objetos, cor e a intensidade de luz refletida. Cada olho fica dentro de uma caixa óssea protetora - a órbita - e apresenta basicamente uma câmara escura, uma camada de células receptoras sensoriais, um sistema de lentes para focalizar a imagem e um sistema de células e nervos para conduzir o estímulo ao córtex cerebral (JUNQUEIRA and CARNEIRO 1995).

O olho é constituído por três túnicas dispostas concêntricamente: 1. a camada externa, formada pela esclera (esclerótica) e pela córnea; 2. a camada média ou túnica vascular, constituída pelo coriódio, pelo corpo ciliar e pela íris; 3. a camada interna nervosa, a retina, que se comunica com o cérebro pelo nervo óptico.

Além desses envoltórios o olho apresenta o cristalino ou lente, uma estrutura biconvexa transparente, que é mantida em posição graças a um ligamento circular, a zona ciliar, que se insere sobre um espessamento da camada média, o corpo ciliar (JUNQUEIRA and CARNEIRO 1995).

Em frente ao cristalino existe uma expansão pigmentada e opaca da camada média que o recobre em parte, a íris. O olho tem três compartimentos: a câmara anterior, situada entre a íris e córnea; a camada posterior, entre a íris e o cristalino e o espaço vítreo, situado atrás do cristalino e circundado pela retina. Nas câmaras existe um líquido que contém proteínas: o humor aquoso. O espaço vítreo que é limitado pela retina e pelo cristalino, apresenta-se cheio de uma substância viscosa e gelatinosa, o corpo vítreo (JUNQUEIRA and CARNEIRO 1995).

Para tratarmos o estrabismo, faz-se necessário o conhecimento da anatomia do olho humano. Na Figura 2.1, temos as principais partes da estrutura externa do olho utilizadas nesse trabalho. A esclera é opaca e esbranquiçada compreendendo cinco sextos da túnica externa. Ela é uma membrana rija e inelástica que mantém o tamanho e a forma do bulbo, sua superfície externa é branca e absolutamente lisa, exceto nos pontos em que se inserem os retos e oblíquos.

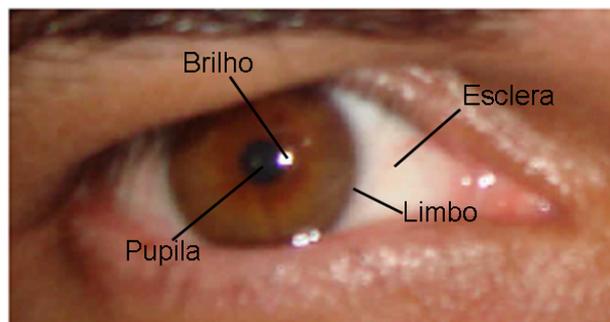


Figura 2.1: Estrutura externa do olho humano.

A abertura circular escura que se pode ver através da córnea é a pupila. Esta abertura é circundada por um diafragma circular pigmentado conhecido como íris. A pupila é responsável pela transmissão da luz. O limbo é a região de contorno entre a esclera e a íris. O brilho ou primeira imagem de Purkinje é o reflexo luminoso gerado, a partir do Teste de Hirschberg, dentro da região limbar representado na Figura 2.1 pelo círculo branco.

2.2 Visão Binocular

Se considerar o campo de visão dos olhos, existe uma área do campo visual do olho esquerdo que também faz parte do campo visual do olho direito: a esta região chamamos de campo de visão binocular. Quando os indivíduos tem os olhos alinhados e recebem estímulos visuais normais de ambos os olhos, eles terão, conseqüentemente, uma região de sua área de visão monocular que é focalizada também pelo outro olho simultaneamente. Considerando-se isto no espaço, haverá uma região bidimensional em que os objetos que ali se encontram estimularão áreas retinianas (dos dois olhos) análogas entre si e onde a visão binocular se processará de forma muito natural, plano este denominado *horóptero*.

A região espacial adjacente ao horóptero, imediatamente à frente e atrás dele, muito embora não estimule áreas retinianas análogas, estarão tão próximas entre si, que ainda assim será possível ocorrer visão binocular única e, a esta região chama-se área de *panum*. Portanto, percebe-se que o espaço visual binocular total compreende uma área tridimensional no espaço físico adiante dos olhos representada pelo horóptero e pela área de panum. A forma geométrica destas duas regiões, se considerado um objeto focalizado no infinito (distância maior que 6m) será de uma abóboda, com concavidade voltada para o rosto do paciente. Este sólido vai aplanando-se à medida que o foco de visão se aproxima do observador e a 1m ele terá o formato plano. A distâncias inferiores a 1m ele novamente adquire a forma de uma cúpula, com a convexidade voltada para os olhos.

É necessário diferenciar visão binocular de visão binocular única. A visão binocular se processa sempre, desde que se possa olhar com os dois olhos. Ou seja, aquém e além do *horóptero-área de panum* qualquer indivíduo normal terá visão binocular, dupla e não única – no entanto esta informação não chega ao plano da consciência e, portanto, o indivíduo não se apercebe deste fenômeno, a menos que seja despertada a sua atenção para ele (diplopia fisiológica). Visão binocular única é a capacidade de, em se tendo imagens dissimilares (cada uma proveniente de um dos olhos), fundir-se estas duas imagens e então, elas passarem a ser percebidas como se fossem uma única imagem. Este fenômeno só se processa em indivíduos normais, que tem o ponto de fixação em ambas as fóveas dos olhos, e dentro do *horóptero- área de panum*.

Diz-se que as imagens são dissimilares e não similares porque elas são

muitíssimo parecidas, mas não idênticas: com o olho esquerdo percebe-se mais os detalhes da face esquerda do objeto fixado, sendo o inverso para o olho direito. E, da fusão de duas imagens tão parecidas entre si, mas não idênticas (dissimilares), criam-se as condições para que surja a mais nobre e delicada das funções visuais, a capacidade de se perceber o espaço com nuances de profundidade, dito visão estereoscópica.

2.3 O Estrabismo

O estrabismo é uma das alterações oftalmológicas mais comuns na infância e pode ser definido como uma interação binocular anormal entre os olhos, em que uma mesma imagem não chega a fóvea¹ de ambos os olhos no mesmo instante de tempo, ou seja, os olhos não fixam a mesma imagem.

Uma vez determinada a posição de cada olho (centro da pupila), relativamente ao referencial (respectivamente, o ponto observado, ou o ponto de observação), isto é, as direções de cada um dos eixos (respectivamente, os visuais, ou os pupilares), conceitua-se o estrabismo como a diferença entre os alinhamentos esperados. Ou seja, o ângulo entre os direcionamentos oculares. Em outros termos, como um distúrbio da relação posicional binocular, com referência a um ponto (normalmente, o objeto para o qual os olhares são dirigidos) (BICAS 2009).

Por exemplo, o desvio pode permanecer e ser sempre aparente (estrabismo constante), ou pode aparecer e desaparecer (estrabismo intermitente), parecendo normal umas vezes, e anormal em outros. Um olho pode olhar em frente enquanto o outro está virado para dentro, para fora, para cima ou para baixo. Em alguns casos, o olho com desvio pode endireitar-se e o olho bom entortar. A Figura 2.2 ilustra a ocorrência do estrabismo.

O estrabismo é causado pelo desalinhamento de músculos oculares. Entretanto, não se sabe a causa precisa desse desvio que leva ao estrabismo. Sabe-se que o estrabismo pode ser uma doença congênita. No entanto, em vários pacientes não existe uma história familiar positiva para estrabismo. Sabe-se ainda que está relacionado com distúrbios neurológicos causados por doenças ou

¹A fóvea está no eixo óptico do olho, em que se projeta a imagem do objeto focalizado, e a imagem que nela se forma tem grande nitidez (JUNQUEIRA and CARNEIRO 1995).



Figura 2.2: Exemplo de estrabismo.

acidentes que alteram o funcionamento dos músculos oculares. O estrabismo pode estar associado ainda, à falta de uso de lentes corretivas no momento adequado pelas crianças que iniciam os estudos fazendo uso da visão de forma mais acentuada.

Os músculos oculares são responsáveis pela iniciação, coordenação e conclusão dos movimentos oculares. Em condições normais, os músculos que fazem mover os olhos trabalham de forma coordenada, permitindo uma visão binocular e a noção de profundidade, percepção tridimensional ou estereopsia, uma vez que o cérebro funde as imagens dos dois olhos e as interpreta como uma só.

Os movimentos oculares dos olhos são controlados por seis músculos que se inserem na parte exterior do olho. Em cada olho, os músculos reto medial (RM) e reto lateral (RL) movem o olho para a direita ou esquerda, os músculos, reto inferior (RI) e reto superior (RS), movem o olho para cima ou para baixo e os músculos oblíquo inferior (OI) e oblíquo superior (OS) controlam os movimentos de inclinação. Para dirigir o olhar para um alvo, é necessário que todos os músculos oculares estejam equilibrados e que trabalhem em conjunto com os músculos do outro olho. Quando estes músculos não funcionam em conjunto, há um desalinhamento, o estrabismo. Na Figura 2.3, temos a representação anatômica muscular do olho.

A visão se desenvolve fundamentalmente nos seis primeiros anos de vida, sendo os dois primeiros os de maior plasticidade sensorial. Sendo assim, a melhor fase para se fazer tratamento do estrabismo é até os sete anos de idade, quando o desenvolvimento ainda não está consolidado (GUIMARÃES 2009). Após esta fase, os tratamentos não costumam obter o sucesso possível e desejado. As metas do tratamento do estrabismo são: preservar a visão, alinhar os olhos e restaurar a visão binocular. O estrabismo pode ser classificado em horizontais: convergente

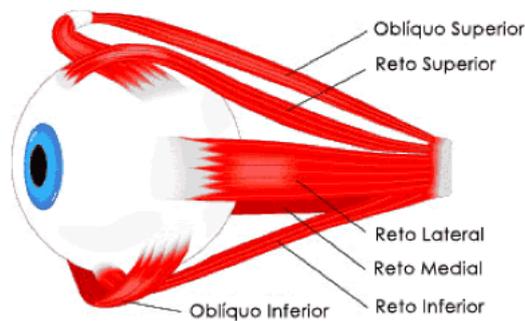


Figura 2.3: Representação anatômica muscular do olho. Fonte: (JUNQUEIRA 2009).

(esotropia) e divergente (exotropia); e verticais: hipertropia e hipotropia. É convergente, quando um olho fixa a imagem e o outro vira para dentro, e divergente, quando se desloca para fora. Na hipertropia um dos olhos pode girar para cima e na hipotropia o olho gira para baixo. Em ambos os casos, cada um dos olhos focaliza imagens diferentes e a pessoa tem o que chamamos de diplopia, ou visão dupla. Nas Figuras 2.4a, 2.4b, 2.4c e 2.4d temos exemplos dos tipos de estrabismo nas quais o olho afetado é o direito.

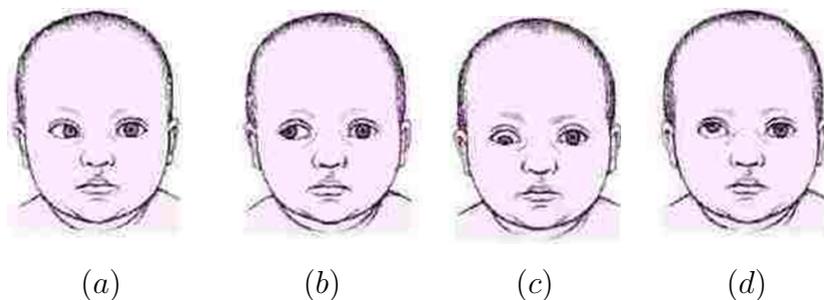


Figura 2.4: Tipos de estrabismo. (a) Esotropia (ET), (b) Exotropia (XT), (c) Hipotropia (HoT) e (d) Hipertropia (H). Fonte: (MERCK 2009)

Os sintomas e as consequências do estrabismo diferem conforme a idade em que aparecem e a maneira como se manifestam. Os estrabismos que surgem antes dos 6 anos possuem um mecanismo de adaptação que faz com que haja supressão da imagem originada no olho desviado, por isso a pessoa não apresenta diplopia. Apesar disso, ocorre diminuição da visão (ambliopia, também conhecida como “olhar preguiçoso”) do olho desviado. Por sua vez, caso fique estrábica após os

6 anos, a pessoa apresentará diplopia, pois cada olho focalizará a imagem em posições diferentes, de acordo com o desvio.

A diplopia consiste na percepção do mesmo objeto em duas localizações espaciais diferentes (na retina). Na criança, a diplopia é periódica levando à supressão. Esta, consiste num mecanismo cortical de eliminação da imagem captada pelo olho desviado ocorrendo apenas em crianças, em que ainda há plasticidade cerebral.

A ambliopia caracteriza-se por uma diminuição da acuidade visual de um olho em relação ao outro, como consequência de um período prolongado de supressão. No estrabismo intermitente, não ocorre ambliopia, uma vez que a supressão não é constante.

A ambliopia estrabísmica será sempre unilateral, a menos que haja outro fator ambliogênico associado, como alta ametropia. O uso freqüente de apenas um dos olhos para fixar, caso não seja um estrabismo com boa alternância no padrão de fixação, em uma pessoa ainda em fase de desenvolvimento do sistema visual, leva a inibição ativa dos impulsos elétricos provenientes da via retinocortical do olho desviado, determinando que parte das vias ópticas do olho não fixador prive-se de correta estimulação nervosa. Isto ocorre particularmente nas camadas do corpo geniculado lateral e córtex óptico (lobo occipital).

Em um primeiro momento, há mera inibição dos estímulos provenientes do olho desviado, ou seja, apenas uma alteração funcional, que se manifestará somente sob condições de visão binocular (supressão). Porém, este estado mantido continuamente levará a alterações microestruturais da via retinocortical em questão, fazendo com que o quadro não mais se reverta pela simples alternância da condição de visão binocular para a monocular. Nesta fase, teremos instalada a ambliopia.

O estrabismo em si não é causa de outros problemas de saúde. Entretanto, em qualquer idade, as pessoas com estrabismos latentes terão queixas de dor de cabeça pelo esforço que fazem para manter os olhos alinhados, quando isso for possível. Outra consequência importante do estrabismo é o torcicolo (chamados de torcicolos oculares), isto é, para usar melhor os dois olhos a pessoa gira ou inclina a cabeça para uma determinada posição.

Existem numerosas técnicas que podem ser aplicadas na correção do

estrabismo, para estabelecer o equilíbrio muscular e resolver o problema da ambliopia. O tratamento médico comumente utilizado é: prescrição de óculos, realização de exercícios ortóptico, obstrução do olho fixador alternando com o outro olho. Quando o tratamento médico não é suficiente aplica-se o procedimento cirúrgico realizando retrocesso ou ressecção dos músculos oculares debilitados.

A grande maioria dos estrabismos exige tratamento cirúrgico para a sua eliminação. Na maior parte das vezes, a finalidade deste é apenas estética; isso, entretanto, não diminui a sua importância, visto que a eliminação de um defeito físico, qualquer que seja ele, especialmente quando localizado nos olhos, principal órgão de relacionamento humano, está intimamente ligada à saúde emocional. Em poucos casos, no entanto, a cirurgia visa instaurar ou recuperar a visão binocular, com todas as suas vantagens, como a estereopsia e o reflexo de fusão, garantia de estabilidade do resultado obtido.

2.3.1 Método de Hirschberg

Para se avaliar o ângulo de desvio de um estrabismo, com o uso de foco luminoso, inicialmente foi descrito o método de Hirschberg, que calcula a magnitude aproximada do desvio de acordo com o deslocamento do reflexo luminoso, no olho não-fixador, em relação ao centro do seu globo ocular. Dependendo do local de incidência do reflexo, com relação ao complexo limbo-íris-pupila, depende-se de quanto será o desvio. Ou, para se escapar de variações dadas pelo tamanho da pupila, pode-se correlacionar o reflexo luminoso apenas com o centro da córnea e o limbo (MIMS and WOOD 2002). O método de Hirschberg clássico é um método de baixa precisão para análise de um desvio e é por isso que a ele somam-se outros métodos, progressivamente mais precisos, como o de Krinsky e o de prisma e cobertura (simultânea ou alternada). Este último, já nem trabalha mais com reflexo luminoso.

Esta técnica foi desenvolvida pelo oftalmologista alemão Julius Hirschberg que em 1886 usou uma vela para observar o reflexo da luz em um olho com estrabismo (WHEELER 1942).

Quando se vai examinar uma pessoa pelo método de Hirschberg, para se chegar ao diagnóstico de estrabismo, deve-se considerar que um olho é o fixador, tem a primeira imagem de Purkinje alinhada com o centro óptico deste olho e o outro,

não-fixador, é onde o desvio será observado. O desvio será inferido comparando-se o reflexo da luz na superfície anterior da córnea com o seu centro óptico e observando-se se há desalinhamento. Como fica difícil determinar-se onde está o centro óptico de um olho não-fixador, de fato, a descentração será avaliada em relação ao centro anatômico do olho, ou, melhor dizendo, ao centro da pupila. Pelo descrito, já se percebe que há outra variável interferindo na observação do desvio, que é o ângulo Kappa²; que precisa ser medido para aquele olho e levado em consideração na hora da observação do reflexo. No entanto, outros fatores também interferem no posicionamento do reflexo luminoso do olho não-fixador em relação à posição que ele, o reflexo, se encontra no olho fixador, como: curvatura corneana, tamanho da córnea e do próprio olho e a sua refração. Se estes dados forem muito diferentes entre os dois olhos, podem interferir na avaliação e, por isso, ao se pensar em alguma forma para analisar ou quantificar o desvio pelo método de Hirschberg, tem que se levar todos estes fatores em consideração (ROMANO 2006)(HASEBE *et al.* 1998).

O Teste de Hirschberg, basicamente, está associado à localização das imagens que uma fonte luminosa forma nas córneas. O descentramento de 1mm das imagens luminosas, em relação ao centro pupilar, corresponde a um desvio de 7° ou de 12 dioptrias prismáticas. Os pacientes que se submetem a este método, geralmente são crianças muito pequenas ou indivíduos que pouco colaboram.

Com a projeção de uma fonte luminosa em direção as córneas, observa-se a sua colocação em relação ao centro pupilar. Geralmente, as imagens obtidas estão localizadas nas pupilas ou discretamente nasais.

Segundo (YAMANE 2006), pode-se quantificar o valor do desvio em relação a este descentramento das imagens luminosas: borda pupilar = 15°, entre a borda e o limbo = 30° e no limbo = 45°. Neste tipo de exame a estimativa da medida do desvio é realizada a partir do pressuposto de que o centro da pupila representa o “ponto zero” do sistema de medidas.

Na Figura 2.5, temos uma imagem que ilustra a simulação do Teste de Hirschberg em um paciente que apresenta esotropia de 30° no olho direito onde a imagem não está sendo formada no centro óptico.

²Ângulo formado entre a linha visual e o eixo da pupila.



Figura 2.5: Simulação do teste de Hirschberg. Fonte: (TECHS 2009)

2.4 Métodos Computacionais de Auxílio ao Diagnóstico

Os avanços computacionais tem contribuído cada vez mais nos procedimentos médicos, auxiliando na detecção, diagnóstico e prevenção de doenças. As ferramentas Computacionais de Auxílio a Detecção (CAD - *Computer-Aided Detection*) são utilizadas como segunda opinião para os especialistas que utilizam imagens analisadas por computador na detecção de patologias.

A finalidade do CAD é melhorar a acurácia do diagnóstico, assim como a consistência da interpretação da imagem utilizando a resposta do computador como referência. Os computadores podem auxiliar os médicos especialistas em estrabismo ou não, ou até não médicos, a detectar estrabismo em imagens faciais agindo como um segundo especialista. O sistema buscará por desalinhamento ocular na imagem indicando a presença, ou ausência, de estrabismo.

Em geral, os sistemas CAD utilizam-se de técnicas provenientes de duas áreas do conhecimento: visão computacional, que envolve o processamento de imagem para realce, segmentação e extração de atributos, e inteligência artificial, que inclui métodos para seleção de atributos e reconhecimento de padrões (KENNETH 1996). Os conceitos utilizados para criar uma metodologia CAD serão abordados a seguir iniciando-se com os principais conceitos em processamento de imagens digitais.

2.5 Processamento de Imagens Digitais

O processamento digital de imagem (PDI) pode ser definido como a manipulação de uma imagem, cuja finalidade é melhorar o poder de discriminação dos objetivos (GONZALEZ and WOODS 2002). Uma imagem, matematicamente, é uma função de intensidade de luz bidimensional $f(x, y)$ onde, x e y denotam coordenadas espaciais e o valor de f na coordenada espacial (x, y) fornece a intensidade, ou seja, o brilho da imagem no ponto.

Nas imagens digitais, a representação é constituída de um conjunto de valores discretos. Geralmente este vetor é unidimensional e o domínio e a imagem de $f(x, y)$ são também discretos. O domínio é finito (geralmente uma matriz retangular) e o conjunto imagem é formado por valores no intervalo $[0, M]$. Os valores assumidos em cada ponto medido são quantificados em um número pertencente a uma escala de diferentes cores. Em imagens médicas, essas cores costumam ser relacionadas a níveis de cinza, sendo atribuído o valor zero à cor mais escura (preto) e o valor máximo M à cor mais clara da escala (branco).

As imagens digitais são, no processamento de imagens, representadas como uma matriz onde cada ponto é um valor discreto. Cada ponto ou elemento constituinte da matriz-imagem é chamado de *pixel* que é uma abreviação do termo em inglês *picture element* que, no português, significa elemento de tela.

Em medicina, principalmente na radiologia, o uso de imagens no diagnóstico médico tornou-se rotineiro e os avanços vêm permitindo o desenvolvimento de novos equipamentos e aplicativos, os chamados sistemas CAD/CADx. O diagnóstico auxiliado por computador é aquele emitido por um médico especialista que usa como referência análises feita por um *software* projetado para reconhecer padrões em imagens. O *software* alerta ao médico para que ele examine mais detalhadamente padrões suspeitos detectados pelo sistema (BRAZ JUNIOR 2008). Neste trabalho, o PDI é aplicado na oftalmologia para detecção de estrabismo.

Na Figura 2.6 temos a representação das etapas do processamento de imagens digitais. Dentre elas, após o delineamento do domínio do problema, estão aquisições das imagens digitais, pré-processamento, segmentação, representação e descrição, reconhecimento e interpretação. As etapas mais à frente recebem como entrada o processamento das etapas anteriores. Como resultado do processamento

pode-se obter uma nova imagem ou não.

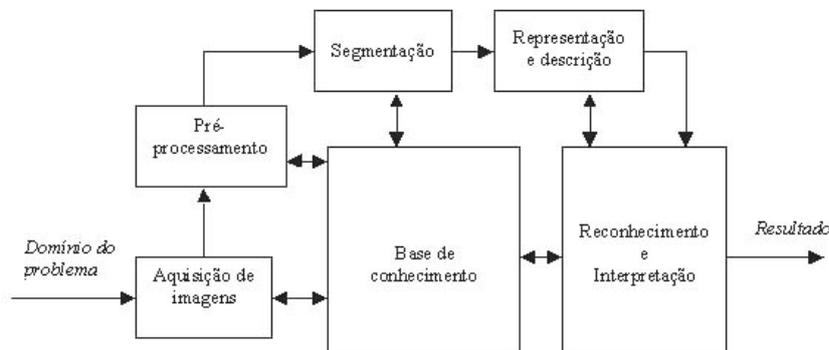


Figura 2.6: Etapas do Processamento de Imagens Digitais. Adaptado de (GONZALEZ and WOODS 1992)

Na primeira etapa temos a aquisição da imagem digital. Para isso, necessita-se de um sensor para imageamento e a capacidade de digitalizar o sinal produzido pelo sensor. Neste trabalho é utilizada uma câmera fotográfica digital para a aquisição de imagens dos pacientes.

A imagem adquirida segue para a etapa de pré-processamento. Esta etapa objetiva melhorar a imagem, realçando contrastes e removendo ruídos, tornando-a mais simples e aumentando as chances para o sucesso das etapas posteriores.

A terceira etapa da metodologia de processamento de imagem é a segmentação cujo objetivo é simplificar a imagem, extraindo o objeto de estudo. Algoritmos de segmentação permitem achar diferenças entre dois ou mais objetos, encontrar regiões homogêneas e distinguir as partículas umas das outras e do fundo. A segmentação é utilizada, geralmente, para localizar objetos e formas (curvas, linhas, etc.) em imagens. Neste trabalho, por exemplo, a segmentação é utilizada para extrair o limbo de ambos os olhos.

A etapa de representação e descrição, também conhecida como extração de características, procura extrair características que resultem em alguma informação quantitativa de interesse ou que sejam básicas para discriminação entre classes de objetos. Na extração de características fizemos uso das funções geoestatísticas descritas na Seção 2.6 para constituir o vetor de características que representa a região dos olhos.

Na quarta e última etapa é realizado o reconhecimento e interpretação.

Reconhecimento é o processo que atribui um rótulo a um objeto. A interpretação envolve a atribuição de significado a um conjunto de objetos reconhecidos. Sendo assim, nesta etapa busca-se a partir de uma base de conhecimento, previamente construída e formada pelas características extraídas na etapa anterior, classificar o objeto em algum grupo rotulado previamente.

2.5.1 Filtragem Homomórfica

O filtro homomórfico é comumente usado em melhoramento de imagens digitais. Esta técnica tenta analisar separadamente informações de iluminação e refletância. Melhorando as propriedades de refletância da imagem, pode-se melhorar o contraste nas áreas com baixos e altos níveis de iluminação (BURGISS Jr and GOODRIDGE 2001).

Esta técnica faz uso do modelo de iluminação – refletância, onde refletância $r(x, y)$ é a quantidade de luz refletida pelos objetos da cena e iluminação $i(x, y)$ é a quantidade de luz incidida na cena, para compressão do intervalo de brilho e realce de contraste simultâneos.

Neste trabalho, é implementado o filtro homomórfico no domínio espacial da imagem digital baseado no filtro proposto em (MELO *et al.* 2005). Na Figura 2.7 observa-se o esquema de aplicação do filtro homomórfico.

Como entrada para o filtro tem-se $f(x, y)$, que é uma função que representa a imagem de entrada (imagem em níveis de cinza). Os valores dos *pixels* da imagem de entrada são convertidos para logaritmo natural $\log(1 + f(x, y))$, onde ocorre a separação dos componentes de iluminação e refletância. Em seguida, é passado na imagem logarítmica o filtro passa-baixa e o filtro passa-alta. O filtro passa-baixa em $\log(1 + f(x, y))$ resultará em $\log(i(x, y))$ e um filtro passa-alta irá resultar em $\log(r(x, y))$.

As imagens resultantes dos filtros passas-alta e passa-baixa são multiplicadas por α e β , onde $\alpha < 1$ e $\beta > 1$, respectivamente, para diminuir os limites amplos de intensidade em $\log(i(x, y))$ e aumentar o contraste local em $\log(r(x, y))$. Depois disso, $\alpha \times \log(i(x, y))$ e $\beta \times \log(r(x, y))$ são combinadas (somadas) e normalizadas entre 0 e 1.

Por último, teremos o cálculo do exponencial da imagem normalizada (evita que a função exponencial tenda ao infinito) seguida de uma nova normalização

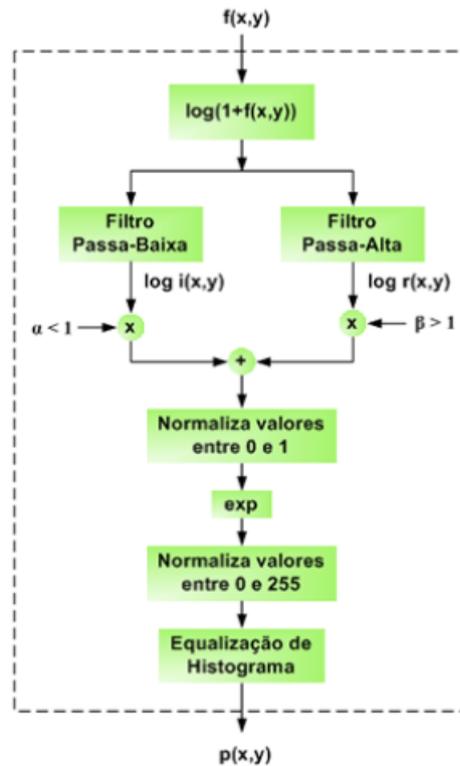


Figura 2.7: Esquema para realce de detalhes ocultos em imagens em níveis de cinza com diferença de iluminação. Fonte: (MELO et al. 2005)

entre 0 e 255 e aplicação da equalização do histograma.

Neste trabalho, o filtro homomórfico foi utilizado para evitar a influência da iluminação no processamento das imagens. O resultado obtido com a filtragem homomórfica é exemplificado pela Figura 2.8. Nas Figuras 2.8a e 2.8b, são exibidas, respectivamente, a imagem original e a imagem após a aplicação do filtro.

2.5.2 Equalização do Histograma

Um histograma é um gráfico com dois eixos, um horizontal, cobrindo todos os níveis de intensidade luminosa possíveis para a representação do valor de um *pixel* da imagem, e outro vertical, representando o número de *pixels* com um nível de intensidade luminosa específico na imagem. O histograma pode ser avaliado a partir da expressão: $H(rk) = nk$, onde rk é o k -ésimo nível de intensidade luminosa possível, de uma faixa que varia entre $[0, L-1]$, e nk é o número de *pixels*

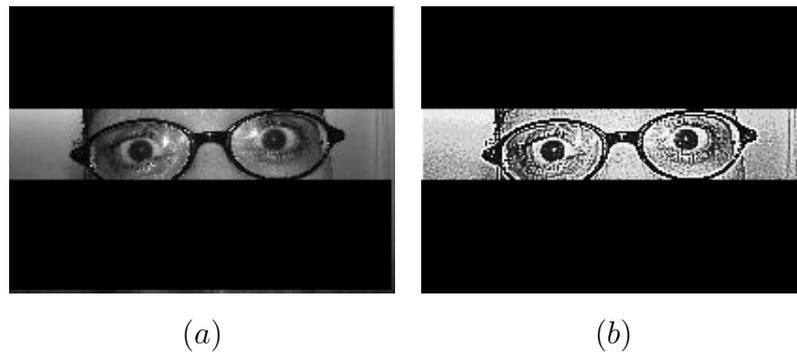


Figura 2.8: Exemplo de utilização do filtro homomórfico (a) imagem original, (b) imagem após a filtragem homomórfica.

contendo nível de intensidade luminosa igual a rk na imagem.

A equalização do histograma, realizada no domínio espacial, é uma das técnicas mais citadas na literatura para realce genérico de contraste. Tem a finalidade de obter um histograma uniforme, através do espalhamento da distribuição dos níveis de cinza ao longo de toda a escala de resolução de contraste, aumentando, dessa maneira, a detectabilidade de aspectos da imagem.

Na Figura 2.9b é exibida uma imagem após a aplicação da equalização do histograma sobre a Figura 2.9a. Como se pode observar a imagem equalizada apresenta um melhor contraste, isso deve-se à equalização do histograma que fez com que ocorresse um espalhamento do histograma ao longo de toda a gama de valores (0 a 255), ficando este mais uniforme.

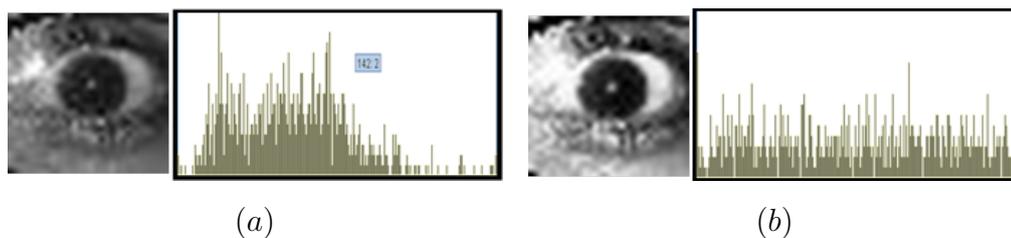


Figura 2.9: Exemplo de utilização da equalização do histograma (a) imagem original, (b) imagem após a equalização do histograma.

2.5.3 Método de Canny

A detecção de bordas é um processo no qual a imagem passa por alguma técnica para realçar as suas bordas, sendo que a mais utilizada é técnica de Canny

(SONKA *et al.* 1999). Os algoritmos utilizados para a detecção de bordas são estruturados de forma a detectar as discontinuidades existentes nas transições.

O método de Canny, desenvolvido por John F. Canny em 1986, é um operador gaussiano de primeira derivada que suaviza os ruídos e localiza as bordas. Ele é considerado um detector ótimo para as bordas do tipo degrau, comum em imagens digitais. Canny também propôs um processo de afinamento de bordas conhecido como supressão não máxima e um outro processo conhecido como histerese, cuja função é a de eliminar a fragmentação das bordas causada pelo ruído da imagem (CANNY 1986). O método de detecção de bordas de Canny possui quatro etapas básicas:

- Suavização da imagem;
- Cálculo do gradiente;
- Omissão de pontos de mínima intensidade;
- Limiarização da borda.

Suavização da imagem

A imagem é suavizada por uma função gaussianica bidimensional (2-D) dada pela Equação 2.1, de tamanho especificado por um parâmetro σ normalmente definido como 3, 5 ou 9. Na prática, convoluções gaussianicas bidimensionais de tamanho elevado, levam muito tempo para serem processadas, portanto é comum aproximá-las por duas funções gaussianicas unidimensionais, uma no eixo x e a outra no eixo y . Isso resulta em dois valores para cada *pixel*.

$$g(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2+y^2)}{2\sigma^2}} \quad (2.1)$$

Cálculo do gradiente

O operador gradiente é um dos procedimentos utilizados para detectar discontinuidades em imagens digitais. A idéia básica é aplicar um processamento computacional baseado em um operador local de derivadas. Computacionalmente, consiste em obter derivadas parciais para todos os *pixels* da imagem.

Considerando a convolução bidimensional apresentada no estágio anterior, a imagem uniformizada é separada nas direções x e y utilizando as Equações 2.2 e 2.3, respectivamente.

$$dx(x, y) = \frac{-x}{2\pi\sigma^4} e^{-\frac{(x^2+y^2)}{2\sigma^2}} \quad (2.2)$$

$$dy(x, y) = \frac{-y}{2\pi\sigma^4} e^{-\frac{(x^2+y^2)}{2\sigma^2}} \quad (2.3)$$

A magnitude do gradiente, da superfície uniforme da imagem convolucionada, é calculada somando-se as magnitudes nas direções x e y utilizando a Equação 2.4.

$$mag(x, y) = \sqrt{dx^2 + dy^2} \quad (2.4)$$

Tendo-se o gradiente nas direções x e y encontramos a direção da borda através da Equação 2.5.

$$dir(x, y) = \arctg\left(\frac{dy(x, y)}{dx(x, y)}\right) \quad (2.5)$$

Omissão de pontos de mínima intensidade

Encontrado a medida da intensidade de cada ponto da imagem, precisa-se localizar agora as bordas. Isso é possível localizando os pontos de máxima intensidade, ou de maneira inversa, pelos pontos de mínima intensidade, que precisam ser omitidos. Um valor de máxima intensidade ocorre no local mais alto da função gradiente ou onde a derivada da função gradiente possui valor zero. Entretanto, desejamos omitir os pontos de mínima intensidade ou pontos de mínimas direções perpendiculares com a borda.

Aproximações são frequentemente usadas, além da diferenciação perpendicular para cada borda. Cada *pixel* em volta forma o centro de um novo *pixel* na vizinhança. Interpolando os valores dos *pixels* ao redor, as magnitudes dos gradientes são calculados pelos limites das fronteiras vizinhas em ambas as direções perpendiculares do *pixel* central, como mostrado na figura abaixo. Nesta, se o *pixel* possuir valor menor do que os valores dos *pixels* vizinhos, ele será omitido.

Histerese

A histerese é o método utilizado pelo algoritmo de Canny para realizar a limiarização da borda da imagem. Considerando um segmento de borda, para todo valor situado acima do limite superior de limiarização, ele é imediatamente

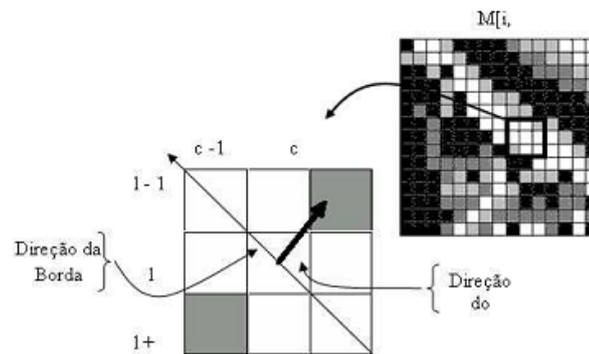


Figura 2.10: Esquema de omissão de pontos de mínima intensidade quando a direção do gradiente é de 45° .

aceito. Para todo valor situado abaixo do limite inferior de limiarização, ele é imediatamente rejeitado. Pontos situados entre os dois limites serão aceitos se eles estiverem relacionados com *pixels* que apresentem respostas fortes. A Figura 2.11b ilustra a detecção bordas da Figura 2.11a através da utilização do operador de Canny.

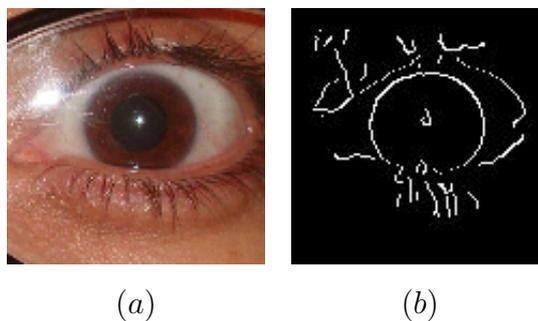


Figura 2.11: Aplicação do método de Canny numa imagem de olho. (a) imagem original, (b) imagem pós detecção de bordas.

2.5.4 Transformada de Hough

A Transformada Hough (TH) é um método matemático proposto por Paul Hough em 1962, patenteada pela IBM e reformulada computacionalmente por (DUDA and HART 1972) utilizada para detecção de bordas de forma que sejam facilmente parametrizadas, ou seja, que possua uma equação com fórmula conhecida, tais como retas, círculos e elipses.

Uma vez detectadas as bordas da imagem, podem ser realizados processamentos para completá-las, se necessário, e interpretá-las, separando as partes desejadas. Neste trabalho a Transformada de Hough é utilizada após a detecção das bordas, através do método de Canny, para localizar as regiões do limbo e do brilho em ambos os olhos.

A transformada de Hough pode ser definida como uma transformação de pontos do plano x, y para o espaço de parâmetros. O espaço de parâmetros é definido de acordo com a forma do objeto de interesse. A idéia é aplicar na imagem uma transformação tal que todos os pontos pertencentes a um mesmo objeto sejam mapeados num único ponto de um novo espaço de parametrização do objeto procurado. Para isto, este espaço dos parâmetros é discretizado e representado na forma de uma matriz de inteiros, onde cada posição da matriz corresponde a um intervalo no espaço real dos parâmetros.

Para encontrarmos regiões circulares através da TH utilizamos a Equação do círculo:

$$r^2 = (x - a)^2 + (y - b)^2 \quad (2.6)$$

onde a e b são os centros do círculo nas direções x e y , respectivamente e r é o raio. Para efeitos computacionais, é melhor utilizar a equação paramétrica do círculo dada pelas Equações 2.7 e 2.8.

$$x = a + r \cos(\theta) \quad (2.7)$$

$$y = b + r \sin(\theta) \quad (2.8)$$

Na Figura 2.12 temos o esquema de detecção de objetos pela TH. O passo inicial no processo de aplicação da TH é a detecção de bordas. Uma vez que as bordas da imagem tenham sido detectadas, converte-se os *pixels* para o domínio da TH através das Equações 2.7 e 2.8 representando-os no vetor de acumulação. A última etapa é a localização dos pontos de máxima no vetor de acumulação e conversão dos índices dos cumes para coordenadas x, y .

Na Figura 2.13 temos um exemplo de aplicação da TH, onde cada ponto de borda do círculo é tomado como centro de um outro círculo de raio desejado. O círculo é desenhado no espaço de parâmetros onde o eixo x tem valor a , y tem

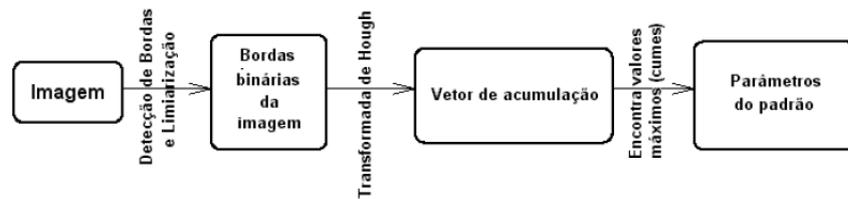


Figura 2.12: Etapas de detecção de objetos em imagens pela TH.

valor b e o eixo z representa o raio. Para todos os pontos onde o perímetro do círculo desenhado passar é incrementado no vetor de acumulação.

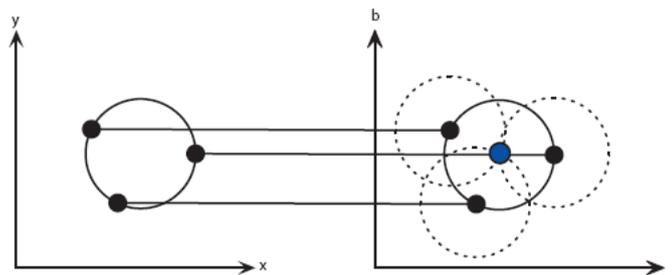


Figura 2.13: Aplicação da TH no círculo transformado do espaço x, y (à esquerda) para o espaço de parâmetros (à direita).

Na Figura 2.14, temos a ilustração do eixo z e do espaço de acumulação, indicando a localização do centro do círculo.

2.5.5 Análise de Textura

Textura é uma propriedade importante na percepção de regiões e superfícies, contendo informações sobre a distribuição espacial das variações de tonalidade locais em valores de *pixels* que se repetem de maneira regular ou aleatória ao longo do objeto ou imagem.

Embora não exista uma definição universalmente aceita para conceituar textura, pode-se defini-la como sendo um atributo que representa o arranjo espacial dos níveis de cinza dos *pixels* em uma região (GERACI *et al.* 1990). (GONZALEZ and WOODS 2002) a definem como sendo uma medida de propriedades tal como suavidade, asperidade e regularidade. A Figura 2.15 mostra diversos exemplos de texturas.

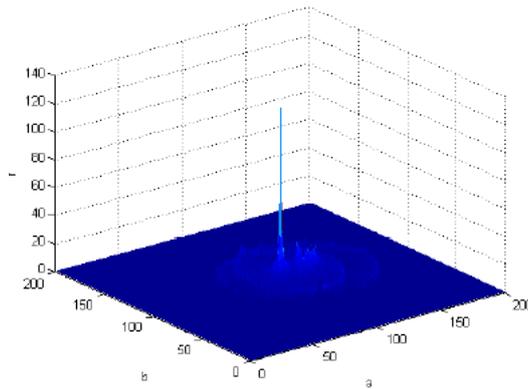


Figura 2.14: Espaço de acumulação.



Figura 2.15: Exemplos de texturas.

A extração de características de texturas a partir da matriz de co-ocorrência está entre os métodos mais utilizados da abordagem estatística para análise de texturas (BRAZ JR 2006). Essa matriz contém a medida de frequência relativa entre dois *pixels*, considerando vizinhos separados pela distância d na orientação θ , um *pixel* com tom de cinza i e o outro com tom de cinza j . As medidas que podem ser obtidas através da matriz de co-ocorrência e todo conceito que a envolvem são abordadas e descritas por (HARALICK *et al.* 1973).

Este trabalho propõe a análise de textura através de funções geoestatísticas para a formação de um padrão textural. Tais funções amplamente conhecidas no âmbito da geoestatística serão empregadas neste estudo para descrição e reconhecimento do padrão identificado por regiões de olhos e de não-olhos (outras áreas da face).

2.6 Funções geoestatísticas para Extração de Textura

Para que o processo de segmentação seja efetuado de maneira satisfatória é necessário que as propriedades de cada região da imagem sejam descritas de maneira efetiva. Estas propriedades, chamadas características, são elementos que fazem a distinção entre classes de objetos (NADLER and SMITH 1993).

Neste contexto, utiliza-se quatro medidas geoestatísticas - semivariograma, semimadograma, covariograma e correlograma - e uma combinação destas na extração de características para identificar e sugerir a região dos olhos. A grande vantagem destas funções é que as características de variabilidade e correlação espacial são analisadas em conjunto. Estas funções sumarizam a associação entre a função de distância e uma possível direção (SILVA 2004).

O conceito de geoestatística surgiu com os trabalhos de Krige (1951) com dados de concentração de ouro nos quais concluiu que apenas a informação fornecida pela variância seria insuficiente para explicar o fenômeno em estudo. Era preciso considerar a distância entre as observações. Assim, a geoestatística leva em consideração a localização geográfica e a dependência espacial (CAMARGO 1997).

Geoestatística é estatística sobre uma população com endereço conhecido, isto é coordenadas: em uma dimensão (ao longo de um rio), duas dimensões (num mapa ou imagem) e três dimensões (num volume). A teoria fundamental da geoestatística é a esperança de que, na média, as amostras próximas no tempo e espaço sejam mais similares entre si do que as que estiverem distantes (ISAACS and SRIVASTAVA 1990).

Alguns métodos estimadores geoestatísticos da autocorrelação espacial são usados como ferramentas de continuidade espacial, como: o variograma, o semivariograma, o covariograma e o correlograma. Essas ferramentas são usadas para investigar a magnitude da correlação entre as amostras e sua similaridade ou não, com a distância.

No contexto da estatística, a textura pode ser descrita em termos dos dois componentes principais associados a *pixels* (ou outra unidade): variabilidade e autocorrelação espacial. A vantagem do uso de técnicas de estatística espacial é que os dois aspectos podem ser medidos em conjunto como será discutido nas

próximas seções. Essas medidas descrevem a textura obtida de uma determinada imagem através do grau de associação espacial presente dentro dos elementos geograficamente referenciados da imagem. A correlação organizacional dos *pixels*, analisados como pontos independentes podem ser analisados com diversas medidas como as descritas na sequência deste capítulo.

2.6.1 Semivariograma

O gráfico da semivariância como uma função da distância de um ponto é denominado Semivariograma. Sendo que quanto maior a distância entre as amostras maior será a semivariância e quanto menor a distância entre as mesmas menor será a semivariância (SILVA *et al.* 2004).

As funções geoestatísticas utilizadas neste trabalho possuem 3 características principais: alcance, patamar e efeito pepita.

A Figura 2.16 apresenta um semivariograma com características próximas do ideal. Na origem ocorre uma descontinuidade denominada efeito pepita. O efeito pepita pode ser explicado pela variabilidade de pequena escala não detectada na amostragem ou simplesmente pela aleatoriedade espacial do conjunto de dados. A curva então cresce suavemente e a partir de um dado valor de h se torna constante. O valor da variável h onde a curva se torna constante é denominado alcance, e o valor correspondente da função $\gamma(h)$ é chamado patamar. Considera-se que a partir do alcance não há mais dependência espacial entre os *pixels* da amostragem.

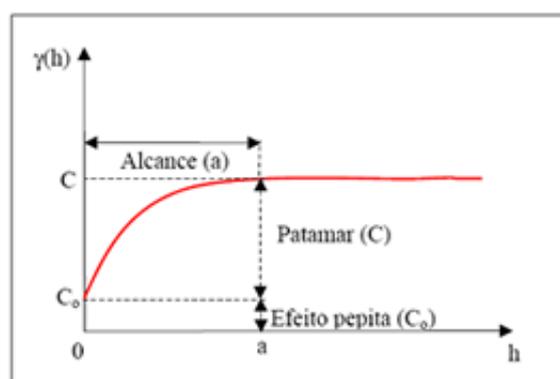


Figura 2.16: Características do semivariograma: Alcance, Patamar e Efeito pepita

- *Alcance* - Representa a distância máxima que uma característica

está correlacionada espacialmente. Refere-se à distância no qual o semivariograma atinge o patamar. É utilizado para avaliar o grau de continuidade espacial dos dados.

- *Patamar* - À medida que a distancia h entre pontos amostrados aumenta, a semivariância $\gamma(h)$ também aumenta até um valor máximo no qual se estabiliza. O patamar é aproximadamente igual à variância dos dados e através dele pode-se medir a variabilidade do semivariograma.
- *Efeito Pepita* - Revela a descontinuidade do semivariograma para distâncias menores do que a menor distância entre as amostras. Na prática, à medida que h tende para 0 (zero), $\gamma(h)$ se aproxima de um valor positivo chamado Efeito Pepita (C_0).

O Semivariograma é definido por:

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} (x_i - y_i)^2 \quad (2.9)$$

onde h é o vetor distância (*lag distance*) entre os valores de origens, x_i , e os valores de extremidade, y_i , e $N(h)$ é o número de pares na distância h . O vetor distância é exemplificado na Figura 2.17.

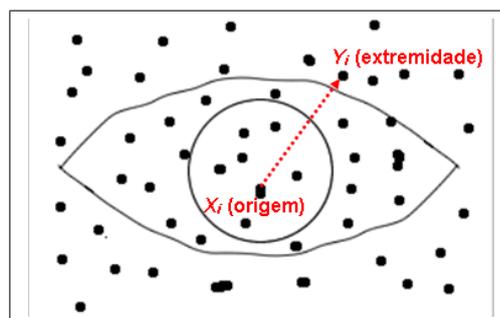


Figura 2.17: Definição do vetor distância.

Os outros parâmetros usados para calcular o semivariograma, como incremento do *lag* (*lag spacing*), tolerância do *lag* (*lag tolerance*), direção (*direction*), tolerância angular (*angular tolerance*) e largura máxima de banda (*maximum bandwidth*) são ilustrados na Figura 2.18.

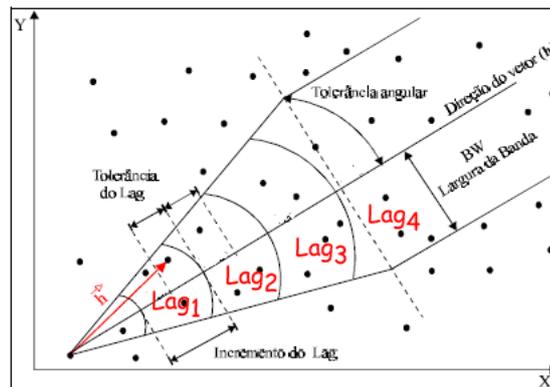


Figura 2.18: Parâmetros utilizados para cálculo das funções geoestatísticas. Fonte: (CAMARGO 1998).

Considerando o conjunto de amostras irregularmente espaçadas, em duas dimensões, conforme apresentado na Figura 2.18. Tomando como referência o Lag_2 , um incremento de lag igual a 1 *pixel* com tolerância de 0,5. Considerando ainda a direção de medida de 45° com tolerância angular $22,5^\circ$. Então, qualquer par de observações cuja distância esteja compreendida entre 1,5 e 2,5 e $22,5^\circ$ e $67,5^\circ$ será incluído no cálculo do semivariograma de Lag_2 . Este processo é repetido para todos os lag 's.

2.6.2 Semimadograma

O semimadograma é a média da diferença absoluta medida nos pares da amostra, como uma função de distância e direção (SILVA *et al.* 2004). A função é definida por:

$$m(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} |x_i - y_i| \quad (2.10)$$

onde h é vetor distância (*lag distance*) entre os valores de origens, x_i , e os valores de extremidade, y_i , e $N(h)$ é o número de pares na distância h .

2.6.3 Covariograma

O covariograma mede a correlação entre duas variáveis. Em Geoestatística, a covariância é calculada como a variância da amostra menos o valor do variograma.

A função de covariância tende a aumentar quanto mais próximas as variáveis estiverem, ou seja, quando $h = 0$ e tende a decrescer quanto mais distantes, ou próximo do limite, as variáveis estiverem. O covariograma é definido por:

$$C(h) = \frac{1}{N(h)} \sum_{i=1}^{N(h)} x_i y_i - m_{-h} m_{+h} \quad (2.11)$$

onde m_{-h} é a média dos valores das origens dos vetores,

$$m_{-h} = \frac{1}{N(h)} \sum_{i=1}^{N(h)} x_i \quad (2.12)$$

e m_{+h} é a média dos valores das extremidades dos vetores,

$$m_{+h} = \frac{1}{N(h)} \sum_{i=1}^{N(h)} y_i \quad (2.13)$$

2.6.4 Correlograma

A função de correlação (correlograma) é a versão normalizada da função de covariância e os coeficientes de correlação estão na faixa de -1 a 1 . Espera-se que a correlação seja alta para unidades que estão próximas umas das outra (correlação = 1 para distância zero) e que tenda a zero quando a distância entre as unidades aumenta (SILVA *et al.* 2004). As Figuras 2.19a e 2.19b ilustram exemplos de amostras correlacionadas e amostras não-correlacionadas, respectivamente.

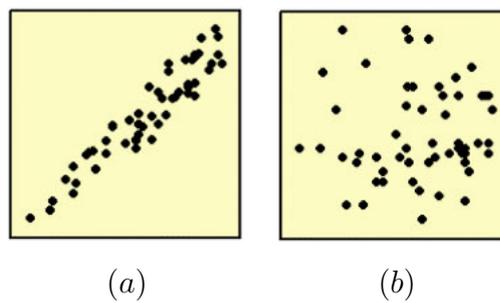


Figura 2.19: (a) amostras correlacionada, (b) amostras não-correlacionadas.

A correlação é definida por:

$$\rho(h) = \frac{C(h)}{\sigma_{-h} \sigma_{+h}} \quad (2.14)$$

onde σ_{-h} é o desvio padrão dos valores das origens dos vetores,

$$\sigma_{-h} = \left[\frac{1}{N(h)} \sum_{i=1}^{N(h)} x_i^2 - m_{-h}^2 \right]^{\frac{1}{2}} \quad (2.15)$$

e σ_{+h} é o desvio padrão dos valores das extremidades dos vetores,

$$\sigma_{+h} = \left[\frac{1}{N(h)} \sum_{i=1}^{N(h)} y_i^2 - m_{+h}^2 \right]^{\frac{1}{2}} \quad (2.16)$$

2.7 Seleção de Características usando Análise Discriminante Linear *Stepwise*

A análise discriminante linear foi desenvolvida originalmente na botânica, objetivando distinguir grupos de plantas baseando-se no tamanho e no tipo de folhas, o que tornaria possível, posteriormente classificar as novas espécies encontradas. Fisher foi o responsável pelo desenvolvimento da análise para dois grupos em 1936.

A seleção de características visa reduzir a dimensionalidade do espaço de características sem perder informações. Os principais motivos para tal redução são o custo de medição e precisão do classificador. Por isso, é necessária a utilização de algoritmos de seleção de características que propiciem a obtenção de representações dos padrões de forma robusta. Sendo assim, utiliza-se a Análise Discriminante Linear (ADL) de Fisher *stepwise*.

A ADL é uma técnica de separação de conjuntos distintos de características que busca gráfica e algebricamente os aspectos (discriminantes) que diferenciam os grupos de características. A idéia é derivar uma regra que possa ser usada para designar combinações lineares das variáveis de entrada que melhor determinam a separação das classes fornecidas (BRAZ JUNIOR 2008).

Ao invés de buscar uma forma particular de distribuição, ADL utiliza uma abordagem empírica para definir os planos de decisão lineares no espaço de atributos. As funções discriminantes usadas em ADL são construídas a partir de combinações lineares das variáveis de forma que maximize a distinção entre classes (LACHENBRUCH and GOLDSTEIN 1979):

$$y = \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n = \beta' x \quad (2.17)$$

O problema é então reduzido a achar um vetor adequado β . A idéia básica por traz da análise discriminante é determinar o quanto as classes são diferentes em relação a média de uma variável e depois usar essa variável para adequar um grupo para a nova amostra.

Dois métodos computacionais podem ser utilizados para determinar uma função discriminante: o método simultâneo (direto) e o método *stepwise*. A estimação simultânea envolve a computação da função discriminante, de modo que todas as variáveis independentes são consideradas juntas (BRAZ JUNIOR 2008). Assim, a função discriminante é computada com base no conjunto inteiro de variáveis independentes, sem consideração do poder discriminatório de cada variável independente (HAIR *et al.* 2005).

Na estimação *stepwise* uma variável é selecionada baseada em sua significância e após cada etapa as variáveis mais significativas são extraídas formando o conjunto de dados para investigação. O processo é iniciado escolhendo-se a melhor variável discriminatória. A variável inicial faz par então com uma das outras variáveis independentes, uma de cada vez, e a variável mais adequada para melhorar o poder discriminatório da função em combinação com a primeira variável é escolhida. As demais variáveis são escolhidas de maneira análoga. Após cada etapa de incorporação de uma variável, tem-se uma etapa em que variáveis previamente selecionadas podem ser descartadas. O procedimento chega ao final quando nenhuma variável é incluída ou descartada.

Neste trabalho, as funções discriminantes são aplicadas para determinar as variáveis que melhor discriminam as regiões dos olhos e as regiões de outras áreas da face criando um modelo que especifica quais são as variáveis que devem ser utilizadas para obter o melhor resultado no momento dos testes. O método *stepwise* é utilizado para selecionar as variáveis independentes que melhor discriminam as classes gerando um conjunto reduzido de variáveis para o modelo. O conjunto reduzido é geralmente melhor do que o conjunto completo de variáveis (HAIR *et al.* 2005).

2.8 Reconhecimento de Padrões

As técnicas de Reconhecimento de Padrões (RP) classificam informações (padrões) baseado ou em conhecimento pré-definido ou em informações estatísticas extraídas dos padrões. Um padrão é tudo aquilo para o qual existe uma entidade nomeável representante, geralmente, criada através do conhecimento cultural humano (LOONEY 1997). O objetivo do RP é a classificação (agrupamento das amostras em classes) e o reconhecimento de objetos desconhecidos como pertencente a uma das classes criadas.

Os sistemas de RP são formados por um sensor que captam observações a serem classificadas ou descritas; um mecanismo de extração de características que discretiza as observações captadas pelo sensor para formar o vetor de características; e por último um mecanismo de classificação das amostras observadas que depende das características que foram extraídas. A classificação pode ser de dois tipos: supervisionada e não-supervisionada.

Na classificação supervisionada, que está sendo utilizada neste trabalho, necessita-se de um supervisor para apresentar previamente o conhecimento do ambiente na apresentação dos dados de entrada e saída, de onde é extraída a representação do conhecimento, objetivando saídas corretas para dados não conhecidos anteriormente.

Um dos pontos cruciais de um sistema RP é a escolha de características. As características devem conter a maior parte da informação relevante e a dimensão do conjunto de características não deve ser muito grande. Para isso, é importante pré-processar os vetores de características a fim de retirar todas as características desnecessárias. Se duas características são extremamente correlatas, elas são redundantes. Esse tipo de característica pode sobrecarregar o classificador e induzi-lo a erros.

Após a seleção de características de cada objeto da população, a próxima etapa é atribuir um rótulo a cada vetor de características formando as amostras. Os objetos são rotulados a partir do conhecimento humano. O classificador utiliza as amostras no treinamento. Na fase de treinamento o classificador tenta gerar assinaturas, que melhor distinguem as classes, para cada rótulo pertencente ao conjunto de amostras. Esse processo é importante na fase de reconhecimento que fará uso da assinatura para identificar se novas amostras não treinadas fazem

parte de uma população específica.

Este trabalho usa Máquina de Vetor de Suporte para realizar o reconhecimento de regiões de olhos amostrados em imagens de faces humanas.

2.8.1 Máquina de Vetores de Suporte

A Máquina de Vetores de Suporte (MVS) introduzida por (VAPNIK 1998) é um método de aprendizagem supervisionada usado para estimar uma função que classifique dados de entrada em duas classes. A idéia básica por trás da MVS é construir um hiperplano como superfície de decisão, de tal maneira que a margem de separação entre as classes seja máxima. O objetivo do treinamento através de MVS é a obtenção de hiperplanos que dividam as amostras de tal maneira que sejam otimizados os limites de generalização.

As MVS são consideradas sistemas de aprendizagem que utilizam um espaço de hipóteses de funções lineares em um espaço de muitas dimensões. Os algoritmos de treinamento das MVS possuem forte influência da teoria de otimização e de aprendizagem estatística. Em poucos anos, as MVS vêm demonstrando sua superioridade frente a outros classificadores em uma grande variedade de aplicações (CRISTIANINI and SHAW-TAYLOR 2000).

As MVSs constituem uma técnica de aprendizado que vem recebendo grande atenção dos pesquisadores de Aprendizado de Máquina (AM) nos últimos anos (HEARST 1998). Algoritmos de AM são algoritmos que melhoram automaticamente à medida que aprendem com experiências passadas, obtendo conclusões genéricas a partir de um conjunto particular de amostras (MITCHELL 1997).

Os resultados da aplicação das MVSs são comparáveis e muitas vezes superiores aos obtidos por outros algoritmos de aprendizado, como Redes Neurais Artificiais (RNAs) (HAYKIN 1999) (CARVALHO *et al.* 1998). Esses resultados são alcançados pelo emprego dos conceitos da Teoria de Aprendizado Estatístico (VAPNIK 1995). Os mesmos apresentam características como a capacidade de generalização e robustez diante de grande volume de dados.

A partir de um conjunto de dados cujas classes são conhecidas, algoritmos de AM podem ser utilizados na indução de um classificador capaz de prever a classe de novos dados do domínio, realizando assim a discriminação desejada. As técnicas

de AM podem ser divididas genericamente em aprendizado supervisionado e aprendizado não supervisionado.

O algoritmo supervisionado necessita de um supervisor para apresentar previamente o conhecimento do ambiente na apresentação dos dados de entrada e saída, de onde é extraída a representação do conhecimento, objetivando saídas corretas para dados não conhecidos anteriormente. Podemos citar como exemplos de algoritmo supervisionado:

- máquina de vetores suporte;
- redes neurais artificiais do tipo *multilayer perceptron*;
- árvores de decisão;
- algoritmos genéticos.

A aprendizagem não supervisionada, ou auto-aprendizagem, é idêntica ao método anterior, porém, k_i , como observado na Equação 2.18, é desconhecido, ou seja, busca-se atribuir um padrão a um conjunto desconhecido de classes de padrões. Este problema é estudado dentro da área denominada de Análise de Conglomerados (*Clustering Analysis*). Os algoritmos de redes neurais do tipo mapa auto-organizáveis, agrupamento hierárquico e K-médias são exemplos de algoritmos não supervisionado.

Utiliza-se um algoritmo supervisionado neste trabalho. Logo, assume-se a existência de um conjunto de amostras de padrões cujas classes são conhecidas, conforme:

$$\mathfrak{S} = (x_1, k_1), (x_2, k_2), \dots, (x_m, k_m) \quad (2.18)$$

onde, X_i representa a i -ésima observação ou padrão. K_i representa a classe, ou rótulo, do padrão acima, e m representa o número de amostras disponíveis. Deve-se produzir um classificador, também denominado modelo, preditor ou hipótese, capaz de prever precisamente o rótulo de novos dados. Esse processo de indução de um classificador a partir de uma amostra é denominado treinamento (LORENA and CARVALHO 2002).

Uma tarefa de classificação normalmente envolve treinamento e teste de dados que consiste em alguns exemplos de dados. Cada exemplo no conjunto de treinamento contém um “valor objetivo” (rótulos de classe) e vários “atributos” (características), e freqüentemente, a variável de interesse é definida da seguinte forma:

$$y_i = \begin{cases} 1, & \text{se o indivíduo pertence ao grupo 1} \\ 0, & \text{se o indivíduo pertence ao grupo 2} \end{cases} \quad (2.19)$$

onde o principal interesse é obter $\text{Prob}(y=1/x) = f(x, \beta)$, e na prática, $f(x, \beta)$ é sempre uma função desconhecida.

A MVS tem como objetivo produzir um classificador que apresente um bom desempenho junto a amostras não-observadas durante o treinamento, isto é, consiga generalizar. Um classificador é uma máquina que fornece classificação. Considerando o exemplo da Figura 2.20, observamos a existência de vários classificadores lineares possíveis que podem separar as amostras disponíveis sem nenhum erro, mas há somente um que maximiza a distância entre o classificador e a amostra mais próxima de cada classe. Este classificador linear é denominado hiperplano ótimo, pois, espera-se que este hiperplano generalize melhor que os demais, quando amostras não utilizadas durante a fase de treinamento devem ser classificadas (LIMA 2004). Também pode-se observar na Figura 2.20 que o hiperplano ótimo criado possui outros hiperplanos como suporte (linhas tracejadas) denominados vetores-suporte e que passam por pontos das classes.

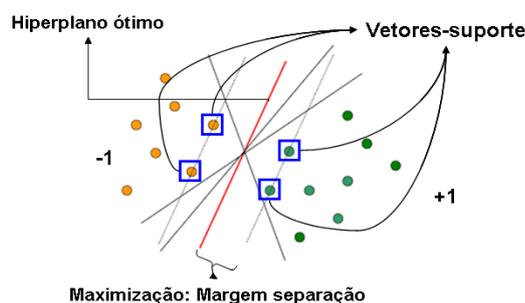


Figura 2.20: Hiperplano ótimo.

Para encontrar a solução ótima, a MVS utiliza o princípio de minimização do risco estrutural e baseia-se no fato de que a taxa de erro nos dados de teste (taxa

de erro de generalização) é limitada pela soma da taxa de erro de treinamento e por um termo que depende da dimensão de Vapnik-Chervonenkis (dimensão VC).

Segundo (SMOLA 2000) a dimensão VC de um conjunto de funções F , é definida como o tamanho do maior conjunto de pontos que pode ser particionada arbitrariamente pelas funções contidas em F . Ou seja, a dimensão VC do conjunto de funções de classificação F é o número máximo de exemplos de treinamento que pode ser aprendido pela máquina sem erro, para todas as rotulações possíveis das funções de classificação (HAYKIN 1999).

Dado um conjunto de treinamento de pares de rótulo (x_i, y_i) , $i = 1 \dots l$ onde $x_i \in \mathfrak{R}^n$ e $y_i \in \{1, -1\}$. A classificação da máxima margem de separação tem como finalidade separar as duas classes por um hiperplano tal que a distância dos vetores-suporte seja maximizada. Cada ponto x no espaço de entrada é mapeado para um ponto $z = \Phi(x)$ de alta dimensionalidade, denominado espaço de característica, onde os dados são linearmente separados por um hiperplano.

Os dados podem ser linearmente separáveis, não linearmente separáveis e não separáveis. Nós podemos escrever a nossa função de decisão usando uma função de *kernel* $K(x, y)$, por ser mais simples que o do mapeamento Φ , e que é definida pela função:

$$f(x) = \sum_{i=1}^l \alpha_i y_i K(x, x_i) + b \quad (2.20)$$

onde $k(x, x_i) = \Phi(x) \cdot \Phi(x_i)$, e os coeficientes α_i e b , são soluções das equações:

$$\min_{w, b, \xi} \frac{1}{2} w^T \cdot w + C \sum_{i=1}^l \xi_i \quad (2.21)$$

sujeito a:

$$y_i [w^T \cdot \phi(x_i) + b] \geq 1 - \xi_i \quad (2.22)$$

onde w é um vetor de pontos perpendicular no hiperplano de separação, $C > 0$ é um parâmetro escolhido pelo usuário, correspondendo a penalidade do erro e os ξ_i 's são variáveis de folga que penalizam os erros de treinamento.

As MVSs possuem diferentes *kernels* que são utilizados para resolver problemas de espaços não lineares, sendo os mais utilizados os tipos Linear, Polinomial

(que manipula uma função polinomial cujo grau pode ser definido durante os treinamentos), Sigmoidal (permite que a MVS tenha o comportamento de uma rede MLP³) e Gaussiano (corresponde a um espaço de características de dimensão infinita; a utilização desse tipo de função permite que a MVS se comporte com características de uma rede RBF⁴). Abaixo temos as quatro funções básicas de *kernel*:

- linear: $K(x, y) = x^T y$;
- polinomial: $K(x, y) = (\gamma x^T y + r)^d, \gamma > 0$;
- sigmoidal: $k(x, y) = \tanh(\gamma x^T y + r)$;
- Função básica radial (RBF): $k(x, y) = e^{-\gamma \|x-y\|^2}$.

As diferentes definições do *kernel* e seus respectivos parâmetros provocam alterações nos resultados fornecidos por uma MVS. Neste trabalho foi utilizado o *kernel* RBF com o parâmetro $\gamma > 0$ definido pelo usuário.

2.8.2 Similaridade

A similaridade entre as duas regiões candidatas a olhos é avaliada através do cálculo do Erro Médio Absoluto (EMA) que é computado através da comparação entre *pixels* correspondentes entre ambas as regiões. Neste trabalho, o cálculo do EMA é realizado seguindo a abordagem adotada em (D’ORAZIO *et al.* 2007), na qual consideram-se que as regiões são espelhadas e definida pela Equação 2.23.

$$\frac{\sum_{i=1}^N \sum_{j=1}^M |a_{ij} - b_{i(M-j+1)}|}{NM} \quad (2.23)$$

onde M e N representam, respectivamente, o número de colunas e de linhas das duas regiões comparadas. a_{ij} e $b_{i(M-j+1)}$ são os *pixels* das regiões em comparação.

2.9 Validação de Resultados

A avaliação de um algoritmo de AM supervisionado é normalmente realizada por meio da análise do desempenho do preditor gerado pelo mesmo na classificação de

³Rede perceptron de múltiplas camadas (*Multi-layer perceptron*)

⁴Funções de base radial (*Radial Basis Function*)

novos dados, não apresentados previamente em seu treinamento (LORENA and CARVALHO 2002).

Em problemas relacionados a área de saúde, a estrutura básica dos testes de classificação são para determinar quão bem um teste discrimina a presença ou ausência de uma doença. Nesses tipos de problemas, existe a presença de uma variável preditora (resultado do teste) e uma variável resultante (a presença ou ausência da doença) (LUNA 2007).

A variável preditora do teste é analisada dividindo o espaço de hipóteses em dois, definindo os critérios de corte que confirmam ou não a presença da doença. A variável resultante do teste diagnóstico é a presença ou ausência da doença, confirmada por um exame considerado *Gold Standard*⁵. Quando se avalia um teste diagnóstico quatro situações são possíveis:

1. O teste é positivo e o paciente tem a doença - Verdadeiro Positivo (VP);
2. O teste é positivo, mas o paciente não tem a doença - Falso Positivo (FP);
3. O teste é negativo e o paciente tem a doença - Falso Negativo (FN);
4. O teste é negativo e o paciente não tem a doença - Verdadeiro Negativo (VN).

Neste trabalho são utilizadas a Sensibilidade (S), Especificidade (E) e a Acurácia (A), por serem métodos estatísticos comumente utilizados, para validar os resultados.

A sensibilidade é a probabilidade de verdadeiros positivos, ou seja, a medida da capacidade do método de decisão prever a condição estrabismo para aqueles casos que realmente a apresentam, segundo a equação

$$S = \frac{VP}{VP + FN} \quad (2.24)$$

onde, VP é o número de verdadeiros positivos, ou melhor, são pacientes diagnosticados como estrábicos e que foram classificados como tal e FN o número de falso negativo, no qual pacientes diagnosticados estrábico que são classificados erroneamente como não-estrábicos.

⁵Padrão de exame com a mais alta taxa de conformidade e qualidade de resultados

A especificidade (E) é a probabilidade de verdadeiros negativos, ou seja, a medida da capacidade do método de decisão de apontar ausência da condição para aqueles casos que realmente não a têm, conforme apresentado:

$$E = \frac{VN}{VN + FP} \quad (2.25)$$

onde VN é o número de verdadeiros negativos, não-estrábico classificado como não-estrábico, e FP é o número de falsos positivos, não-estrábico classificado como estrábico.

A acurácia (A) é a probabilidade de predições corretas, dada pela Equação abaixo:

$$A = \frac{VP + VN}{VP + VN + FP + FN} \quad (2.26)$$

Valor preditivo positivo (VPP) é a probabilidade de um indivíduo avaliado e com resultado positivo ser realmente estrábico, dado por:

$$VPP = \frac{VP}{VP + FP} \quad (2.27)$$

Valor preditivo negativo (VPN) é a probabilidade de um indivíduo avaliado e com resultado negativo ser realmente não-estrábico, dado por:

$$VPN = \frac{VN}{VN + FN} \quad (2.28)$$

A sensibilidade, especificidade, valor preditivo positivo e negativo além do acerto total do sistema são usados para avaliar o desempenho da metodologia criada neste trabalho na detecção de estrabismo, além de avaliar a eficiência das funções geoestatísticas para discriminar regiões de olhos.

2.10 Resumo

Neste capítulo, foram apresentadas informações relevantes a respeito do estrabismo, seu conceito, causas, consequências e tratamentos, bem como estrutura externa do olho foi representada para melhor compreensão desta

patologia. Discorreu-se também, sobre a aplicação do método de Hirschberg pelos estrabólogos para identificar a presença de estrabismo.

Comentou-se a importância das ferramentas CAD; as técnicas de processamento de imagens utilizadas na metodologia deste trabalho: filtragem homomórfica, equalização do histograma, método de Canny, transformada de Hough e análise de textura.

Por último, foram apresentadas as funções geoestatísticas (semivariograma, semimadograma, covariograma e correlograma) usadas na extração de características; a técnica de seleção de características através da análise discriminante *stepwise*; o classificador MVS e as medidas estatísticas de validação dos resultados.

Materiais e Métodos

Este capítulo descreve os procedimentos utilizados para detecção automática de estrabismo em imagens digitais, a partir de imagens de faces de pacientes. Primeiramente é apresentada a infraestrutura computacional utilizada nos experimentos, em seguida apresenta-se a base de imagens de pacientes utilizadas nos testes. Na seqüência, é descrita a seqüência de etapas realizadas para alcançar os objetivos da metodologia.

3.1 *Software e Hardware* utilizados

Uma das linguagens orientadas a objetos mais utilizadas atualmente é a linguagem Java (JAVA 2008). A sua importância no cenário de desenvolvimento de *software* atual é justificada por uma série de características importantes da linguagem, tais como a simplicidade de implementação, aliada a uma série de recursos disponíveis através de bibliotecas, e a independência de plataforma, uma vez que o código compilado pode ser executado em qualquer plataforma que possua uma máquina virtual Java instalada.

Todos os métodos utilizados neste trabalho foram implementados usando a linguagem de programação Java versão 1.6.0 (JAVA 2008) e a IDE (Integrated Development Environment) *freeware* de desenvolvimento denominada Eclipse versão 3.2.2 (FOUNDATION 2006).

Todas as funções geoestatísticas usadas neste trabalho foram implementadas usando a linguagem Java e validadas com um *software freeware* denominado

GSLIB através da comparação dos resultados (SOUSA Jr. 2006).

A manipulação das imagens foi realizada através das funções da biblioteca *Java Advanced Imaging* (JAI) (SUN 2007), disponível gratuitamente na Internet. A biblioteca pode ser usada com a linguagem Java, fornecendo classes simples e funções para carregar, salvar, processar e exibir imagens. Possui grande portabilidade, funcionando perfeitamente em ambientes Linux e Windows.

O classificador MVS foi obtido através da biblioteca LIBSVM (CHANG and LIN 2003). A biblioteca encontra-se disponível gratuitamente na internet. Para selecionar as variáveis mais significantes foi utilizada a análise discriminante *stepwise* (LACHENBRUCH and GOLDSTEIN 1979) através do *software* Statistical Package for the Social Sciences (SPSS 2003).

O computador utilizado para os teste foi um: AMD Athlon 64 X2, 1.9 Ghz, 3gb de memória e 160gb de HD, Windows XP.

3.2 Pacientes

As imagens utilizadas neste estudo são de pacientes oriundos de um consultório oftalmológico privado especializado em estrabismo, localizado na cidade de São Luís-MA. A aquisição das imagens ocorreu por um período aproximado de 8 meses. Todos os pacientes que concordaram em participar do estudo assinaram o Termo de Consentimento Livre e Esclarecido.

3.2.1 Protocolo de Aquisição

Os pacientes foram submetidos ao protocolo de aquisição estabelecido pelo médico especialista. Este protocolo estabelece critérios para inclusão e exclusão dos pacientes na base de dados, sendo descritos a seguir.

Exame e critérios de inclusão de pacientes na base de dados

Os pacientes pertencentes à base de dados são examinados, observando-se:

- Acuidade visual com a melhor correção visual;

- Biomicroscopia¹;
- Fundoscopia² (pólo posterior);
- Tonometria de aplanção³ (sempre que possível);
- Exame de motilidade ocular⁴.

No exame de motilidade ocular foi feita a avaliação do alinhamento ocular pelo *Cover Test*, ou teste de cobertura simples e alternada. Este, é um teste um pouco mais complexo do que o método de Hirschberg através do qual se oclui alternadamente os dois olhos, sendo solicitado que o Paciente fixe o olhar num determinado ponto (objeto parado). Se ambos os olhos mantiverem-se alinhados, quer seja, sem desvio quando se troca a oclusão, isso significa que não há estrabismo. Contrariamente, ou seja, quando a troca da oclusão provoca movimentação do olho desviado para fixação no objeto, isso significa que há Estrabismo. Do *Cover Test*, pode-se constatar duas situações:

1. Não houve desvio: completa-se a avaliação estrabológica com teste das 4^Δ (dioptria prismática⁵) e avaliação sensorial pelo teste de acuidade estereoscópica de Titmus.
 - (a) se as duas últimas avaliações também forem normais, o paciente fará parte do grupo controle (sem estrabismo);
 - (b) se pelo menos um destes dois exames der alterado, o paciente será incluído no grupo teste (com estrabismo)

¹A biomicroscopia corresponde à visualização externa do olho (córnea, esclera, conjuntiva) bem como de todos componentes da câmara anterior (íris, aquoso, cristalino e suas cápsulas) e até de parte do segmento posterior (vítreo anterior e retina) através de lentes apropriadas.

²A fundoscopia é exame de fundo de olho.

³A tonometria é a medida da pressão intra ocular.

⁴A avaliação da motilidade ocular é realizada através do cover test (do oclutor manual) ou do reflexo luminoso corneal, solicitando que o paciente fixe o olhar num ponto (cover test) ou luz (reflexo luminoso), para ser verificado o desvio dos olhos para perto e para longe

⁵Unidade de desvio prismático. Unidade que especifica o desvio produzido por um prisma oftálmico. Uma dioptria prismática representa um desvio de um centímetro em uma superfície plana situada a um metro do prisma.

2. Houve desvio: aplica-se o método de prisma e cobertura (prisma e *cover*) alternado, para quantificação do desvio e o paciente irá para o grupo teste, se o seu desvio horizontal e/ou vertical for de até 15^Δ . Acima deste valor, inclui-se em um dos critérios de exclusão.

Critérios de exclusão de pacientes da base de dados

- **Grupo teste (com estrabismo)**

- Ter desvio maior que 15^Δ na horizontal e/ou vertical;
- Opacidade ou qualquer tipo de alteração corneana e/ou palpebral que inviabilize a observação dos reflexos luminosos em ambas as córneas;
- Irregularidade no contorno limbar;
- Alterações no tamanho de um dos olhos, como a microftalmia. Não se incluem como critérios alterações pupilares ou irianas, tais como: leucocoria, anisocoria, discoria; bem como alterações de segmento posterior, com ou sem comprometimento visual;
- Nistagmo⁶ manifesto.

- **Grupo controle (sem estrabismo)**

- Incapacidade de atingir 1,0 / 1,0 (na tabela de Snellen) de visão com a melhor correção visual ou de informar a acuidade visual;
- Incapacidade de alcançar 40" de arco no teste de acuidade visual estereoscópica de Titmus ou de realizar o teste;
- Nistagmo manifesto ou oscilações repetidas e involuntárias rítmicas de um ou ambos os olhos em algumas ou todas as posições de mirada.

3.2.2 Aquisição das imagens

A aquisição das imagens foi realizada no próprio consultório oftalmológico utilizando uma câmera *SonyR Cyber-shot 8.1 megapixels* (ou superior), com zoom

⁶Nistagmo são oscilações repetidas e involuntárias rítmicas de um ou ambos os olhos em algumas ou todas as posições de mirada

óptico de 3x, ajustada para o modo de captura de imagens (com mais detalhes e nitidez), com resolução de 2048 x 1536 *pixels*.

A fotografia é adquirida com o paciente sentado na cadeira de exames, o rosto deve está centralizado a cerca de 40-50cm de distância da máquina fotográfica. A luz da sala permanece ligada, mas sem o foco de luz complementar. Pede-se para o paciente olhar para uma figura acomodativa presa lateralmente à objetiva da câmera fotográfica. O *flash* deve está ativado para gerar o brilho, ou primeira imagem de Purkinje. Já a função macro é utilizada para garantir a focalização perfeita da imagem adquirida, mesmo o paciente estando próximo a uma distância de 40-50cm da câmera. Caso o paciente utilize lentes corretivas, a foto será adquirida com as mesmas. A Figura 3.1 ilustra a aquisição da fotografia da face do paciente realizada no consultório oftalmológico.



Figura 3.1: Aquisição da fotografia da face do paciente.

A base total de imagens adquiridas para testes é formada por 45 imagens contendo fotos de pacientes de ambos os sexos e variadas idades, com ou sem lentes corretivas. Dos 45 pacientes, 15 foram diagnosticados pelo especialista como estrábicos.

3.3 Metodologia Proposta

A detecção do estrabismo em imagens digitais depende da localização precisa do limbo e do brilho gerado nas imagens. Sendo assim, para atender tais necessidades,

a metodologia proposta está organizada em quatro etapas, representada na Figura 3.2.

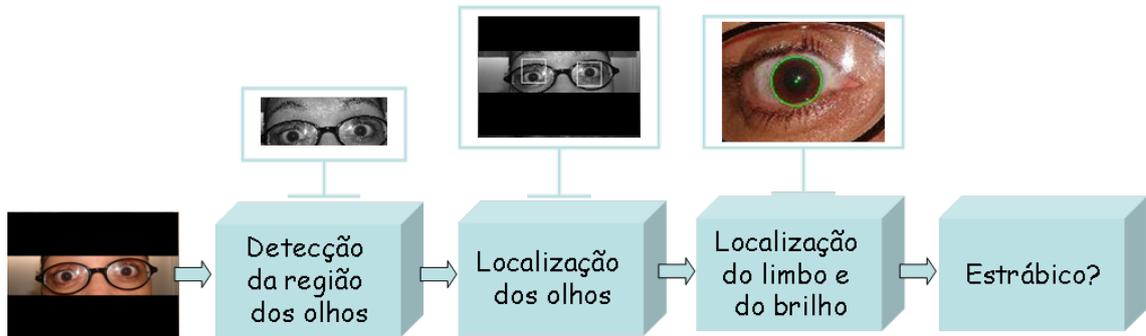


Figura 3.2: Etapas da Metodologia proposta pelo trabalho

A primeira etapa da metodologia visa obter a região dos olhos para minimizar o espaço de busca e excluir regiões que não interessam à metodologia. Em seguida, é realizada a localização precisa dos olhos restringindo mais ainda o espaço de busca. Na terceira etapa é realizada a localização do limbo e do brilho, e por último temos a decisão se o paciente possui ou não estrabismo. Nas próximas seções discutiremos sobre cada uma dessas etapas.

3.3.1 Detecção da Região dos Olhos

A Figura 3.3 representa os passos realizados na detecção automática da região dos olhos. As letras que referenciam cada fase na Figura 3.3 serão utilizadas entre parênteses nos parágrafos seguintes no decorrer da explicação.

A etapa inicial de detecção automática da região dos olhos visa reduzir o espaço de busca gerando uma subimagem com a possível região dos olhos e excluindo regiões que não tem interesse (boca, nariz, cabelos e plano de fundo), para facilitar a etapa seguinte de localização dos olhos. A metodologia é iniciada com a aquisição da imagem, descrita na Seção 3.2.2, seguida do redimensionamento da imagem de 2048×1536 *pixels*, resolução original, para um resolução dez vezes menor de 205×154 *pixels* visando minimizar o custo computacional do processamento da imagem. Esta imagem reduzida é utilizada apenas até a fase de localização dos olhos, uma vez que na fase de localização do limbo necessita-se de uma imagem com maior resolução para não perder dados da imagem prejudicando, conseqüentemente, a

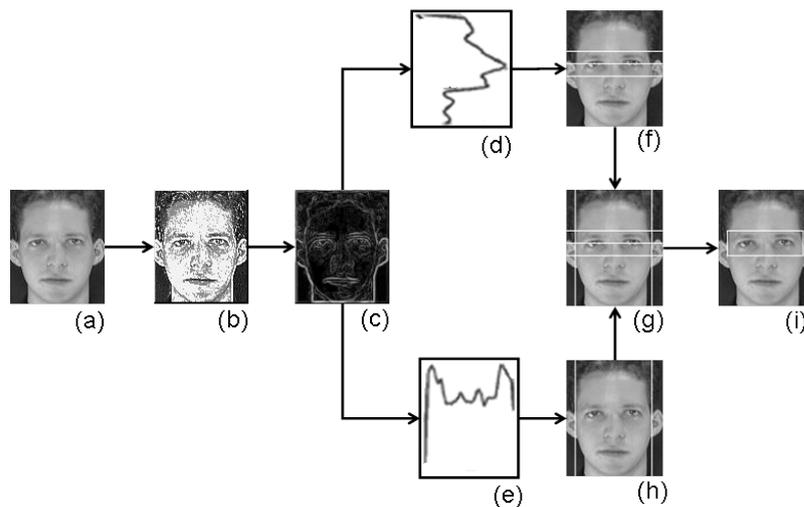


Figura 3.3: Etapas de detecção da região dos olhos

fase de localização do limbo e do brilho.

A imagem também é convertida de colorida, modelo de cor RGB, para níveis de cinza (a), pois é mais fácil e eficiente computacionalmente trabalhar em um canal do que em três canais. Na conversão dos canais RGB para um único canal (níveis de cinza) utiliza-se a Equação 3.1 na qual, NC é a imagem convertida em nível de cinza, R é a canal da primitiva vermelho, G da primitiva verde e B da primitiva azul.

$$NC = 0,299 * R + 0,587 * G + 0,114 * B \quad (3.1)$$

Após as conversões é aplicada a filtragem homomórfica (b), descrita na Seção 2.5.1, para solucionar divergências de luminosidade. Os fatores multiplicativos α e β , utilizados no filtro foram respectivamente, 0,9 e 1,1. As máscaras dos filtros passa-alta e passa-baixa foram, respectivamente, as ilustradas nas Figuras 3.4a e 3.4b. Esses parâmetros não foram escolhidos ao acaso. Estes, são os mesmos utilizadas na literatura (MELO *et al.* 2005).

Na etapa seguinte, é feita uma suavização da imagem utilizando o filtro gaussiano de máscara 3 x 3 em seguida, o gradiente da imagem de entrada (c), gerada na fase anterior, é calculado utilizando filtro de Sobel (GONZALEZ and WOODS 1992).

É aplicada uma projeção horizontal desse gradiente (d) obtendo como

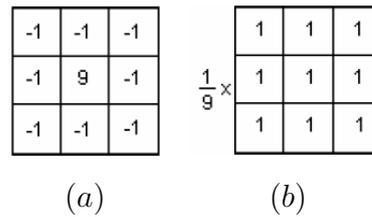


Figura 3.4: Máscaras utilizadas no filtro homomórfico (a) máscara do passa-alta, (b) máscara do passa-baixa.

resultado a média dos três maiores picos dessa projeção. É relevante saber que os olhos encontram-se na parte superior da face e que juntos com as sobrancelhas correspondem aos 2 picos mais próximos um do outro. Esta informação fisiológica, conhecida *a priori*, pode ser utilizada para se identificar a área de interesse, o pico da projeção horizontal irá fornecer a posição horizontal dos olhos. Ao mesmo tempo, aplica-se uma projeção vertical (e) na imagem do gradiente. Existem dois picos à esquerda e à direita que corresponde aos limites da face. Desses dois limites é estimado o comprimento da face (h). Combinando-se os resultados das projeções (g) obtemos as coordenadas da imagem que representa a região dos olhos (i).

3.3.2 Localização dos Olhos

As etapas propostas para a localização dos olhos, na região segmentada na fase anterior, seguem a sequência representada pela Figura 3.5.

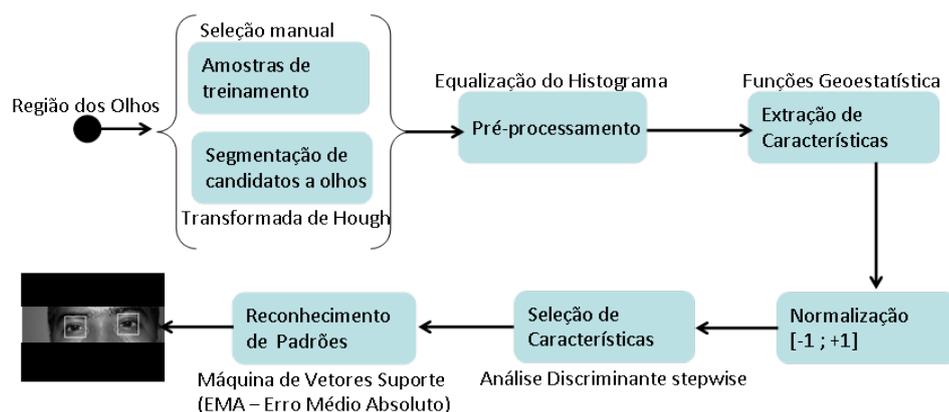


Figura 3.5: Etapas de localização dos olhos.

Por utilizar técnicas de reconhecimento de padrões, a localização dos olhos

é realizada em duas fases: treinamento e teste. Na etapa de treinamento é criado o modelo de classificação, enquanto que na fase de testes as amostras são classificadas através do modelo treinado. A única diferença na execução das mesmas são as amostras utilizadas nas fases seguintes. Para treinamento, foram selecionadas 1008 amostras de 28 imagens de pacientes, sendo 18 regiões de olho, 9 de cada olho, e 18 regiões de outras áreas da face. Ou seja, para cada imagem utilizada no treinamento foram extraídas, manualmente, 36 amostras formadas por uma janela de 30 x 30 *pixels*.

Para teste, as amostras são detectadas automaticamente através da transformada de Hough, que foi aplicada para localizar os candidatos a olhos usando intervalos de raios⁷ de 4 a 10 *pixels*. São extraídas 6 coordenadas com mais votos no vetor de acumulação da primeira e segunda metade da imagem, correspondendo respectivamente, aos candidatos a olho direito e esquerdo.

Em seguida, as amostras passam por um pré-processamento através da equalização do histograma. As regiões de interesse depois do pré-processamento da etapa anterior são submetidas à etapa de extração de características de textura. Este trabalho utiliza as funções geoestatísticas para descrever a textura de objetos representantes de olhos e de outras áreas da face, retirados de imagens de faces. As funções utilizadas são: correlograma, covariograma, semivariograma e semimadograma.

Extração de Características

Os parâmetros usados pelas funções geoestatísticas para extração das características em cada amostra foram, as direções 0°, 45°, 90° e 135° com tolerância angular de 22,5° e incremento de *lag* (distância) igual a 1, 2 e 3 correspondendo a 29, 14 e 9 *lags* e tolerância de cada distância de *lag* igual a 0,5, 1,0 e 1,5, respectivamente. As direções adotadas são as mais utilizadas na literatura para análise de imagens, já para escolher a tolerância de *lag* segundo (ISAACS and SRIVASTAVA 1990) a escolha mais comum é adotar a metade do incremento de *lag*.

Na Figura 3.6, temos a ilustração da maneira como as distâncias e direções

⁷Os intervalos de raios considerados neste trabalho foram determinados através de análise realizada no banco de imagens usado nos testes.

do *lag* são utilizadas. Supondo que essa imagem seja de 30×30 *pixels*, que é o tamanho da janela utilizada, o máximo de *lags* que teremos em qualquer das quatro direções para $d = 1$ será 29, $d = 2$ será 14 e $d = 3$ será 9 justificando assim, a presença desses valores nos parâmetros.

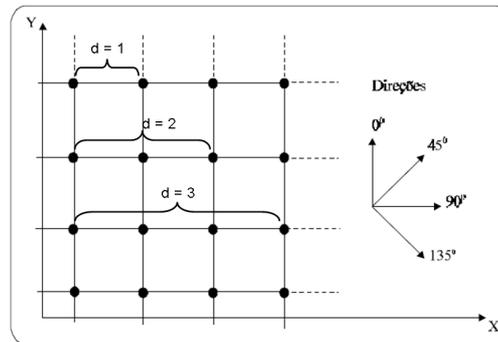


Figura 3.6: Distâncias e direções dos *lags*. Adaptada: (CAMARGO 1998).

Para criação do Vetor de Características (VC), que representa a assinatura da amostra, foram extraídas 208 características por amostra correspondentes as 4 direções de 52 *lags* ($29 + 14 + 9$) para cada função geoestatística. Uma combinação de todas as quatro funções geoestatísticas utilizadas neste trabalho resulta num VC de 832 características (4×208). Antes de realizar a seleção de características as mesmas passam por um processo de normalização para uma faixa de valores comuns como -1 à $+1$. Esse mecanismo facilita o classificador a convergir com maior facilidade na etapa de treinamento. Além de padronizar a distribuição de valores das variáveis, as quais podem assumir diferentes domínios.

Seleção de Características

As extrações de características realizadas pelas funções geoestatísticas geram muitas variáveis. A abordagem adotada para extração de textura usando covariograma, correlograma, semivariograma e semimadograma geram cada um 208 variáveis e uma combinação de todas elas gera 832 variáveis. Por termos tantas variáveis faz-se necessária a redução de dimensionalidade. Esse procedimento busca um bom desempenho do classificador na etapa posterior.

Para realizar a seleção das características que melhor discriminam as classes olho e não-olho (outras áreas da face) para as bases de características usadas, esse

trabalho utiliza a técnica Análise Discriminante *stepwise* apresentada na Seção 2.7. A aplicação da técnica gera um conjunto específico de variáveis apresentando menos redundâncias que poderiam prejudicar o classificador durante a etapa de generalização.

Reconhecimento de Padrões

A etapa final consiste em classificar cada objeto em olho ou não olho utilizando técnicas de reconhecimento de padrões (Seção 2.8) de acordo com a análise de textura obtida pelas funções geoestatísticas (Seção 2.6), após a etapa de seleção de características feita pela Análise Discriminante *stepwise* (Seção 2.7). Esta metodologia utiliza MVS (Seção 2.8.1) para classificar as regiões extraídas em olho ou não olho de acordo com a informação de textura obtida nas etapas anteriores. A Figura 3.7 ilustra o fluxo de atividades realizadas durante a fase de reconhecimento de padrões.

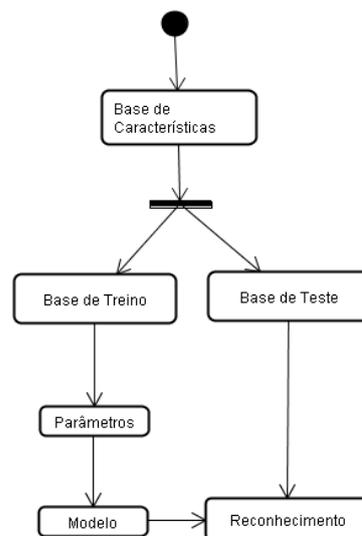


Figura 3.7: Fluxo de atividades realizadas durante a etapa de classificação desde a base de características originais, estimação de parâmetros e reconhecimento de padrão. Adaptada: (BRAZ JUNIOR 2008)

A base de imagens usada para treinamento e teste do classificador MVS é composta, respectivamente, pelas amostras selecionadas manualmente de imagens de 28 pacientes e pelos candidatos a olhos identificados pela aplicação do método

de Hough após a detecção de região nas imagens submetidas para teste. Cada objeto de treinamento teve suas medidas de textura extraídas e foi rotulado de acordo com a sua classe gerando uma base de características. Já os objetos de teste são rotulados de acordo com o resultado da classificação.

Nesta etapa fizemos utilização da biblioteca LIBSVM (CHANG and LIN 2003), que tem como objetivo ajudar usuários a usar MVS facilmente como uma ferramenta. Um tópico relevante sobre LIBSVM é que a mesma tenta ajudar as pessoas que nunca treinaram uma MVS antes. Para esta finalidade há dois *scripts python* - *grid.py* e *easy.py* - no “diretório de ferramentas”.

A MVS é utilizada com o núcleo radial (RBF). Existem dois parâmetros que devem ser configurados, quando está se utilizando o *kernel* RBF: C e γ . Não se sabe anteriormente qual C e γ é melhor para o problema, sendo assim, algum tipo de modelo de seleção (parâmetros de busca) deve ser feito. O objetivo é identificar o melhor C e γ de forma que o classificador possa prever dados desconhecidos com precisão.

É comum separar dados de treinamento em duas partes, sendo que uma é considerada desconhecida no treinamento do classificador. Então a precisão da predição, neste conjunto, pode refletir mais precisamente no desempenho da classificação de dados desconhecidos. A validação cruzada é a versão melhorada deste procedimento.

Como exemplo de validação cruzada, podemos citar a validação cruzada *v-fold*⁸, onde primeiramente divide-se o conjunto de treinamento em v subconjuntos de tamanhos iguais. Em seguida, um subconjunto é testado usando o classificador treinado no restante do subconjunto $v - 1$. Assim, cada exemplo do conjunto de treinamento inteiro é predito uma vez que a precisão da validação cruzada é a porcentagem de dados que são classificados corretamente (CHANG and LIN 2003). Neste trabalho, utiliza $v = 10$, ou seja, temos os dados de treinamento organizados em 10 grupos. Este parâmetro não foi escolhido ao acaso, é comumente utilizado na literatura.

Para construir o modelo, descrevemos um conjunto de classes pré-determinadas, para o qual cada exemplo é considerado como pertencente a uma classe pré-definida, determinada pelo rótulo de seu atributo-classe; o conjunto de

⁸Número de grupos que o conjunto de dados de aprendizado é particionado.

exemplos usado na construção do modelo é o conjunto de treinamento, e o modelo pode ser representado por regras de classificação, árvores de decisão ou fórmulas matemáticas.

O reconhecimento encerra-se com o treinamento e testes da MVS gerando a localização dos olhos, configurada com os parâmetros C e γ para cada conjunto de amostras submetidas ao processo. Após o reconhecimento, se necessário, realiza-se o cálculo da similaridade entre as regiões classificadas como olho usando o Erro Médio Absoluto (Seção 2.8.2).

Similaridade - Erro Médio Absoluto

A similaridade é utilizada para localizar apenas as duas regiões correspondentes ao olho direito (OD) e ao olho esquerdo (OE) quando existirem mais de uma região classificada pela MVS. É usada também, para tentar localizar o olho correspondente dentre os candidatos quando for localizado apenas um dos olhos. Por exemplo, supondo que a MVS tenha classificado apenas OD, buscamos então encontrar o maior pico na matriz de acumulação localizado dentro de uma área de 5 *pixels* acima, abaixo e à esquerda de OD. Encontrado o maior pico, realiza-se uma nova classificação na MVS. Se o OE não for encontrado, realiza-se o cálculo da similaridade nesse mesmo espaço de busca na imagem em nível de cinza comparando-se a região de OD classificada pela MVS com as regiões candidatas a OE.

3.3.3 Localização do Limbo e do Brilho

Localização do Limbo

Nossa metodologia aplica o teste de Hirschberg automático a partir da imagem adquirida. Utiliza-se a localização do reflexo gerado pelo teste de Hirschberg como parâmetro de verificação do alinhamento de ambos os olhos. Para tal, aplicou-se o método de Canny, como técnica de realce de borda, e a Transformada de Hough (TH). Um bom resultado desta fase depende de que uma porcentagem razoável das bordas do limbo estejam bem definidas, para que a TH possa localizá-lo com maior precisão.

A metodologia é iniciada com a aquisição da imagem, descrita na Seção

3.2.2, seguida do redimensionamento da imagem de 2048 x 1536 *pixels*, resolução original, para um resolução de 819 x 614 *pixels* visando minimizar o custo computacional do processamento da imagem sem perder detalhes da borda do limbo. A imagem também é convertida de colorida, escala de cor RGB, para níveis de cinza.

As coordenadas dos olhos encontradas na fase anterior, Seção 3.3.2, são reescaladas para encontrar os valores correspondentes na resolução de 819 x 614. Sendo assim, as coordenadas x e y dos olhos são aumentadas em 4 vezes assim como a janela da região dos olhos, que é ampliada de 30 x 30 (Figura 3.8a) para 120 x 120 (Figura 3.8b). Em seguida, aplica-se o método de Canny configurado com parâmetros de 1,2 fator de derivação, máscara de 5 x 5 usada na função gaussiana, limite inferior de 100 e limite superior de 136. Na Figura 3.8c temos o resultado da aplicação do método de Canny sobre a Figura 3.8b.

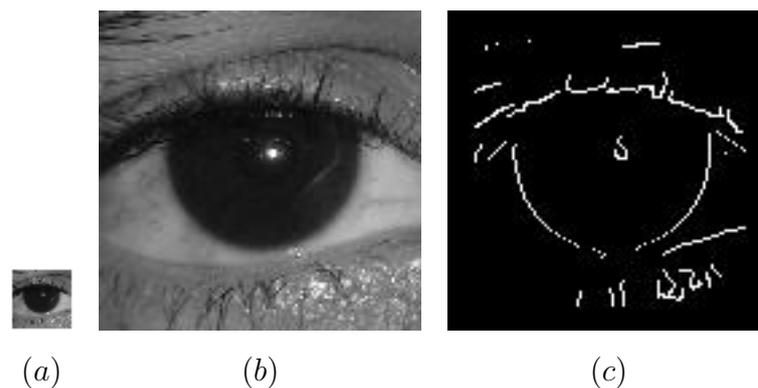


Figura 3.8: Aplicação do método de Canny (a) imagem de olho localizada 30 x 30, (b) imagem de olho reescalada para 120 x 120, (c) detecção de bordas.

Para determinar a localização das bordas do limbo é usada a técnica TH que utiliza o mapa de bordas gerado na fase anterior. Um bom resultado desta fase depende de que uma porcentagem razoável das bordas do limbo estejam bem definidas, para que a TH possa localizá-lo com maior precisão.

A Figura 3.9 ilustra a forma que a TH foi utilizada nesta fase para localizar o limbo. Foram considerados os pontos no intervalos de 0 a 60°, 300 a 360° correspondendo a uma abertura de 120° do lado direito do círculo desenhado nos pontos de bordas e 120 a 240° correspondendo a uma abertura de 120° no lado esquerdo. Os pontos fora destes intervalos foram excluídos do vetor de

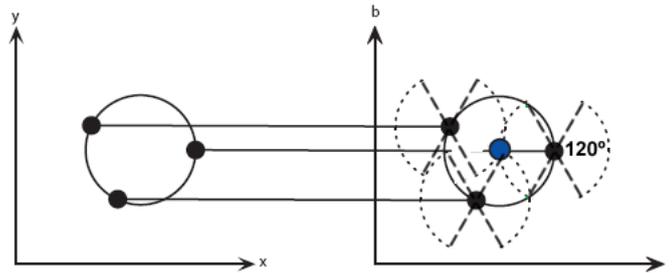


Figura 3.9: Aplicação da TH no círculo transformado do espaço x, y (à esquerda) para o espaço de parâmetros à direita.

acumulação. Com a realização desse procedimento excluimos a influência das pálpebras na localização do limbo. Na Figura 3.10 temos exemplo de paciente com olhos entreabertos.



Figura 3.10: Paciente com olhos entreabertos.

Para localizar a borda do limbo foram usados intervalos de raios⁹ de 15 a 37 *pixels*, onde seleciona-se, em seguida, as 80 coordenadas¹⁰ mais votadas dentro do vetor de acumulação. As coordenadas são ordenadas considerando-se a votação. Em seguida, separa-se a coordenada mais votada e verifica-se dentre as coordenadas seguintes, ordenadas, se existem outras com a mesma quantidade de votos. Caso exista, considera-se a que tiver menor raio. Com isso, buscamos garantir a escolha de uma região circular. Esse processo é realizado para os limbos direito e esquerdo.

Tendo os dois principais candidatos a limbos, chamados por exemplo de limbo direito (L_d) e limbo esquerdo (L_e) com raios R_d e R_e , respectivamente. Verificamos se a diferença entre R_d e R_e é maior que 2 *pixels*, visto que os limbos devem apresentar raios próximos. Se existir diferença, tomamos o menor como

⁹Os intervalos de raios considerados neste trabalho foram determinados através de análise realizada no banco de imagens usado nos testes.

¹⁰Esse número foi escolhido depois da realização de alguns testes.

referência. Considerando R_d menor buscamos dentro os mais votados no vetor de acumulação de L_e o primeiro raio que apresentar diferença de no máximo 2 *pixels* em relação ao R_d . Em seguida, verificamos se existem mais picos com o raio igual a R_e . Caso exista, escolhemos dentre os que tiverem raios iguais a R_e , o que apresentar alinhamento mais próximo em relação ao eixo horizontal do L_d . Com isso, garantimos a localização precisa de ambos os Limbos.

Localização do Brilho

A TH foi aplicada inicialmente para detectar o centro e o raio do limbo em ambos os olhos na imagem segmentada. Em seguida, aplica-se novamente a TH dentro da região detectada anteriormente para localizar o centro do reflexo. Para localizar o brilho foram usados intervalos de raios de 2 a 4 *pixels* e considerados todos os pontos dos círculos desenhados no mapa de bordas e projetados no espaço de Hough (vetor de acumulação). Em seguida, seleciona-se as 80 coordenadas¹¹ mais votadas dentro do vetor de acumulação. As coordenadas são ordenadas considerando-se a votação.

Tomando como exemplo a localização do brilho do olho direito. Verifica-se dentre os 6 maiores picos no vetor de acumulação qual deles está mais próximo do centro do limbo direito, considerando as coordenadas (x,y). Com isso, garantimos que a localização do limbo não caia na região das pálpebras, quando os olhos estiverem entreabertos, ou que não seja confundido com reflexos gerados por lentes corretivas. Esse procedimento é realizado para localizar o brilho dos olhos direito e esquerdo.

3.3.4 Detecção do Estrabismo

Para detectar o estrabismo utiliza-se a localização do reflexo luminoso corneano ou primeira imagem de Purkinje gerada pelo teste de Hirschberg (Seção 2.3.1) e a localização do limbo como parâmetros de verificação do alinhamento de ambos os olhos.

Como o objetivo deste estudo é criar uma maneira fácil, ágil e barata de se avaliar de forma automatizada a possibilidade de alguém ter estrabismo, para

¹¹Esse número foi escolhido depois da realização de alguns testes.

que seja acessível a oftalmologistas generalistas ou não subespecializados em estrabismo, pressupõe-se que não seja viável qualquer método que requeira a mensuração do ângulo Kappa¹² em cada olho, ceratometria¹³ e/ou ceratoscopia¹⁴ e tampouco o comprimento axial de cada globo ocular, como feito em outros estudos (ROMANO 2006)(HASEBE *et al.* 1998). Neste contexto, o máximo que se admite é considerar a refração de cada um dos olhos ao se analisar as fotografias, por ser um dado básico e de simples aferição por qualquer médico oftalmologista. Desta maneira, foi idealizada a avaliação do posicionamento da primeira imagem de Purkinje, em cada um dos olhos, da seguinte forma:

1. Mede-se a distância do centro do reflexo para o centro do limbo na direção vertical (DV) e horizontal (DH);
2. Avalia-se, também, o diâmetro corneano a 180° e compara-se com o do outro olho;
3. Não havendo diferença nos diâmetros, faz-se a comparação das DH e DV dos olhos;
4. Existindo diferença nos diâmetros corneanos, calcula-se a proporção da descentração do reflexo no olho não-fixador em relação ao posicionamento do reflexo no olho fixador, com base na diferença de diâmetro das duas córneas, conforme explicado em seguida:

Supondo-se que o diâmetro da córnea do olho direito (OD) seja 11 *pixels* e do olho esquerdo (OE) 11,5 *pixels*. Então 1,0 *pixel* de reta traçada na córnea do OE será igual a “X *pixels*” no OD. Aplicando-se uma regra de três, tem-se:

$$11,5 \text{ pixels} \longleftrightarrow 11,0 \text{ pixels}$$

$$1,0 \text{ pixel} \longleftrightarrow X \text{ pixels}$$

Logo, $X = (11,0 * 1,0) / 11,5 \implies X = 0,956$. Sendo assim, cada *pixel* de deslocamento em linha reta, considerado na córnea do OE, equivale a

¹²Ângulo formado pelo eixo óptico e a linha de mirada

¹³Exame computadorizado realizado para medir a curvatura da superfície corneana.

¹⁴A Ceratoscopia ou Topografia Computadorizada de córnea, é o exame indicado através do qual uma análise qualitativa e quantitativa do astigmatismo corneano pode ser realizada.

0.956 do mesmo deslocamento na córnea do OD. Então, as DH e DV do OE deverão ser multiplicadas por 0,956, constante de proporcionalidade corneana OD/OE (CPC), antes de serem comparadas com as respectivas distâncias tomadas no OD.

Assim, é possível mensurar o posicionamento da primeira imagem de Purkinje, levando-se em consideração diferenças no tamanho da córnea em ambos os olhos. Passa-se a considerar, inclusive, diferenças de erros refracionais (anisometropias) dispensando-se o uso de lentes de contato, quando do registro fotográfico de anisométricos. Isto porque, qualquer incremento ou diminuição no tamanho da córnea, dado artificialmente por uma lente corretora de equivalente esférico elevado, será descontado ao se calcular a CPC entre os olhos, para aquela imagem captada sob a influência do poder dióptrico das lentes corretoras em uso.

Como o maior problema na avaliação destes pacientes pelo método proposto é a anisometropia, já que diferenças de tamanho ou curvatura de córnea, ou do comprimento axial não são tão significativas na maioria dos estrábicos, resolvendo-se este problema, pode-se pretender que o método proposto seja aplicável à maioria dos pacientes em questão.

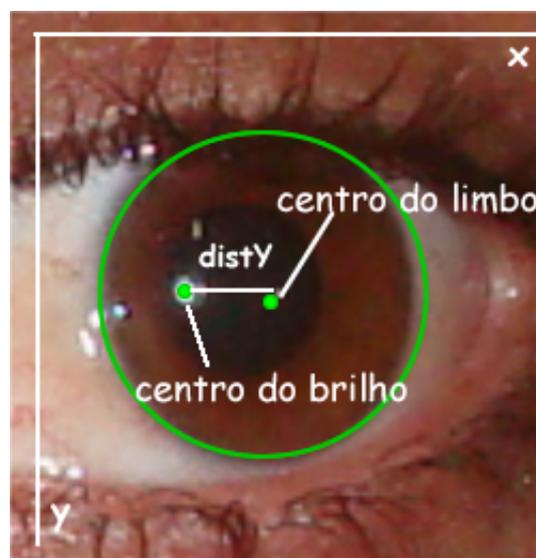


Figura 3.11: Cálculo do alinhamento.

Conforme ilustrado na Figura 3.11, são calculadas as distâncias, em *pixels* para cada olho, do centro do reflexo ao centro do limbo na direção vertical e

horizontal, representadas respectivamente por $distX$ e $distY$. Para diagnosticar o alinhamento, multiplica-se a CPC pelas distâncias, $distX$ (distância calculada em relação ao eixo x) e $distY$ (distância calculada em relação ao eixo y), do olho de maior limbo, substituindo as distâncias por estas. Em seguida, calcula-se a diferença absoluta das distâncias entre os olhos tanto na horizontal (DIFH) quanto na vertical (DIFV).

A aplicação do método de Hirschberg apresenta uma diferença de 2 a 4° do eixo visual em relação ao eixo anatômico, isso pode ocasionar uma impressão de falso desvio horizontal. Sendo assim, definimos pontos de cortes, ou limiares de até 1,0 *pixel* de DIFV e 2,0 *pixels* de DIFH para que um paciente seja considerado normal. O limiar de DIFV é menor que o DIFH porque os desvios verticais possuem efeito estético pior que os horizontais.

3.3.5 Validação de Resultados

Realizada a detecção de estrabismo através da análise de textura e MVS, é necessário validar os resultados e discutir possíveis melhorias. Para tanto, essa metodologia usa as técnicas de análise de sensibilidade, especificidade, acurácia, valor preditivo positivo e valor preditivo negativo apresentadas na Seção 2.9. Essas são as métricas comumente utilizadas em sistemas CAD/CADx e aceitas pela comunidade para análise de desempenho de sistemas baseados em processamento de imagem.

Com essas métricas, esse trabalho pretende medir o desempenho da metodologia como satisfatório ou não. Também pretende apontar pontos positivos e negativos para indicar futuras melhorias.

3.4 Resumo

Neste capítulo, tratamos inicialmente sobre as ferramentas de *software* e *hardware* utilizadas na elaboração deste trabalho. Em seguida, discorreremos sobre a formação do banco de pacientes baseado nos critérios de inclusão e exclusão, além dos exames realizados nestes pacientes e do protocolo seguido durante a aquisição das imagens.

Por último, apresentamos a metodologia elaborada que foi dividida em quatro

fases: detecção da região dos olhos, localização dos olhos, localização do limbo e do brilho e por último, a identificação do estrabismo.

Na primeira fase obtemos a região dos olhos através da aplicação de projeções na magnitude do gradiente visando minimizar o espaço de busca. Na segunda fase, é realizada a localização dos olhos através da classificação no MVS utilizando as funções geoestatísticas como características de textura, buscando localizar os dois olhos. Na penúltima fase, localizamos o limbo e o brilho utilizando o detector de bordas de Canny e a transformada de Hough. Na última fase, identificamos a presença ou não de estrabismo através da verificação do alinhamento de ambos os olhos.

Resultados e Discussão

Este capítulo apresenta e discute os resultados obtidos pela metodologia proposta baseada no teste de Hirschberg para detecção de estrabismo a partir de fotografias de imagens digitais. São discutidos os resultados das fases de detecção da região dos olhos; localização dos olhos; localização do limbo e do brilho e detecção do estrabismo.

Nas fases de detecção da região dos olhos e localização dos olhos foi utilizado para testes e comprovação da metodologia, além da base de imagens de pacientes, o banco de imagens ORL (CAMBRIDGE 2009).

4.1 Detecção da Região dos Olhos

4.1.1 Testes com o Banco ORL

Inicialmente foram testadas 400 imagens da base ORL com dimensões de 92 x 112 em níveis de cinza, formada por 40 pessoas com diferentes expressões faciais, estilos de cabelos, condições de iluminação, com e sem óculos. Para estas, foi possível detectar a região em 81,5% das imagens, ou seja, 327 imagens. A Figura 4.1 apresenta exemplos de regiões detectadas com sucesso. Já a Figura 4.2 ilustra exemplos de imagens para as quais não foi possível detectar com sucesso a região dos olhos. Foi observado que a maioria dos erros ocorreram devido ao posicionamento da face, principalmente quando o rosto estava voltado para os lados, e pelos variados tipos de armações de óculos e penteados de cabelo.



Figura 4.1: Região dos olhos detectadas corretamente (ORL).

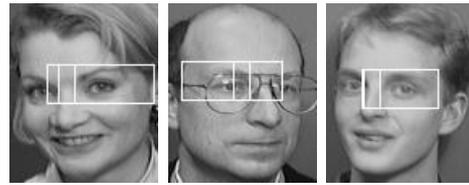


Figura 4.2: Falha na detecção da região dos olhos (ORL).

Mais detalhes podem ser consultados no artigo aceito na “International Conference on Computer Vision Theory and Applications” (VISAPP 2010) no qual foi desenvolvida uma metodologia para detecção automática de olhos em imagens de faces humanas, da base ORL, utilizando função de correlograma e máquinas de vetores suportes. Padrões de regiões dos olhos e regiões de outras áreas da face são representados através da função correlograma para discriminar com precisão a localização dos olhos (ALMEIDA *et al.* 2010).

4.1.2 Testes com as imagens de pacientes

Para o banco de imagens de pacientes, formado por 45 imagens, obteve-se taxa de acerto de 100% na detecção da região dos olhos. Nas Figuras 4.3a e 4.3b temos alguns exemplos da realização da detecção automática da região dos olhos.

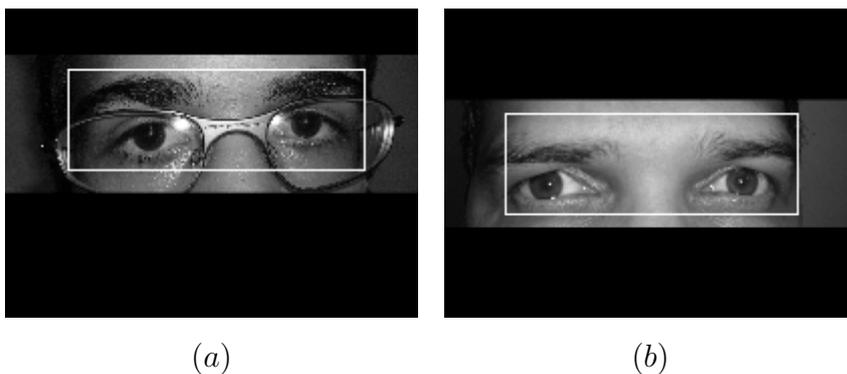


Figura 4.3: Detecção automática da região dos olhos dos pacientes.

4.2 Localização dos Olhos

Com a redução do espaço de busca alcançado através da detecção automática das região dos olhos, iniciou-se a etapa de localização dos olhos (Seção 3.3.2). Assim como na fase anterior, foram realizados testes preliminares com imagens da base ORL para validar a extração de característica através das funções geoestatísticas e da classificação usando MVS.

4.2.1 Testes com o Banco ORL

Foram selecionadas, aleatoriamente, 164 imagens da base ORL para treinamento da MVS, que equivalem a 50% das 327 imagens que tiveram a região dos olhos detectadas corretamente. Para cada imagem submetida no treinamento foram retiradas 18 amostras de olhos e 6 amostras de não-olhos, totalizando 3984 amostras.

As amostras utilizadas no treinamento foram selecionadas manualmente, diferentemente das amostras de teste que foram selecionadas pela metodologia (Apêndice ??). Sendo assim, para avaliar a eficiência das medidas geoestatísticas utilizadas em conjunto com a MVS, a metodologia é aplicada nas 327 imagens nas quais a região dos olhos foi detectada corretamente. Da etapa de segmentação dos possíveis olhos resultaram 781 amostras para serem classificadas pela MVS treinada. O resultado do teste para o correlograma, que apresentou a melhor taxa de acerto, foi de uma taxa de sensibilidade igual a 93,3%, especificidade igual a 82,18% e acurácia igual a 89,39%. A combinação das funções obteve taxa de sensibilidade igual a 93,38%, especificidade igual a 81,27% e acurácia igual a 89,24%.

Maiores detalhes da metodologia aplicada no banco de imagens da ORL podem ser consultados em (ALMEIDA *et al.* 2010).

4.2.2 Testes com as imagens de pacientes

Conforme apresentada na Seção 3.2.2, a base de imagens de pacientes é constituída por 45 fotografias. A partir destas, foi formado o banco de treinamento apresentado na Seção 3.3.2 seguido da extração (Seção 3.3.2) e seleção de características (Seção 3.3.2), e do treinamento da MVS 3.3.2. A abordagem de

extração de características usando apenas uma das funções geoestatística gera um conjunto de 208 características, enquanto que utilizando uma combinação das quatro funções gera um total de 832 características.

Após a etapa de seleção de características usando análise discriminante *stepwise* obteve-se uma redução das características, estatisticamente significativa, para discriminar as classes de olhos e de não-olhos. A Tabela 4.1 apresenta o quantitativo da redução de característica para cada medida geoestatística e para uma combinação de todas elas.

| | total | redução |
|----------------|-------|---------|
| Semimadograma | 208 | 37 |
| Semivariograma | 208 | 29 |
| Correlograma | 208 | 17 |
| Covariograma | 208 | 30 |
| Todas | 832 | 59 |

Tabela 4.1: Quantidade de características selecionadas pela análise discriminante *stepwise* por medida geoestatística.

Utilizando as variáveis selecionadas, a base de treinamento composta por 1008 amostras de 28 imagens de pacientes foi treinada no classificador MVS. Os valores estimados para C e γ em relação ao núcleo radial são apresentados na Tabela 4.2. Estes valores foram obtidos para cada base de treinamento a partir da ferramenta *grid.py* do LIBSVM.

| | C | γ |
|----------------|-----|----------|
| Semimadograma | 32 | 0,5 |
| Semivariograma | 8 | 2 |
| Correlograma | 32 | 0,5 |
| Covariograma | 8 | 2 |
| Todas | 8 | 0,5 |

Tabela 4.2: Parâmetros C e γ estimados pelo *grid.py* para as amostras de treinamento.

Seguindo o fluxo da metodologia proposta na Seção 3.3.2, o passo seguinte

é a etapa de classificação e validação de resultados. Os resultados obtidos pelo classificador MVS usando os parâmetros acima estão relacionados na Tabela 4.3.

| | VP | VN | FP | FN | S (%) | E (%) | VPP (%) | VPN (%) | A (%) |
|----------------|-----|-----|----|----|-------|-------|---------|---------|-------|
| Semimadograma | 408 | 99 | 8 | 25 | 94,23 | 92,53 | 98,08 | 79,84 | 93,89 |
| Semivariograma | 392 | 90 | 16 | 42 | 90,32 | 84,96 | 96,08 | 68,19 | 89,26 |
| Correlograma | 383 | 76 | 29 | 52 | 88,05 | 72,38 | 92,96 | 59,38 | 85,00 |
| Covariograma | 369 | 70 | 31 | 70 | 84,06 | 69,30 | 92,25 | 50,00 | 81,30 |
| Todas | 411 | 103 | 5 | 21 | 95,14 | 95,38 | 98,78 | 83,07 | 95,19 |

Tabela 4.3: Resultados da classificação no MVS para as imagens de pacientes.

O melhor resultado obtido alcança sensibilidade de 95,14%, especificidade de 95,38% e acerto de 95,19% para a configuração da combinação de todas as funções geoestatística. As taxas de 98,78% de VPP e 83,07% de VPN indicam que esta abordagem conseguiu classificar as regiões de olhos com mais eficiência do que as regiões de outras áreas da face. Justificando assim, a utilização das funções geoestatísticas combinadas na fase de localização dos olhos, pois necessita-se que o classificador seja capaz de reconhecer os olhos nas amostras de testes não conhecidas previamente na etapa de treinamento.

A Figura 4.4 apresenta exemplos de imagens para as quais a metodologia, utilizando a combinação de todas as medidas, obteve êxito na localização dos olhos apresentando VP de 411. Já a Figura 4.5 apresenta exemplo em que a metodologia falhou obtendo FP de 5. Analisando os resultados observa-se que os erros ocorreram principalmente nas regiões de armações dos óculos.



Figura 4.4: Localização dos olhos realizada corretamente



Figura 4.5: Falha na localização dos olhos.

Analisando a classificação das regiões de não-olho, observa-se que a quantidade de VN e FN foram respectivamente 103 e 21. A Figura 4.6 apresenta exemplos de regiões de olho que foram classificadas como não-olho. Foi observado que a maioria dos erros ocorreram nas imagens de pacientes que apresentavam reflexos nas lentes dos óculos e nas imagens em que os olhos estavam entreabertos.

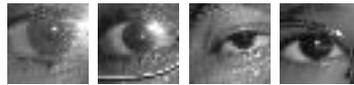


Figura 4.6: Regiões de olhos classificadas como não-olhos.

Tendo as regiões de olhos classificadas e seguindo a metodologia citada na Seção 3.3.2 obteve-se 91,11% de acerto na localização de ambos os olhos, errando em apenas 4 imagens. A Figura 4.7, apresenta exemplos de imagens nas quais a localização dos olhos foi realizada corretamente.

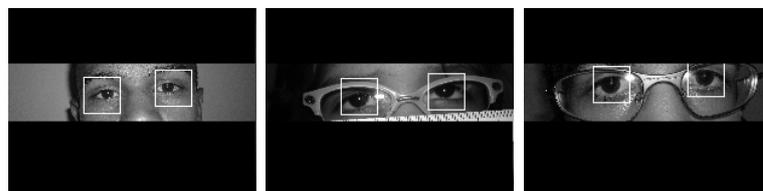


Figura 4.7: Exemplos de imagens em que a localização dos olhos foi realizada corretamente.

Já nas Figuras 4.8a, 4.8b, 4.8c e 4.8d, são apresentadas as imagens nas quais não foi possível localizar ambos os olhos corretamente. A seguir, são descritas as possíveis causas que direcionaram a metodologia ao erro.

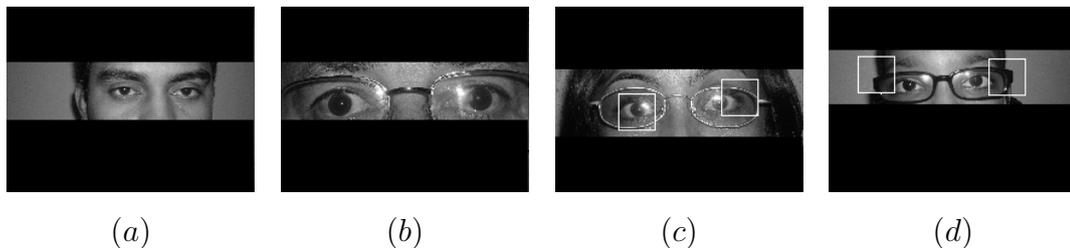


Figura 4.8: Exemplos de imagens em que metodologia falhou.

Analisando o resultado da Figura 4.8a, percebe-se na saída do vetor de acumulação, utilizado na TH, representado na Figura 4.9a que a metodologia não conseguiu localizar o olho esquerdo como candidato através da TH. No entanto, localizou o olho direito (Figura 4.9b) mas, errou na etapa de classificação na MVS. Não existindo, pelo menos um dos olhos classificado pela MVS não teria como localizar o outro olho pela metodologia descrita na Seção 3.3.2.

A segunda Figura a ser analisada é a 4.8b, na qual observa-se que não foi

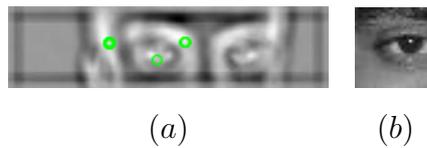


Figura 4.9: Análise da Figura 4.8a. (a) Imagem de saída do vetor de acumulação após aplicação da TH na imagem da região dos olhos. (b) Candidato a olho direito classificado erroneamente como não-olho no MVS.

possível identificar a região circular dos olhos através da TH e sim o canto central direito e esquerdo da armação dos óculos segundo ilustram as Figura 4.10a, 4.10b e 4.10c. Contudo, a classificação dos candidatos a olhos foi realizada corretamente, ou seja, as Figuras 4.10b e 4.10c que não representam os olhos foram classificadas como não-olhos. E também, por não ter pelo menos um dos olhos localizado a metodologia ignora a busca por novos candidatos.

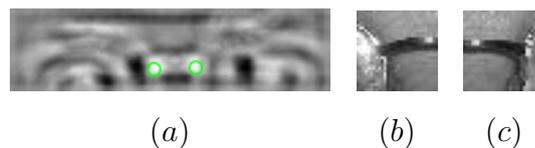


Figura 4.10: Análise da Figura 4.8b. (a) Imagem de saída do vetor de acumulação após aplicação da TH na imagem da região dos olhos. (b) e (c) candidatos a olhos direito e esquerdo, respectivamente, classificados corretamente como não-olho no MVS.

Já na Figura 4.8c, observa-se que o olho direito foi localizado corretamente pela metodologia que classificou a Figura 4.11 corretamente. No entanto ocorreu falha na classificação no candidato a olho esquerdo ilustrado na Figura 4.11c.

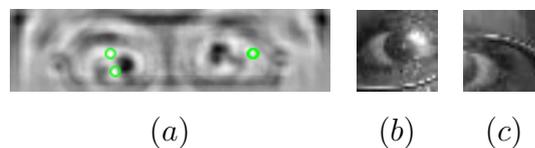


Figura 4.11: Análise da Figura 4.8c. (a) Imagem de saída do vetor de acumulação após aplicação da TH na imagem da região dos olhos. (b) Candidatos a olho direito classificado corretamente como olho. (c) candidatos a olho esquerdo classificados erroneamente como olho na MVS.

Por último, é discutido o resultado da Figura 4.8d. A Figura 4.12a, apresenta

a imagem de saída do vetor de acumulação após aplicação da TH na imagem da região dos olhos, nela percebe-se que a TH não conseguiu localizar a região circular dos olhos. A Figura 4.12b ilustra o candidato a olho esquerdo que foi classificado erroneamente pela MVS como olho. Na Figura 4.8d, observa-se a falha na localização do olho direito ocasionada pela aplicação da similaridade entre o candidato a olho direito e a amostra que foi classificada pela MVS.

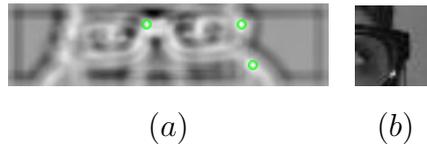


Figura 4.12: Análise da Figura 4.8d. (a) Imagem de saída do vetor de acumulação após aplicação da TH na imagem da região dos olhos. (b) Candidatos a olho esquerdo classificados erroneamente como olho pela MVS.

4.3 Localização do Limbo e do Brilho

Nesta etapa, considerando as 41 imagens que deram certo da etapa anterior, obteve-se taxa de acerto de 97,56% para localização do limbo em ambos os olhos, ou seja, a metodologia errou em apenas 1 das 41 imagens. Nas Figuras 4.13a e 4.13b são apresentados exemplos de imagens nas quais a metodologia localizou corretamente a região do limbo.

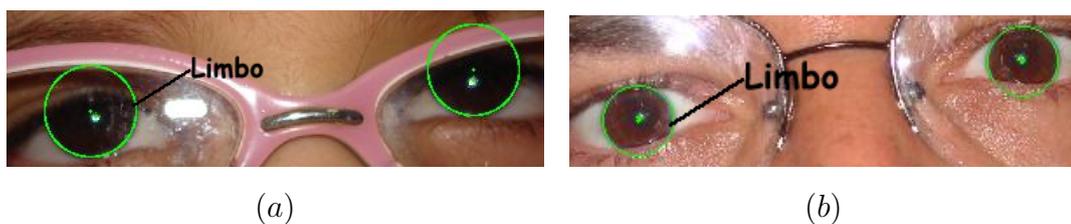


Figura 4.13: Exemplos de imagens nas quais a metodologia acertou na localização do limbo.

Na Figura 4.14, observa-se a imagem na qual a metodologia falhou na localização precisa do limbo em ambos os olhos. Analisando-a, percebeu-se que o erro ocorreu, principalmente, pela presença de reflexos luminosos na lente direita dos óculos encobrendo a região do limbo do paciente. Analisando a região visível

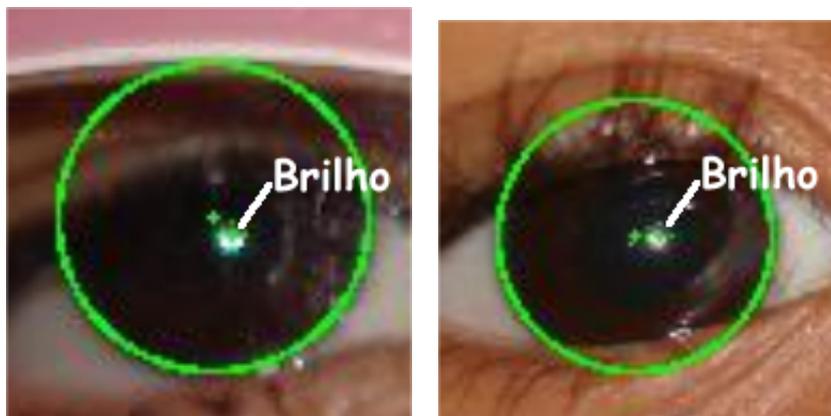
do limbo do olho direito (OD), a mesma apresenta raio menor que o do limbo do olho esquerdo (OE) e com diferença superior a 2 *pixels*. Sendo assim, considerando que a metodologia toma como referência o limbo menor, caso essa possibilidade ocorra, não teria como localizar corretamente o limbo do OE, mesmo ele estando visível e de fácil localização.



(a)

Figura 4.14: Imagem na qual a metodologia falhou na localização do limbo.

Considerando a localização do brilho nas 40 imagens provenientes da localização correta do limbo, obteve-se taxa de 100% para localização do brilho em ambos os olhos. Nas Figuras 4.15a e 4.15b temos exemplos de imagens nas quais a metodologia localizou corretamente o brilho.



(a)

(b)

Figura 4.15: Exemplos de imagens nas quais a metodologia acertou na localização do brilho.

4.4 Detecção do Estrabismo

Nesta seção, são apresentados os resultados alcançados na etapa de detecção do estrabismo. Serão considerados os 40 pacientes nos quais a metodologia localizou o limbo e o brilho na fase anterior.

Na Tabela 4.4 são relacionados os resultados finais alcançados pela metodologia no processamento das 40 imagens. Nela, são listados os valores em *pixels* do raio esquerdo (Re) e direito (Rd); da distância do alinhamento do brilho em relação ao centro do limbo na direção vertical (distX) e horizontal (distY) para cada olho; da constante de proporcionalidade corneana (CPC); a diferença de alinhamento vertical (DIFV) e horizontal (DIFH) entre os olhos; e exame do paciente pelo médico especialista e pela metodologia.

Analisando a Tabela 4.4, obtêm-se os valores VP=10, FP=4, VN=21 e FN=5 representados na matriz de decisão para determinar similaridades entre as respostas obtidas pelo especialista e pela metodologia desenvolvida (Tabela 4.5). A partir dos dados da matriz de confusão verifica-se que a metodologia alcançou 67% de sensibilidade, 84% de especificidade e 77,5% de acerto para as 40 imagens de pacientes. Sendo que, dos 9 erros que ocorreram, 7 foram causados pelas limitações do método de Hirschberg, que consegue identificar apenas os estrabismos estéticos, pois trabalha considerando o eixo anatômico do olho e não o eixo visual.

Nas Figuras 4.16a e 4.16b são apresentados exemplos de imagens dos olhos direito e esquerdo de um dos pacientes em que o teste de Hirschberg falhou, por possuir desalinhamento aparente. Neste caso, segundo o especialista o paciente não apresentava estrabismo, porém, a metodologia indicou desvio incluindo-o no grupo dos estrábicos. Dos 7 pacientes errados apenas 2 não apresentavam estrabismo, segundo o especialista. Esse erro, do método de Hirschberg, é justificado pelo fato de que não existe estrabismo quando um desvio aparente (pseudoestrabismo), causado por eixos pupilares angulados entre eles quando, na verdade, os eixos visuais acham-se corretamente posicionados relativamente ao objeto visado (BICAS 2009).

Já nas Figuras 4.17a e 4.17b são apresentados exemplos de imagens dos olhos direito e esquerdo de 1 dos 5 pacientes estrábicos em que o teste de Hirschberg falhou. Neste caso, segundo o especialista, o paciente apresentava estrabismo,

| paciente | OD | | | OE | | | Estrabismo | | | | |
|----------|----|-------|-------|----|-------|-------|------------|------|------|--------------|-------------|
| | Rd | distY | distX | Re | distY | distX | CPC | DIFH | DIFV | especialista | metodologia |
| 1 | 34 | 4 | 4 | 34 | 0 | 8 | 1 | 4 | 4 | sim | sim |
| 2 | 26 | 2 | 5 | 28 | 0,92 | 1,85 | 0,93 | 1,07 | 3,14 | não | sim |
| 3 | 33 | 1,87 | 1,88 | 31 | 1 | 0 | 0,93 | 1,87 | 0,87 | não | não |
| 4 | 25 | 3 | 1 | 25 | 0 | 3 | 1 | 3 | 2 | sim | sim |
| 5 | 30 | 3,73 | 0 | 28 | 3 | 0 | 0,93 | 0,73 | 0 | não | não |
| 6 | 34 | 4 | 2 | 34 | 4 | 1 | 1 | 0 | 1 | não | não |
| 7 | 31 | 2,80 | 3,74 | 29 | 0 | 4 | 0,93 | 2,80 | 0,25 | sim | sim |
| 8 | 32 | 6,78 | 1,93 | 31 | 3 | 1 | 0,96 | 3,78 | 0,93 | não | sim |
| 9 | 34 | 0,97 | 1,94 | 33 | 6 | 1 | 0,97 | 5,02 | 0,94 | não | sim |
| 10 | 27 | 3,85 | 0 | 26 | 3 | 0 | 0,96 | 0,85 | 0 | não | não |
| 11 | 28 | 1,92 | 0,96 | 27 | 1 | 0 | 0,96 | 0,92 | 0,96 | sim | não |
| 12 | 34 | 0 | 2 | 34 | 5 | 0 | 1 | 0 | 1 | não | não |
| 13 | 31 | 3,87 | 0 | 30 | 2 | 1 | 0,96 | 1,87 | 1 | não | não |
| 14 | 25 | 1,92 | 1,92 | 24 | 2 | 1 | 0,96 | 0,08 | 0,92 | não | não |
| 15 | 33 | 5,82 | 0 | 32 | 3 | 0 | 0,97 | 2,82 | 0 | sim | sim |
| 16 | 26 | 0 | 4 | 26 | 2 | 1 | 1 | 2 | 3 | sim | sim |
| 17 | 20 | 3,0 | 1,0 | 20 | 1,0 | 0 | 1,0 | 2,0 | 1,0 | não | não |
| 18 | 32 | 4 | 1 | 33 | 2 | 0 | 0,97 | 2 | 1 | não | não |
| 19 | 27 | 1 | 1 | 27 | 3 | 0 | 1 | 2 | 1 | não | não |
| 20 | 21 | 2 | 1 | 21 | 1 | 0 | 1 | 1 | 1 | não | não |
| 21 | 20 | 2 | 1 | 20 | 3 | 2 | 1 | 1 | 1 | não | não |
| 22 | 24 | 2 | 1 | 25 | 1,92 | 0,96 | 0,96 | 0,08 | 0,04 | não | não |
| 23 | 21 | 1,90 | 0 | 20 | 1 | 1 | 0,95 | 0,90 | 1 | sim | não |
| 24 | 18 | 2 | 0 | 18 | 3 | 2 | 1 | 1 | 2 | sim | sim |
| 25 | 23 | 2 | 4 | 23 | 1 | 2 | 1 | 1 | 2 | sim | sim |
| 26 | 20 | 1 | 2 | 20 | 1 | 1 | 1 | 0 | 1 | não | não |
| 27 | 25 | 2 | 2 | 25 | 1 | 2 | 1 | 1 | 0 | não | não |
| 28 | 19 | 2 | 0 | 19 | 0 | 0 | 1 | 2 | 0 | não | não |
| 29 | 21 | 1 | 0 | 21 | 1 | 0 | 1 | 0 | 0 | não | não |
| 30 | 23 | 1,91 | 0,95 | 22 | 2 | 3 | 0,95 | 0,08 | 2,04 | não | sim |
| 31 | 16 | 2 | 0 | 16 | 8 | 0 | 1 | 6 | 0 | sim | sim |
| 32 | 26 | 1 | 0 | 26 | 1 | 1 | 1 | 0 | 1 | sim | não |
| 33 | 22 | 1 | 1 | 23 | 1,91 | 0 | 0,95 | 0,91 | 1 | não | não |
| 34 | 21 | 2 | 0 | 21 | 2 | 1 | 1 | 0 | 1 | não | não |
| 35 | 22 | 3,82 | 0 | 21 | 5 | 2 | 0,95 | 1,18 | 2 | sim | sim |
| 36 | 24 | 0,95 | 0 | 23 | 0 | 0 | 0,96 | 0,96 | 0 | sim | não |
| 37 | 22 | 1 | 0 | 24 | 1,83 | 0 | 0,91 | 0,83 | 0 | não | não |
| 38 | 25 | 2 | 1 | 25 | 0 | 1 | 1 | 2 | 0 | sim | não |
| 39 | 24 | 2,87 | 0,95 | 23 | 2 | 1 | 0,95 | 0,87 | 0,04 | não | não |
| 40 | 19 | 1 | 2 | 20 | 0 | 0,95 | 0,95 | 1 | 1,2 | sim | sim |

Tabela 4.4: Resultado do processamento das 40 imagens de pacientes para verificação do alinhamento dos olhos comparados à análise do especialista.

porém, a metodologia não conseguiu identificar desalinhamento, incluindo-o no grupo dos pacientes normais. Nestes casos, o método de Hirschberg limita-se ao fato que pode haver um estrabismo, mascarado por um ângulo Kappa de sinal contrário, anulando a aparência de desvio e dando a noção de uma posição binocular adequada, embora haja o desvio (BICAS 2009).

Analisando a Tabela 4.4, desconsiderando os pacientes para os quais o método de Hirschberg não consegue avaliar corretamente, obtêm-se os valores VP=10, FP=2, VN=21 e FN=0 representados na matriz de decisão (Tabela 4.6). A partir dos dados da matriz de confusão verifica-se que a metodologia alcançou 100%

| Resultado | Estrabismo | |
|-----------|------------|----------|
| | Positivo | Negativo |
| Positivo | 10 | 4 |
| Negativo | 5 | 21 |

Tabela 4.5: Matriz de decisão utilizada para comparar as repostas do especialista com as da metodologia. (considerando os 40 pacientes).

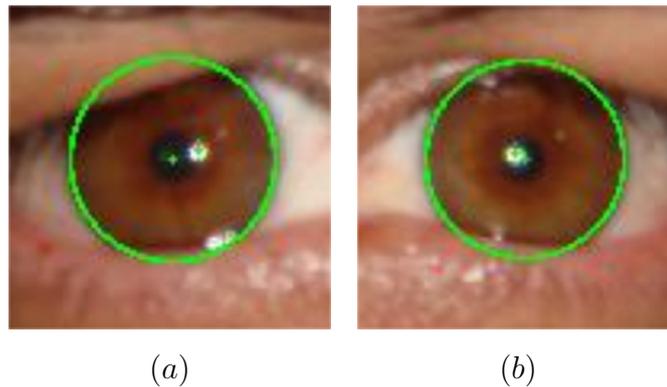


Figura 4.16: Imagens em que a aplicação do teste de Hirschberg falhou na identificação de paciente normal. (a) Olho direito. (b) Olho esquerdo.

de sensibilidade, 91,3% de especificidade e 94% de acerto para as 33 imagens restantes. Os 2 pacientes considerados como estrábicos, mesmo não sendo, foram julgados como tal devido ao erro de precisão na localização do limbo.

| Resultado | Estrabismo | |
|-----------|------------|----------|
| | Positivo | Negativo |
| Positivo | 10 | 2 |
| Negativo | 0 | 21 |

Tabela 4.6: Matriz de decisão utilizada para comparar as repostas do especialista com as da metodologia desconsiderando os pacientes para os quais o teste de Hirschberg não funciona.

As Figuras 4.18a, 4.18b, 4.18c e 4.18d, são as imagens dos pacientes em que o método falhou na precisão da localização do limbo.

Analisando a Figura 4.18a que representa o olho direito do paciente 2 da Tabela 4.4, percebe-se que a região do limbo não foi precisamente localizada, pois

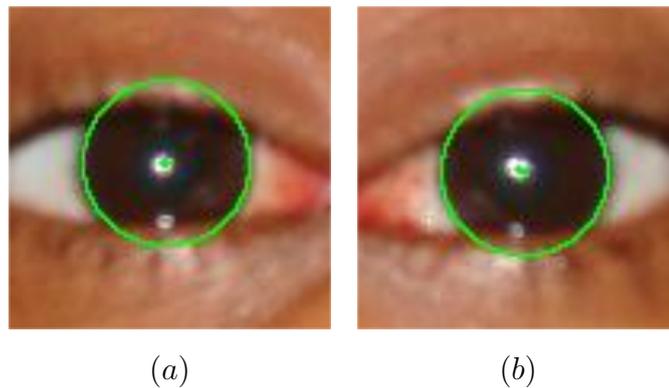


Figura 4.17: Imagens em que a aplicação do teste de Hirschberg falhou na identificação de paciente estrábico. (a) Olho direito. (b) Olho esquerdo.

o centro do limbo deveria está mais próximo do centro da pupila. Isso resultou no desalinhamento vertical do olho direito em relação ao olho esquerdo (Figura 4.18b) fazendo com que o resultado de DIFV igual a 3,14 indicasse a presença de estrabismo, contradizendo o diagnóstico do especialista.

Já na Figura 4.18d que representa o olho esquerdo do paciente 30 da Tabela 4.4, percebe-se que assim como no erro anterior, a região do limbo não foi precisamente localizada, existindo uma pequena sobra de limbo fora da região localizada. Isso provocou o surgimento do desalinhamento vertical do olho esquerdo em relação ao olho direito (Figura 4.18c) fazendo com que o resultado de DIFV igual a 2,04 indicasse a presença de estrabismo, contradizendo o diagnóstico do especialista.

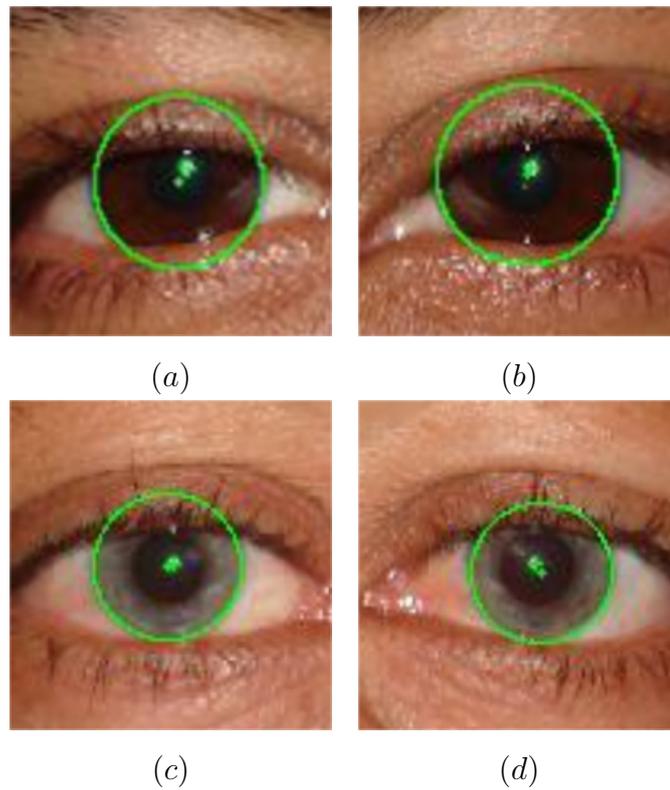


Figura 4.18: Imagens em que a metodologia falhou na localização precisa do limbo. (a) e (b) OD e OE do paciente 2. (c) e (d) OD e OE do paciente 30.

CAPÍTULO 5

Conclusão

O presente trabalho apresentou a viabilidade da utilização de técnicas de processamento de imagens, funções geoestatísticas e máquina de vetores de suporte para detecção automática de estrabismo em imagens digitais através do método de Hirschberg. A metodologia proposta foi organizada em quatro fases: localização da região dos olhos, localização dos olhos, localização do limbo e do brilho, e identificação automática do estrabismo.

No decorrer deste estudo podem ser observadas algumas contribuições. A primeira ocorre na fase de localização dos olhos, onde é usada uma combinação inovadora de técnicas (filtragem homomórfica, transformada de Hough, funções geoestatísticas, análise discriminante *stepwise*, MVS e a medida de similaridade EMA) para localizar olhos em faces humanas.

A segunda na fase de extração de características onde são usadas funções geoestatísticas com intuito de extrair informações da textura dos olhos que os discriminassem com precisão. A terceira e principal contribuição é a criação de uma metodologia de auxílio na identificação automática de estrabismo em imagens digitais.

No trabalho foram realizados testes para cada uma das quatro fases para comprovar a eficiência do método proposto. Todos os testes, com exceção da fase de identificação do estrabismo, foram feitos de forma visual, ou seja, uma pessoa analisou cada imagem e determinou se as imagens resultantes de cada fase foram computadas corretamente, verificando se a região dos olhos foi obtida corretamente na fase 1, se os olhos foram localizados na fase 2 e se o limbo e o

brilho foram localizados na fase 3.

A fase de detecção automática da região dos olhos utilizando as projeções na magnitude do gradiente obteve taxa de acerto de 100% para as imagens de pacientes. Nesta etapa, conclui-se que a utilização da filtragem homomórfica contribuiu para o acerto total, uma vez que a técnica ajusta a iluminação, deixando-a mais uniforme na imagem.

Na segunda fase, a metodologia obteve taxa de acerto de 95,19%, para as imagens de pacientes, e 89,24%, para as imagens da ORL, na utilização da combinação das quatro funções geoestatísticas como descritores de textura na extração de características. Entretanto, mesmo estes resultados sendo promissores, se faz necessário aumentar a variabilidade das amostras de faces para alcançar uma metodologia robusta e genérica. No entanto, visto o tamanho e o reconhecimento acadêmico da base de faces da ORL utilizada nos testes, pode-se concluir que os resultados obtidos impulsionam novas abordagens baseadas em funções geoestatísticas na descrição de textura da região dos olhos em imagens digitais de faces. Ainda na segunda fase, a metodologia obteve 91,11% de acerto para a localização de ambos os olhos das imagens de pacientes.

Na localização do limbo e do brilho, fase que utilizou o método de Canny e a transformada de Hough, foram alcançadas, respectivamente, taxas de 97,5% e 100% de acerto. Onde, conclui-se que o erro ocorrido na localização do limbo foi causado principalmente pelos reflexos luminosos gerados na aquisição da imagem do que pela própria metodologia.

O resultado para identificação do estrabismo foi de 77,5% de acerto para as 40 imagens que passaram da fase de localização do limbo e do brilho. Esse resultado teve influência direta de 7 imagens que não são aplicáveis ao teste de Hirschberg devido as limitações do mesmo a avaliação estética do estrabismo. No entanto, desconsiderando as imagens para as quais o teste de Hirschberg não é eficaz foi possível alcançar taxa de 94% de acerto.

Mesmo tendo potencial para ser aplicado como uma solução para auxiliar o especialista na identificação do estrabismo faz-se necessária a utilização de outras técnicas de detecção de estrabismo, uma vez que o teste de Hirschberg é o menos preciso comparado a outros métodos como o Krimsky e o Cover Test.

A quantidade de imagens de pacientes (30 saudáveis e 15 estrábicos) e sua

desproporção (mais saudáveis do que estrábicos) prejudicaram sensivelmente uma análise mais apurada do método proposto. Sendo assim, é necessária outra análise com uma base de imagens de pacientes maior e mais equilibrada. Também é importante utilizar outras imagens adquiridas com protocolo de aquisição diferente da estudada, para avaliar o comportamento da metodologia.

5.1 Trabalhos Futuros

As técnicas propostas neste trabalho foram incorporadas em uma ferramenta com o intuito de tornar o processo automático. No entanto, com o objetivo de aperfeiçoar o problema estudado, existem diversas atividades que podem dar continuidade ao trabalho e que serão listadas a seguir:

- Pesquisar outras funções geoestatísticas a serem utilizadas na extração das características. Como por exemplo, a função semiograma.
- O classificador MVS que desempenhou papel fundamental na classificação, pode ser trocado por algum outro classificador de maneira a avaliar o desempenho destes novos classificadores na tarefa de reconhecimento de padrões de olho e de outras áreas da face.
- A substituição da técnica de Canny por um outro algoritmo de detecção de bordas, visando melhorar a localização da borda e minimizar a quantidade de parâmetros exigido pela técnica de Canny. Como por exemplo, a utilização do algoritmo *watershed*.
- A realização do *Cover Test* computadorizado a partir da aquisição do vídeo da realização do exame. O *Cover Test* é um exame mais preciso além de possibilitar a aferição do desvio.
- A realização do planejamento cirúrgico do estrabismo a partir do diagnóstico gerado pelo método de Hirschberg e pelo *Cover Test*.

Por fim, a metodologia descrita nesse trabalho poderá integrar uma ferramenta CADx a ser aplicada em casos reais na identificação de estrabismo. Também poderá ser utilizada separada, utilizando-a por exemplo, até a segunda fase em aplicações que necessitem localizar os olhos.

Referências Bibliográficas

- AHRQ (2004). Screening for visual impairment in children younger than age 5 years. Technical report. Agency for Healthcare Research and Quality. Disponível em: <http://www.ahrq.gov/clinic/3rduspstf/visionscr/vischrs.htm>. Acesso em 17 nov. 2009.
- ALMEIDA, J. D. S., A. C. SILVA and A. C. PAIVA (2010). Automatic Eye Detection in Human Faces Using Correlogram Functions and Support Vector Machines. *International Conference on Computer Vision Theory and Applications, VISAPP 2010*.
- BICAS, H.E.A. (2009). Estrabismos: da teoria à prática, dos conceitos às suas operacionalizações. *Arq Bras Oftalmol* **72**(5), 585–615.
- BRAZ JR, Geraldo (2006). Identificação de Massas em Mamografias Usando Textura, Geometria e Algoritmos de Agrupamento e Classificação.
- BRAZ JUNIOR, Geraldo (2008). *Classificação de Regiões de Mamografias em Massa e Não Massa usando Estatística Espacial e Máquina de Vetores de Suporte*. Dissertação de Mestrado, Universidade Federal do Maranhão, São Luís, MA.
- BURGISS Jr, S.G. and S.G. GOODRIDGE (2001). Multiframe averaging and homomorphic filtering for clarification of dark and shadowed video scenes. In: *Proceedings of SPIE*. Vol. 4232. p. 480.
- CAMARGO, E. C. G. (1997). Desenvolvimento, implementação e teste de procedimentos geoestatísticos (KRIGEAGEM) no sistema de processamento de informações georreferenciadas (SPRING).

- CAMBRIDGE, AT&T Laboratories (2009). ORL Face Database:. *Database available at <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>*.
- CANNY, J. (1986). A computational approach to edge detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence* **8**(6), 679–698.
- CARVALHO, A., A. P. BRAGA and T. B. LUDERMIR (1998). Fundamentos de Redes Neurais Artificiais. *11a. Escola de Computação. Rio de Janeiro: UFRJ*.
- CHANG, CHIH-CHUNG and CHIH-JEN LIN (2003). LIBSVM – A Library for Support Vector Machines. Disponível em: <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>.
- CHUA, B. and P. MITCHELL (2004). Consequences of amblyopia on education, occupation, and long term vision loss. *British Journal of Ophthalmology* **88**(9), 1119.
- CRISTIANINI, N. and J. SHAWE-TAYLOR (2000). *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*. Cambridge University Press.
- DIAZ, J. Prieto and C. Souza DIAS (2000). *Strabismus*. Butterworth Heinemann, Woburn, Massachusetts, EUA.
- D’ORAZIO, T., M. LEO, C. GUARAGNELLA and A. DISTANTE (2007). A visual approach for driver inattention detection. *Pattern Recognition* **40**(8), 2341–2355.
- DUDA, R. O. and P. E. HART (1972). Use of the Hough transformation to detect lines and curves in pictures.
- EENWYK, J. Van, A. AGAH, J. GIANGIACOMO and G. CIBIS (2008). Artificial Intelligence Techniques for Automatic Screening of Amblyogenic Factors. *Transactions of the American Ophthalmological Society* **106**, 64.
- FOUNDATION, Eclipse (2006). Eclipse.

- GERACI, A. K. et al. (1990). IEEE Standard Glossary of Image Processing and Pattern Recognition Terminology. *Institute of Electrical and Electronics Engineers (IEEE) Std* pp. 610–4.
- GONZALEZ, R. C. and R. E. WOODS (2002). *Digital image processing*. Prentice Hall, NJ.
- GONZALEZ, R. C. and R.E. WOODS (1992). *Digital Image Processing*. Addison-Wesley Reading, Mass.
- GUIMARÃES, Ricardo (2009). Hospital de olhos de minas gerais. , Disponível em <http://www.holhos.com.br>. Acessado em 23 de janeiro de 2009.
- GUPTA, R. and PE UNDRILL (1995). The use of Texture Analysis to Delineate Suspicious Masses in Mammography. *Phys. Med. Biol* **40**(5), 835–855.
- HAIR, Joseph F. Jr, Rolph E. ANDERSON, TATHAN Ronald L. and William C. BLACK (2005). *Análise Multivariada de Dados*. Bookman.
- HARALICK, R. M., K. SHANMUGAN and I. DINSTEN (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics* v. **3**, n.6, 610–621.
- HASEBE, S., H. OHKITSUKI, R. KONO and Y. NAKAHIRA (1998). Biometric confirmation of the Hirschberg ratio in strabismic children. *Investigative ophthalmology & visual science* **39**(13), 2782.
- HAYKIN, S. (1999). *Neural networks a comprehensive foundation*, 2 nd.
- HEARST, M. A. (1998). Trends & Controversies: Support Vector Machines. *IEEE Intelligent Systems* **13**(4), 18–28.
- HELVESTON, E. M., F. H. ORGE, R. NARANJO and L. HERNANDEZ (2001). Telemedicine: Strabismus e-consultation. *Journal of American Association for Pediatric Ophthalmology and Strabismus* **5**(5), 291–296.
- ISAACS, E. H. and R. M. SRIVASTAVA (1990). *Applied geostatistics*.

- ISHIZAKI, M., G. ZHU, T. HASEBA, S. S. SHAFER and W. W. KAO (1993). Expression of collagen I, smooth muscle alpha-actin, and vimentin during the healing of alkali-burned and lacerated corneas. *Investigative ophthalmology & visual science* **34**(12), 3320.
- JAVA (2008). Java development kit. Sun, Disponível em <http://java.sun.com/javase/downloads/index.jsp>.
- JIAO, F. and G. HE (2007). Real-Time Eye Detection and Tracking under Various Light Conditions. *Data Science Journal* **6**(0), 636–640.
- JOLSON, A. S., H. R. MYLER and A. WEEKS (1992). Apparatus for evaluating eye alignment. US Patent 5,094,521.
- JUNQUEIRA, L. C. and J. CARNEIRO (1995). Histologia básica. 8ª edição. Guanabara Koogan.
- KENNETH, R. (1996). Castleman, Digital image processing.
- KIM, H. J. and W.Y. KIM (2008). Eye Detection in Facial Images Using Zernike Moments with SVM. *ETRI Journal* **30**(2), 335–337.
- KINOSHITA, S. K., PEREIRA R. R., M. O. HONDA, JAH RODRIGUES and P. M. AZEVEDO-MARQUES (2004). An Automatic Method for Detection of the Nipple and Pectoral Muscle in Digitized Mammograms. *Congresso Latino-Americano de Engenharia Biomédica (CLAEB 2004)*.
- LACHENBRUCH, P. A. and M. GOLDSTEIN (1979). Discriminant Analysis. *Biometrics* **35**(1), 69–85.
- LIBRALÃO, G. L., A. VALERIO NETTO, A. P. L. F. CARVALHO and M. C. F. OLIVEIRA (2005). Determinação de vícios refrativos oculares utilizando Support Vector Machines. *Sba: Controle & Automação Sociedade Brasileira de Automatica* **16**, 146–158.
- LIFESPAN (2008). Amblyopia. Technical report. ADAM Multimedia Encyclopedia. Disponível em: <http://www.lifespan.org/adam/healthillustratedencyclopedia/1/001014.html>. Acesso em 17 nov. 2009.

- LIMA, C. A. de M. (2004). *Comitê de Máquinas: Uma abordagem Unificada Empregando Máquinas de Vetores-Suporte*. Tese doutorado, Universidade Estadual de Campinas, SP.
- LOONEY, C.G. (1997). *Pattern Recognition using Neural Networks: Theory and Algorithms for Engineers and Scientists*. Oxford University Press, Inc. New York, NY, USA.
- LORENA, A. C. and A. CARVALHO (2002). *As máquinas de vetores suporte, relatório interno*. Laboratório de Inteligência Computacional, ICMC/USP, São Carlos-SP, junho.
- LUNA, Bráulio Filho (2007). Utilização Racional dos Testes Diagnósticos em Cardiologia. CASA DA CARDIOPATIA HIPERTENSIVA. Disponível em <http://www.unifesp.br/dmed/cardio/ch/utiliza.htm>.
- MEERSMAN, D., P. SCHEUNDERS and D. VAN DYCK (1998). Detection of Microcalcifications using non-linear Filtering. *Proc. EUSIPCO'98, European Signal Processing Conference IV*, 2465–2468.
- MELO, R.H.C. de, E. de Almeida VIEIRA and A. CONCI (2005). A System to enhance details on partially shadowed images. *by A. Karras, S. Voliotos, M. Rangouse and A. Kokkosis* pp. 309–312.
- MILLER, J. M., M. MELLINGER, J. GREIVENKEMP and K. SIMONS (1993). Videographic Hirschberg measurement of simulated strabismic deviations. *Investigative ophthalmology & visual science* **34**(11), 3220.
- MIMS, J. L and R. C. WOOD (2002). Proportional (fractional) displacement of the Hirschberg corneal light reflection (test): a new easily memorized aid for strabometry; photogrammetric standardization (calibration).. *Binocular vision & strabismus quarterly* **17**(3), 192.
- MITCHELL, T (1997). *Machine Learning*. McGraw Hill, New York.
- MOTWANI, M., R. MOTWANI and F.C. HARRIS Jr (2004). Eye detection using wavelets and ann. *Proceedings of Global Signal Processing Conferences & Expos for the Industry (GSPx)*.

- NADLER, M. and E.P. SMITH (1993). *Pattern recognition engineering*. Wiley New York, NY:.
- NOORDEN, G.K. Von and E.C. CAMPOS (2001). *Binocular vision and ocular motility: theory and management of strabismus*. Mosby Inc.
- OLERF (2008). Amblyopia. Technical report. Ohio LIONS Eye Research Foundation (OLERF). Disponível em: <http://www.ohiolionseyeresearch.com/amblyopia.htm>. Acesso em 10 nov. 2009.
- PENG, K., L. CHEN, S. RUAN and G. KUKHAREV (2005). A robust algorithm for eye detection on gray intensity face without spectacles. *Journal of Computer Science and Technology* **5**(3), 127–132.
- POTT, J. W. R., C. KINGMA, K. VERHOEFF, R.J GROOTENDORST and J. FABER (2003). The polaroid suppression test in a pediatric population with ophthalmologic disorders. *Journal of AAPOS* **7**(2), 137–141.
- QUICK, M. W. and R. G. BOOTHE (1992). A photographic technique for measuring horizontal and vertical eye alignment throughout the field of gaze. *Investigative ophthalmology & visual science* **33**(1), 234.
- ROMANO, P. E. (2006). Individual case photogrammetric calibration of the Hirschberg Ratio (HR) for corneal light reflection test strabometry. *Binocular vision & strabismus quarterly* **21**(1), 45.
- SBO (2009). Dia mundial da visão: 8 de outubro de 2009. Technical report. Sociedade Brasileira de Oftalmologia (SBO). Disponível em: <http://www.sboportal.org.br>. Acesso em 28 dez. 2009.
- SILVA, A.C., M. GATTASS and P.C.P. CARVALHO (2004). Analysis of Spatial Variability using Geostatistical Functions for Diagnosis of Lung Nodule in Computerized Tomography Images. *Pattern Analysis and Applications* **7**(3), 227–234.
- SILVA, Aristófanés Corrêa (2004). *Algoritmos para Diagnóstico Assistido de Nódulos Pulmonares Solitários em Imagens de Tomografia Computadorizada*.

- Tese de Doutorado, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, RJ.
- SMOLA, A. J. (2000). *Advances in large margin classifiers*. the MIT Press.
- SONKA, M., V. HLAVAC and R. BOYLE (1999). Image processing, analysis, and machine vision, Brooks. *Cole Publishing Company*, **2**, 5.
- SOUSA Jr., O. S. (2006). *Método de reconhecimento pessoal através da íris usando funções geoestatísticas*. Dissertação de Mestrado, Universidade Federal do Maranhão, São Luís, MA.
- SOUZA Jr., O. S. S., A. C. SILVA and Z. ABDELOUAH (2009). Personal Identification Based on Iris Texture Analysis Using Semivariogram and Correlogram Functions. *International Journal for Computacional Vision and Biomechanics*.
- SOUZA, M. B., V. O. TOMIKAWA, B. F OLIVEIRA and M. POLATI (2004). Uso da rede neural artificial no planejamento cirúrgico da correção do estrabismo. *Arq Bras de Oftalmol* **67**(5), 459–52.
- SPSS, Lead Technologies (2003). SPSS 11.0 for windows. Disponível em <http://www.spss.com>.
- SUBHARNGKASEN, I. (2003). Successful amblyopia therapy by using synoptophore.. *Journal of the Medical Association of Thailand= Chotmaihet thangphaet* **86**, S556.
- SUN (2007). Jai, Java Advanced Image api. SUN. Disponível em <http://java.sun.com/javase/technologies/desktop/media/jai/>.
- TAKEGAMI, T., T. GOTOH, S. KAGEI and R. MINAMIKAWA-TACHINO (2003). A hough based eye direction detection algorithm without on-site calibration. In: *Proc. 7th Digital Image Computing: Techniques and Applications*. pp. 10–12.
- VAPNIK, V. N. (1995). *The Nature of Statistical Learning Theory*. Springer Verlag, New York.

- VAPNIK, V.N. (1998). *Statistical Learning Theory*. Wiley New York.
- WANG, P., M. B. GREEN, Q. JI and J. WAYMAN (2005). Automatic eye detection and its validation. In: *Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)-Workshops*. Citeseer. p. 164.
- WANG, Q. and J. YANG (2008). Eye detection in facial images with unconstrained background. *Journal of Pattern Recognition Research* **1**(1), 55.
- WHEELER, M.C. (1942). Objective strabismometry in young children. *Transactions of the American Ophthalmological Society* **40**, 547.
- YAMANE, Y. (2006). Estrabismo. In: Dantas, Adalmir Morterá; Moreira, Ana Tereza Ramos. (Org.). *Oftalmologia Pediátrica*.