

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIA EXATA E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO
DEPARTAMENTO DE COMPUTAÇÃO

**“SISTEMA PARA TOMADA DE DECISÃO BASEADO NA GERAÇÃO DE
IMAGENS ESTEREOSCÓPICAS E RECONHECIMENTO DE PADRÕES
CIRCULARES”**

Fábio Bento Takeda
Orientador: Prof. Dr. Paulo Estevão Cruvinel
Co-Orientador: Prof. Dr. José Hiroki Saito

São Carlos
Junho/200

Universidade Federal de São Carlos
Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Ciência da Computação

**SISTEMA PARA TOMADA DE DECISÃO BASEADO NA GERAÇÃO DE
IMAGENS ESTEREOSCÓPICAS E RECONHECIMENTO DE PADRÕES
CIRCULARES**

Fábio Bento Takeda

Dissertação de Mestrado
apresentada ao Programa de Pós-
Graduação em Ciência da
Computação da Universidade
Federal de São Carlos, como parte
dos requisitos para a obtenção do
título de Mestre em Ciência da
Computação.

Membros da Banca :

São Carlos
Agosto / 2003

**Ficha catalográfica elaborada pelo DePT da
Biblioteca Comunitária da UFSCar**

T136st

Takeda, Fábio Bento.

Sistema para tomada de decisão baseado na geração de imagens estereoscópicas e reconhecimento de padrões circulares / Fábio Bento Takeda. -- São Carlos : UFSCar, 2003.

136 p.

Dissertação (Mestrado) -- Universidade Federal de São Carlos, 2003.

1. Processamento de imagens. 2. Reconhecimento de padrões. 3. Imageamento estereoscópico. 4. Transformada de Hough. I. Título.

CDD: 006.42 (20^a)

Dedico este trabalho
a Deus, aos meus
Pais Valdemar e
Edina, minha irmã
Patrícia e a minha
namorada Milene.

Agradecimentos

Agradeço em primeiro lugar a Deus que nos momentos mais difíceis, me iluminou para que conseguisse terminar este trabalho.

Aos meus Pais e minha Irmã, que sempre me apoiaram nas decisões que tomei, dando-me força, amor e carinho.

Aos amigos que junto a mim formaram um verdadeiro lar, Fernando, Marcelo e Will que por muitas vezes nos encontramos nos horários mais estranhos para estudar.

Aos amigos do mestrado Alexandre, Ana Claudia, Davidson, Dinho, Felipe, Lucas, Lucia, Luis (Pschico), Marcelo Módolo, Matheus, Maurício, Moacir, Nori, Pablo, Paulo, Thiago, Verônica, que de alguma forma me ajudaram.

Aos Professores, Bataiolla, Hélio, Marcarenhas, Prado, Wanderlay Zorzo, pelos ensinamentos proporcionados.

Em especial ao meu orientador Cruvinel que mesmo no descanso da noite, madrugada, feriado, fim de semana arrumou um tempo para me orientar, assim com meu co-orientador Saito que por todo o período do mestrado me ajudou.

A professora Rosane Minglim os alunos da ICMC –USP pelas dicas e ajuda.

E finalmente, mas não menos importante a minha namorada Milene que entrou na fase da minha vida mais difícil, mas sempre me auxiliando com todo seu companheirismo e compreensão.

Sumário

Lista de Figuras.....	III
Lista de Tabelas.....	IX
Lista de Símbolos	X
Capitulo 1 – Introdução	1
Capitulo 2 – Imagiamento Estereoscópico	4
2.1 - Introdução	4
2.2 - Imagiamento Estereoscópico.....	6
2.3 - Modelagem para obtenção de imagem estereoscópica.....	11
2.4 – Correspondência por blocos	22
Capitulo 3 – Transformada de Hough para reconhecimento de padrões e definição de descritores	26
3.1 - Métodos Utilizados no Reconhecimento de Padrões.....	27
3.1.1 - Métodos para Detecção de Pixels, Linhas e Bordas.	28
3.1.2 - Técnicas de Limiarização (<i>THRESHOLD</i>)	33
3.2 - O Processamento de Imagens com Reconhecimento de Padrões e suas implicações em reconhecimento de padrões circulares.....	35
3.3 - Uso da Transformada de Hough no reconhecimento de padrões	35
3.3.1 - Fundamentos	37
3.3.2 - Generalização da Transformada de Hough e Rápida	43
3.3.2 - Transformada de Hough para objetos circulares	44
3.4 - Definição e classes nas técnicas de reconhecimento de padrões	52
3.4.1 - Alguns Descritores usuais	54
3.4.2 - Descritores de Fronteiras	63
Capitulo 4 – Desenvolvimento do sistema para tomada de decisão baseado na geração de imagens estereoscópicas e reconhecimento dos padrões circulares	72

4.1 – Modelagem de objetos do sistema para tomada de decisão baseado em imagiamento estereoscópico.	72
4.2 Entrada do Sistema	73
4.3 – Pré-Processamento Individual	79
4.4 – Pré-Processamento Coletivo.....	83
4.5 – Armazenagem	97
4.6 - Visualização	99
Capítulo 5 – Resultados e Conclusões	100
5.1 - Avaliação da Interface com o usuário.....	100
5.2 – Calibração para medida de padrões circulares em imagens bidimensionais.	113
5.3 – Calibração para medida de padrões circulares em imagens bidimensional como correção de profundidade obtido por estereoscopia.....	118
5.4 – Estudo de caso com aplicação do método em imagens reais.	120
5.5 - Conclusões.....	127
5.6 - Sugestões de trabalhos futuros.....	128
Referência Bibliográfica	129

Lista de Figuras

Figura 2.1 - Tipos de elementos de dados de volume.	6
Figura 2.2- (a) Imagem bidimensional de uma das faces de uma imagem tridimensional. (b) Imagem estereoscópica.	7
Figura 2.3 – Duplicidade do polegar gerado por imagens respectivas a cada olho.	8
Figura 2.4 – Valor Máximo indicado para a visualização do parallax.....	9
Figura 2.5 - Geração de uma imagem estereoscópica pelo método Anaglyph.....	10
Figura 2.6 - Configuração canônica de câmeras.....	11
Figura 2.7 – Método de olhos cruzados. (a) Imagem que será posicionada à frente do olho esquerdo. (b) Imagem que será posicionado à frente do olho direito.	12
Figura 2.8 – Configuração com geometria epipolar.	14
Figura 2.9 - Representação esquemática de um epipolo, um plano epipolar e uma linha epipolar.	14
Figura 2.10 - Representação esquemática da formação de uma família de planos a partir da rotação de um plano epipolar sobre sua linha de base.....	15
Figura 2.11 - Configuração de câmeras com eixos não paralelos.	16
Figura 2.12 - Imagem retificada para alcançar linhas epipolares paralelas.	19
Figura 2.13 - Pseudo-código para reconhecimento de pontos correspondentes.....	24
Figura 3.1– Modelo para auxílio à tomada de decisão a partir do reconhecimento dos objetos em imagens digitais.	27
Figura 3.2 – Um exemplo de máscara utilizada para detectar pixels isolados.....	28

Figura 3.3 - Máscaras que podem ser utilizadas para detectar linhas isoladas nas direções (a) 00 (b) 450, (c) 900, (d)-450 (GONZALEZ & WOODS, 1993).....	29
Figura 3.4 - (a) Imagens com descontinuidade, (b) Sinal da descontinuidade, (c) Primeira derivada do sinal e (d) Segunda derivada do sinal.....	30
Figura 3.5 - Máscaras utilizadas no detector de Sobel.....	31
Figura 3.6 - Determinação da magnitude dos gradientes e também do ângulo.....	32
Figura 3.7 - Exemplo de limiarização global – (a) imagem original, (b) resultado da segmentação simples com limiar $T= 90$	34
Figura 3.8 - A transformada de Hough a) espaço de imagem b) espaço de parâmetro (DUDA & HART, 1972).	38
Figura 3.9 - (a) Representação da equação da reta e, função de suas coordenadas polares. (b) Relação entre definição de reta em coordenadas polares.....	39
Figura 3.10 - Ilustração da aplicação da transformada de Hough. (a) Pontos no espaço da imagem. (b) Mapeamento dos pontos no espaço($\rho - \theta$). (c) Detecção das propriedades de colinearidade. Ponto A denota intersecção de curvas correspondentes aos pontos 1, 3 e 4.(d) Propriedade de reflexão da transformada de Hough.....	42
Figura 3.11- Imagem de uma circunferência, ilustrando os pixels no plano.....	45
Figura 3.12 - Espaço de parâmetros a e b para circunferências.....	46
Figura 3.13 - Circunferência geradas com centro em pixels que ficam nas bordas da imagem.	47
Figura 3.14 - Dimensões do arranjo acumulador.	47
Figura 3. 15- Circunferências fracionada e incompleta.....	50
Figura 3. 16 - Representação de classes de padrões e seus descritores.	53
Figura 3.17- Duas fronteiras simples e suas correspondentes assinaturas (distância em função do ângulo) (GONZALEZ & WOODS, 1993).....	57

Figura 3.18 - Eixo médio de três regiões simples.....	58
Figura 3.19 – Ilustração para atendimento às condições a e b . Descrever novamente $N(p_1) = 4$ e $S(p_1) = 3$	59
Figura 3.20 - (a) Resultado após aplicação do primeiro passo do algoritmo de afinamento durante a primeira iteração pela região; (b) Resultado após aplicação do segundo passo; (c) Resultado final. (GONZALEZ & WOODS, 1993).....	61
Figura 3.21- Exemplo de afinamento de uma imagem (GONZALEZ & WOODS, 1993).....	61
Figura 3.22 - A região (S) e sua deficiência convexa (em cinza).	63
Figura 3.23 - Uma fronteira digital e sua representação por uma seqüência complexa. Os pontos (x_0, y_0) e (x_1, y_1) são (arbitrariamente) os dois primeiros pontos da seqüência.....	66
Figura 3.24- Exemplos de reconstrução de descritores de Fourier para vários valores de M	68
Figura 3.25- H_1 e H_2 representam número de buracos.	70
Figura 3.26- C_1 , C_2 e C_3 representam o número de componentes complexos.	70
Figura 4.1 - Diagramação do sistema de imagiamento estereoscópico com reconhecimento de padrões circulares.	74
Figura 4.2 - Foto ilustrativa da câmera WebCam Creative®.....	75
Figura 4.3 - Código da Classe TGraphConfig de configuração do componente VCAP.....	76
Figura 4.4 - Fluxograma de atualização da lista de dispositivos de câmeras instalado.	77
Figura 4.5 - Fluxograma de atualização de modos de exibição.	78
Figura 4.6 - Fluxograma de conversão de uma imagem colorida em uma imagem com tons de cinza.	80
Figura 4.7 - Fluxograma da filtragem por Average de imagens.	81
Figura 4.8 - Fluxograma do procedimento para equalização do histograma.....	82
Figura 4.9 - Modelos de correspondência por blocos.....	83

Figura 4.10 - Fluxograma do procedimento de correspondência por blocos.....	84
Figura 4.11 - Fluxograma da técnica de limiarização.....	85
Figura 4.12 - Fluxograma de reconstrução tridimensional.	86
Figura 4.13 - Fluxograma do procedimento de correção do planos da imagem.....	87
Figura 4.14 - Fluxograma de transformação da imagem tridimensional para uma imagem bidimensional.....	88
Figura 4.15 - Fluxograma do arranjo acumulador.	91
Figura 4.16 - Fluxograma para eliminação de pequenos grupos.	93
Figura 4.17 - Fluxograma para detecção de extremidades.	94
Figura 4.18 - Fluxograma para reconhecimento de padrões circulares com a transformada de Hough.....	95
Figura 4.19 - Fluxograma do algoritmo de Backmapping.....	96
Figura 4.20 - Fluxograma do procedimento de armazenamento das imagens adquiridas pelas câmeras 1 e 2.....	98
Figura 5.1 - Tela principal do sistema de reconhecimento de padrões circulares com correção de profundidade.....	101
Figura 5.2 - Ilustração dos itens oferecidos pelo menu iniciar.	102
Figura 5.3 - Seleção da forma que a imagem será aberta, ou seja, de forma formal como foi digitalizada ou convertendo-a em tons de cinza.	103
Figura 5.4 - Opção de salvar oferecida pelo menu Arquivo.	104
Figura 5.5 - Chamada da função de equalização automática de histogramas.	105
Figura 5.6 - Chamada da função de correspondência por blocos.....	106
Figura 5.7 - Procedimento para recuperação da coordenada Z através de técnica de imagiamento estereoscópico.	107
Figura 5.8 - Tela do sistema com o resultado da equalização automática do histograma.	107
Figura 5.9 - Resultado do procedimento de ponto de correspondência através de um único ponto.	108
Figura 5.10 - Tela do sistema com a opção de filtros oferecidos.....	108

Figura 5.11 – Tela de saída com a ilustração de um exemplo de resultado obtido através dos cálculos de imageamento estereoscópico.	109
Figura 5.12 - A limiarização para cada uma das imagens funciona de forma independente, podendo ser ajustado uma limiar para cada uma das imagens.	109
Figura 5.13 – Resultado após aplicação do filtro Laplaciano em cada uma das imagens.	110
Figura 5.14 - Tela com resultados da aplicação da transformada de Hough.	110
Figura 5.15 – Tela de acesso à definição do Backmapping e do algoritmo de vizinhança.	111
Figura 5.16 - Relatório em forma de tabela e histograma de distribuição de padrões circulares.	112
Figura 5.17 - Padrões de imagens para calibração do sistema de medida, onde (a) representa o menor tamanho (raio de 18 pixels) e (b) o maior tamanho (raio de 85 pixels).	113
Figura 5.18 - Imagens Adquiridas para a calibração onde as imagens (a) e (b) foram adquiridas com profundidade 0,5m, foram adquiridas com profundidade (c) e (d) de 1m, foram adquiridas com profundidade (e) e (f) de 1,5m, foram adquiridas com profundidade (g) e (h) de 2m, foram adquiridas com profundidade (i) e (j) de 2,5m e foram adquiridas com profundidade (k) e (l) de 3m.	118
Figura 5.19 - Primeiro padrão de teste, realizado com bolas de isopor com tamanhos diferentes posicionada de forma aleatória. ((a) Imagem com a câmera 1; (b) Imagem com a câmera 2).....	121
Figura 5. 20 - (a) e (b) ilustram o Filtro Laplaciano e a identificação da transformada de Hough na imagem do primeiro estudo de caso, respectivamente.	121
Figura 5. 21 – Histograma dos padrões circulares identificados pela transformada de Hough.....	122
Figura 5. 22 - Segundo padrão de teste com oito bolas de isopor com tamanhos diferentes, posicionadas de forma aleatória com uma	

sobreposição. ((a) Imagem com a câmera 1; (b) Imagem com a câmera 2)	123
Figura 5. 23 - (a) e (b) ilustram o Filtro Laplaciano e a identificação da transformada de Hough na imagem do segundo estudo de caso, respectivamente.	124
Figura 5. 24 - Histograma de padrões circulares identificados pela transformada de Hough.....	124
Figura 5. 25 - Terceiro teste com oito bolas de tamanhos diferentes e desalinhadas. ((a) Imagem com a câmera 1; (b) Imagem com a câmera 2)	125
Figura 5. 26 - (a) e (b) ilustram o Filtro Laplaciano e a identificação da transformada de Hough na imagem do terceiro estudo de caso, respectivamente.	126
Figura 5. 27 - Histograma das circunferência identificadas pela transformada de Hough.....	126

Lista de Tabelas

Tabela 1 - Principais características da WebCam Creative®.....	75
Tabela 2 -Dados gerados das imagens analisadas com diâmetros no intervalo de 18 à 34 pixels.....	114
Tabela 3- Síntese da análise para padrões circulares com diâmetros na faixa de 18 pixels à 34 pixels.	114
Tabela 4 - Dados gerados das imagens analisadas com diâmetros no intervalo de 35 à 51 pixels.....	115
Tabela 5 - Síntese da análise para padrões circulares com diâmetros na faixa de 35 pixels à 51 pixels.	115
Tabela 6 - Dados gerados das imagens analisadas com diâmetros no intervalo de 52 à 68 pixels.....	116
Tabela 7 - Síntese da análise para padrões circulares com diâmetros na faixa de 52 pixels à 68 pixels.	116
Tabela 8 - Dados gerados das imagens analisadas com diâmetros no intervalo de 69 à 85 pixels.....	117
Tabela 9 - Síntese da análise para padrões circulares com diâmetros na faixa de 69 pixels à 85 pixels.	117
Tabela 10 - Tabela com os resultados da calibração.	119
Tabela 11 - Lista dos padrões utilizados nos estudos de caso com seus respectivos tamanhos.....	120
Tabela 12- Tabela comparativa do resultado obtido no primeiro estudo de caso e respectivo erro médio percentual.	122
Tabela 13 - Tabela comparativa dos resultados obtido pelo sistema no segundo estudo de caso e respectivo erro médio percentual.	125
Tabela 14 - Resultados obtidos no terceiro estudo de caso e respectivo erro médio percentual.	127

Lista de Símbolos

\approx - projeção até uma escala conhecida;

Imagem 3D – imagem tridimensional;

A e B – matriz transformada;

C – centro focal da primeira imagem;

C' – centro focal da segunda imagem;

CCD – *Charge Coupled Device*;

D – distância entre as duas câmeras;

D_D – índice para a imagem direita;

D – matriz diagonal;

D_E – índice para a imagem esquerda;

e e e' - epipolos;

F – matriz fundamental;

$f(x,y)$ – função densidade de um pixel;

$$G = \begin{bmatrix} 0 & -1 & 0 \\ -1 & 0 & 0 \\ 0 & 0 & -1 \end{bmatrix};$$

H_1 – matriz de normalização da primeira imagem;

H_2 – matriz de normalização da segunda imagem;

$h, i, j, h', i', j', h'', i'', j''$ - relação entre a imagem projetada e o ponto u

$i(x,y)$ – função de iluminação de um pixel;

K – matriz de calibração da primeira imagem;

K' – matriz de calibração da segunda imagem;

K^{-1} – inversa da matriz de calibração;

l e l' - linhas peipolares;

M, M' e M'' – matriz de perspectiva;

M'_1, m'_2 e m'_3 – vetor derivado de M para a segunda imagem;

M_1, m_2 e m_3 – vetor derivado de M para a primeira imagem;

R – rotação de uma imagem;

$r(x,y)$ – função de reflectância de um pixel;

R^{-1} – rotação inversa da imagem;

$S(t)$ – matriz de inclinação simétrica;

SVD – decomposição de valor unitário;

$()^T$ – matriz transposta;

t – translação de uma imagem;

t_c – distância entre a lente e o sensor CCD;

u e u' - projeções da cena;

U e V – coordenadas homogenia;

$\overset{\cup}{u}$ e $\overset{\cup}{v}$ – matriz de transformação de tamanho 3x3 da primeira imagem;

$\overset{\cup}{u'}$ e $\overset{\cup}{v'}$ – matriz de transformação de tamanho 3x3 da segunda imagem;

X e y – coordenadas do pixel de uma imagem;

X , Y e Z – coordenada da imagem 3D;

X' - coordenada x da segunda imagem;

X_1 e y_1 – coordenadas dos pixels da primeira imagem;

X_2 e y_2 – coordenadas dos pixels da segunda imagem;

Q – Matriz de projeção;

$$Z = \begin{bmatrix} 0 & -1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}.$$

Resumo

É apresentado um sistema para auxílio a tomada de decisão baseado na geração de imagens estereoscópicas e reconhecimento de padrões circulares. Para o imagiamento estereoscópico são utilizadas duas câmeras de baixo custo do tipo Webcam em configuração canônica e correspondência por blocos é utilizada para se encontrar a correspondência entre duas imagens adquiridas de uma cena de interesse. Adicionalmente a transformada rápida de Hough é utilizada para o reconhecimento de padrões circulares, os quais são, após identificados, corrigidos em função de seus diâmetros com a informação da profundidade obtida por estereoscópica e um fator de escala dado pela calibração do método. Resultados obtidos com padrões simulados e com cenas reais compostas com padrões circulares em diversas situações de distribuição espacial ilustram a potencialidade do método para auxílio de tomada de decisão em processos que envolvem o reconhecimento de padrões circulares.

Abstract

In this work, it is presented a system for decision-making based on stereoscopic image generation and recognition of circular patterns. For stereoscopic imaging are used two low cost Web cam in canonical configuration and block correspondence, which is used to find out the correspondence between images from a scene of interest. Also, the fast Hough transform is used to recognize circular patterns, which are identified and corrected based on their diameters with depth information obtained from both stereoscopic imaging and a calibration factor. The results obtained with simulated patterns and with composed real scenes with circular patterns in varied situations of special distribution illustrate the method potentiality for decision-making in procedures, which involve circular pattern recognition.

Capítulo 1

Introdução

A competitividade e as exigências trazidas pela sociedade moderna, tem cada vez mais pressionado o setor agrícola a buscar maior eficiência na produção com a diminuição de agressões ao meio ambiente e busca pela conservação dos recursos naturais, diminuindo a poluição e visando o controle dos problemas ambientais. Diversas aplicações de insumos têm sido pesquisadas para otimizar problemas associados às práticas agronômicas, como por exemplo, melhoria na execução de aplicações convencionais de fertilizantes e defensivos baseadas nas necessidades médias das áreas agriculturáveis. Essas aplicações significam, muitas vezes, aplicações excessivas em algumas áreas do campo e insuficientes em outras, pois uma área dificilmente é uniforme. Dessa maneira, as aplicações excessivas dos insumos podem tornar-se fontes de contaminação das águas subterrâneas e superficiais.

A Agricultura de Precisão, como uma nova técnica de manejo agrícola, tem possibilitado o uso de tecnologias atuais para o manejo de insumos e culturas de modo adequado às variações espaciais e temporais em fatores que afetam a produtividade e o meio ambiente. Pode-se conceitualizar a Agricultura de Precisão como a habilidade em monitorar e acessar a atividade agrícola em sítios específicos, com o objetivo de aumentar a eficiência do processo produtivo e a sustentabilidade.

Dentre as ferramentas utilizadas na Agricultura de Precisão destaca-se o potencial do sensoriamento remoto, muito utilizado para o mapeamento de áreas de cultura e estimação do rendimento das

mesmas. Entretanto, nos últimos anos a pesquisa tem sido direcionada para o monitoramento das condições da cultura como, por exemplo, a identificação de deficiências nutricionais em planta, a ocorrência de pragas e doenças, a classificação e quantificação de plantas daninhas, índices de produtividade. Neste contexto, tem sido observado que existe grande potencial para a utilização de sistemas de visão artificial (SVA), o que se configurou como principal motivação para o desenvolvimento deste trabalho de pesquisa.

O desenvolvimento de SVAs capazes de reconhecer e distinguir regiões agrícolas pode resultar na redução substancial do volume de trabalho de campo e auxiliar em processos de tomada de decisão que envolva a melhoria da figura de mérito que envolva manejo e custo benefício.

O processo de desenvolvimento de um SVA passa necessariamente por três fases distintas. Primeiramente, coleta-se imagens digitais. Posteriormente, extrai-se das imagens as características descritoras de interesse. Na fase seguinte as características descritoras serão os dados de entrada em algoritmos de classificação para auxílio à tomada de decisão.

Embora seja possível diferenciar três diferentes etapas no processo de desenvolvimento de um sistema de classificação, estas estão interligadas. A adoção de uma técnica ou outra em cada fase do desenvolvimento de um sistema de visão artificial depende de inúmeros fatores inerentes aos problemas estudados e suas aplicações.

Neste trabalho é apresentado um sistema de visão computacional de baixo custo que viabiliza o reconhecimento de objetos circulares diretamente no campo, através do uso da transformada de Hough com correção por estereoscopia em função da profundidade, com potencial uso em aplicações agrícolas.

Neste contexto, a organização do texto com relato da pesquisa desenvolvida conta com cinco capítulos, os quais estão dispostos da seguinte forma:

- **Capítulo 1 – Introdução:** onde é apresentado a motivação do desenvolvimento deste sistema, assim como a disposição deste documento.
- **Capítulo 2 - Imagiamento estereoscópico:** onde são apresentados os conceitos básicos de visualização e construção de imagens estereoscópicas, que possibilitam a construção de uma imagem tridimensional a partir de duas imagens bidimensionais;
- **Capítulo 3 - Transformada de Hough para reconhecimento de padrões e definição de descritores:** onde são apresentadas as técnicas de análise por imagem digital. Um dos métodos considerado importante é o reconhecimento de padrões, o que viabiliza a identificação qualitativa e quantitativa de objetos presentes na imagem sob análise.
- **Capítulo 4 - Desenvolvimento do sistema para tomada de decisão baseado na geração de imagens estereoscópicas e reconhecimento dos padrões circulares:** onde é apresentada a metodologia desenvolvida e a descrição do sistema de imagem tridimensional utilizando técnicas de imagiamento estereoscópico e reconhecimento de padrões circulares com auxílio da transformada de Hough;
- **Capítulo 5 - Resultados e Conclusões:** onde são apresentadas a avaliação do sistema desenvolvido, sua validação e conclusões.

Capítulo 2

Imagiamento Estereoscópico

Neste capítulo é apresentado o conceito de básicos sobre a visualização e geração de imagens estereoscópicas.

2.1 - Introdução

Uma imagem pode ser definida por uma função de intensidade luminosa bidimensional, como $f(x,y)$ e pode ser caracterizada pela quantidade de luz incidida na cena observada e a quantidade de luz refletida pelos objetos desta cena. Seus componentes são chamados de iluminação $i(x,y)$ e refletância $r(x,y)$, como expressa a Equação 2.1.

$$f(x,y) = i(x,y)r(x,y) \quad \text{Equação 2.1}$$

onde $0 < i(x,y) < \infty$ e $0 < r(x,y) < 1$


Quando uma imagem é adquirida por dispositivos como scanner, máquinas fotográficas, câmeras, entre outros, a mesma, após discretizada no tempo, pode ser representada na forma de amostras igualmente espaçadas em uma matriz $N \times M$ conforme ilustra a Equação 2.2.

Assim, pode-se dizer que cada um dos elementos que compõe a matriz denomina-se um elemento da imagem, ou simplesmente *pixel* (*picture element*).


$$f(x,y) \cong \begin{pmatrix} f(0,0) & f(0,1) & \dots & f(0,M-1) \\ f(1,0) & f(1,1) & \dots & f(1,M-1) \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ f(N-1,0) & f(N-1,1) & \dots & f(N-1,M-1) \end{pmatrix} \quad \text{Equação 2.2}$$

Análogo ao *pixel* utilizado no plano bidimensional, o *voxel* é o menor elemento de uma imagem tridimensional (*volume x element*). Formalmente, *voxel* pode ser definido como paralelepípedos fortemente agrupados, formados pela divisão do espaço do objeto através de um conjunto de planos paralelos aos eixos principais do objeto. Em geral a literatura divide-se em duas diferentes definições para o conjunto de pontos de um *voxel*. Na primeira, um *voxel* é representado por um hexaedro definido em torno de um pixel central como demonstrado na Figura 2.1(a), em outros lugares é possível ser definido como um hexaedro, onde cada vértice representa valores amostrados, conforme ilustrado na Figura 2.1(b) (PAIVA *et al.*, 1999).

Na Figura 2.2(a) tem-se uma das faces de uma imagem tridimensional e conforme o objeto é rotacionado é possível observar os demais ângulos de visualização. A diferença entre uma imagem tridimensional e uma imagem estereoscópica é que a imagem estereoscópica, mesmo em um plano bidimensional, proporciona a percepção do objeto extrapolar o plano de visualização. Como exemplo de imagem estereoscópica, tem-se a imagem apresentada na Figura 2.2 (b). As visualizações de imagens estereoscópicas são acompanhadas de técnicas que buscam alcançar os efeitos tridimensionais.



(a) Voxel



(b) Célula

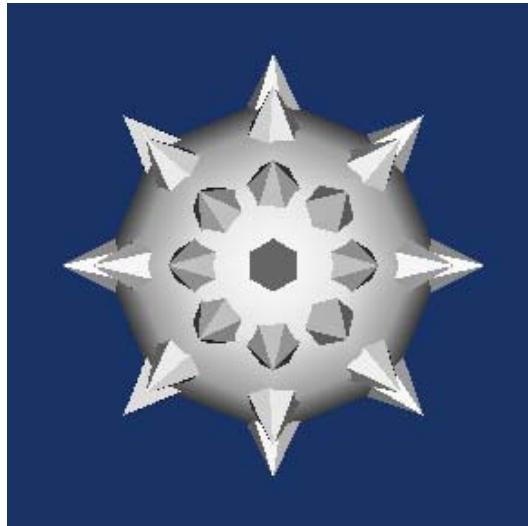
Figura 2.1 - Tipos de elementos de dados de volume.

2.2 - Imagiamento Estereoscópico


O estado da arte do imagiamento estereoscópico, tem mostrado que as aplicações dessa técnica têm invadido diversas áreas de conhecimento (HERNANDES *et al.*, 1995; CARBONI e DESAULNIERS, 1997.; KARTHIK *et al.*, 1997; SAITO *et al.*, 1997; SCHUBERT, 1999; NILCHOLSON, 2001).

O imagiamento estereoscópico, ou também chamado de problema de correspondência, é um sistema de processamento de imagens que

possibilita, a partir de duas imagens recuperar a informação de profundidade de vídeos ou fotos. Esse método foi apresentado pelo físico Charles Wheatstone, professor da *King's College London*, que em 1938 apresentou a primeira literatura desse contexto explicando o funcionamento das imagens estereoscópicas (FRANCESCHI, 2000).



(a)



(b)

Figura 2.2- (a) Imagem bidimensional de uma das faces de uma imagem tridimensional. (b) Imagem estereoscópica.

Wheatstone explicou que o cérebro produz uma única imagem com a sensação de profundidade e distância entre os objetos a partir da captura de duas imagens pelos olhos. Essa sensação é produzida pela disparidade da retina, que nada mais é que a distância entre as duas visões. Um exemplo para melhor explicar a disparidade da retina, pode ser demonstrado posicionando-se um único polegar à frente do seu campo de visão e fixando olhar no mesmo. Observa-se que será apresentado um único dedo, apesar de ser observado por ambos os olhos. Entretanto ao fixar o olhar em um único objeto ao fundo do seu polegar será observado que haverá uma duplicidade do polegar, como é apresentado na Figura 2.3. A disparidade da retina é a distância entre as duas visualizações do polegar. Essa distância entre o centro de cada imagem observada por cada olho, é de aproximadamente 64 milímetros para seres humanos adultos (LIPTON, 1997).




Figura 2.3 – Duplicidade do polegar gerado por imagens respectivas a cada olho.

Semelhante á disparidade da retina tem-se o *parallax* que pode ser definido pela distância do observador em relação ao objeto observado. O *parallax* pode ser dado em termos de medida angular e para melhor observação o valor dele não pode ultrapassar $1,5^\circ$ como

apresentado na Figura 2.4. A impressão de profundidade está diretamente relacionada ao *parallax*, assim variando-o é possível aumentá-la ou diminuí-la conforme a distância das exibições.

O método de *parallax* é utilizado em uma das técnicas disponíveis para a visualização de imagens estereoscópicas, chamada de *Anaglyph*. Este método é em geral mais utilizado, devido a sua facilidade de compreensão e exibição. A Figura 2.5, exibe a geração de uma imagem estereoscópica utilizando o método de *Anaglyph*, o qual baseia-se na sobreposição de imagens diferenciadas por cores diferentes, com o auxílio de um óculos com as cores respectivas para cada olho.




Figura 2.4 – Valor Máximo indicado para a visualização do *parallax*.

Outros métodos também são aplicados ao imagiamento estereoscópico, como por exemplo:

- Olhos cruzados: onde são posicionadas as duas imagens lado a lado, conforme ilustrado na Figura 2.7, sendo que a imagem respectiva ao olho esquerdo é vista na esquerda (Figura 2.7a) e a imagem respectiva ao olho direito é vista na direita (Figura 2.7b). Visualizando-se com o auxílio do dedo indicador posicionado ao centro das suas imagens, junto á tela de exibição. Trazendo o dedo vagorosamente na direção do observador e fixando o olhar na ponta do dedo, a imagem estereoscópica se formará ao fundo.




Figura 2.5 - Geração de uma imagem estereoscópica pelo método Anaglyph.

- Visão paralela: procedimento que também é conhecido como visualização livre de métodos. As imagens têm tamanhos pequenos e cada uma delas, respectivas a cada um dos olhos, são posicionadas próximas a cada olho, mas cada uma com sua respectiva foto. Ao fixar o olhar com bastante atenção em um ponto da imagem elas se transformarão em quatro imagens e eventualmente em três para em seguida formarem a imagem central ou imagem estereoscópica (VREX, 1997).

2.3 - Modelagem para obtenção de imagem estereoscópica

Para se modelar uma imagem estereoscópica pode-se optar por configuração que considere configuração canônica (conforme ilustra a Figura 2.6) ou geometria epipolar (conforme ilustra Figura 2.8).

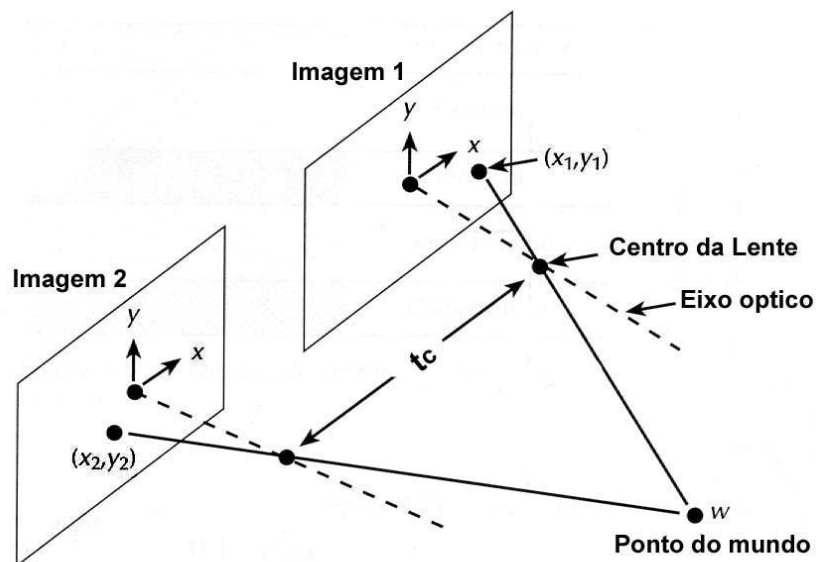


Figura 2.6 - Configuração canônica de câmeras.



(a)

(b)

Figura 2.7 – Método de olhos cruzados. (a) Imagem que será posicionada á frente do olho esquerdo. (b) Imagem que será posicionado á frente do olho direito.

Para a configuração canônica a reconstrução 3D de uma imagem estereoscópica pode ser alcançada através das coordenadas (x_1, y_1) da imagem 1 e (x_2, y_2) da imagem 2 que representam a imagem respectiva a cada uma das câmeras (FU, 1987).

O processo de reconstrução das coordenadas X , Y e Z podem ser obtidas através das equações 2.3, 2.4 e 2.5 respectivamente (GONZALEZ e WOODS, 1992), ou seja:

$$Z = d - \frac{dt_c}{x_2 - x_1} \quad \text{Equação 2.3}$$

$$X = \frac{x_1}{d}(d - Z) \quad \text{Equação 2.4}$$

$$Y = \frac{y_1}{d}(d - Z) \quad \text{Equação 2.5}$$

onde X , Y , Z denotam as coordenadas da imagem tridimensional, d é a distância entre as duas câmeras, t_c é a distância da lente até o dispositivo de CCD (*Charge Coupled Device*), x_1 , x_2 e y_1 são as coordenadas a primeira e segunda imagem respectivamente.

A Figura 2.8 apresenta os centros ópticos denotados por C e C' (linhas de base) respectivos á câmara da esquerda e da direita que definem um plano *epipolar*, cuja intersecção dos planos de imagem gera linhas *epipolares* denotadas por l e l' . A geometria *epipolar* expressa a relação entre duas imagens e um corpo rígido. Formalmente, *epipolo* é o ponto de intersecção de uma linha com os centros ópticos (linha de base) com o plano da imagem. A linha direta que intercepta os *epipolos*, criando a intersecção do plano *epipolar* com o plano da imagem, é chamada de linha *epipolar*. Finalmente, um plano *epipolar* é definido

pela área entre o ponto X de coordenadas do mundo real e as linhas *epipolares*. As figuras 2. 9 e 2. 10 apresentam respectivamente um *epipolo*, um plano *epipolar* e a rotação de um plano *epipolar* sobre sua linha de base com a formação de uma família de planos (FISHER, 1997).

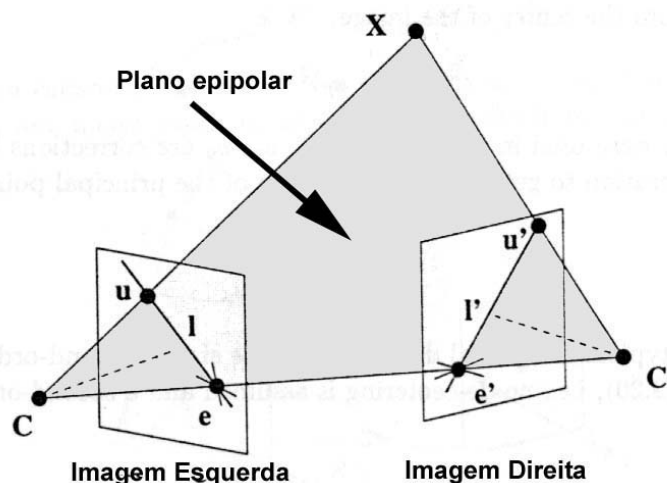


Figura 2.8 – Configuração com geometria epipolar.

Quando há uma movimentação em X que denota um ponto no horizonte, todas as linhas *epipolares* passam através dos *epipolos* e e e' , que são a intersecção da linha de base com a perspectiva dos planos de imagem. As projeções da cena do ponto X são denotadas por u e u' .




Figura 2.9 - Representação esquemática de um epipolo, um plano epipolar e uma linha epipolar.

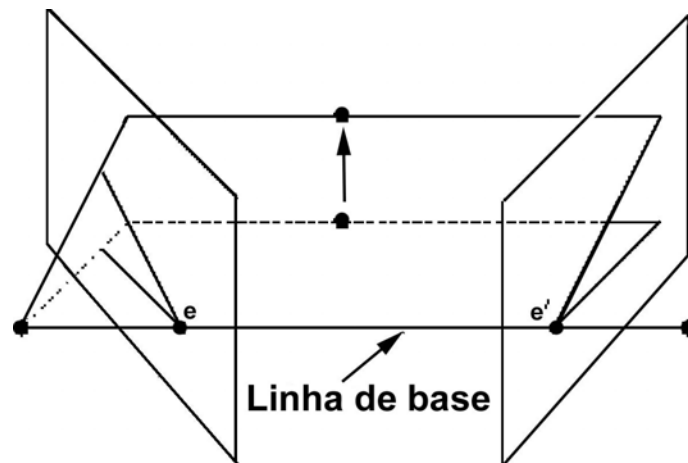


Figura 2.10 - Representação esquemática da formação de uma família de planos a partir da rotação de um plano *epipolar* sobre sua linha de base.

Assim a descrição matemática para esta configuração de eixos ópticos não paralelos, conforme ilustra a Figura 2.11, é apresentada nas Equações 2.6 e 2.7, onde o símbolo \approx denota a projeção até uma escala conhecida, K e K' são as matrizes de calibração das câmeras esquerda e direita respectivamente, R a rotação da imagem e t a translação. Assim, u será a projeção da imagem da esquerda e u' será a projeção da imagem direita.

$$u \approx [k | 0] \begin{bmatrix} X \\ 1 \end{bmatrix} = KX \quad \text{Equação 2.6}$$

$$u' \approx [K'R | K'Rt] \begin{bmatrix} X \\ 1 \end{bmatrix} = K'(RX - Rt) = K'X' \quad \text{Equação 2.7}$$

Sabendo-se que X , X' e t são co-planares pode-se distinguir as câmeras pelos índices E e D , respectivos à câmera esquerda e direita. Pode-se escrever as coordenadas de rotação como demonstrado na Equação 2.7 e na Equação 2.8.

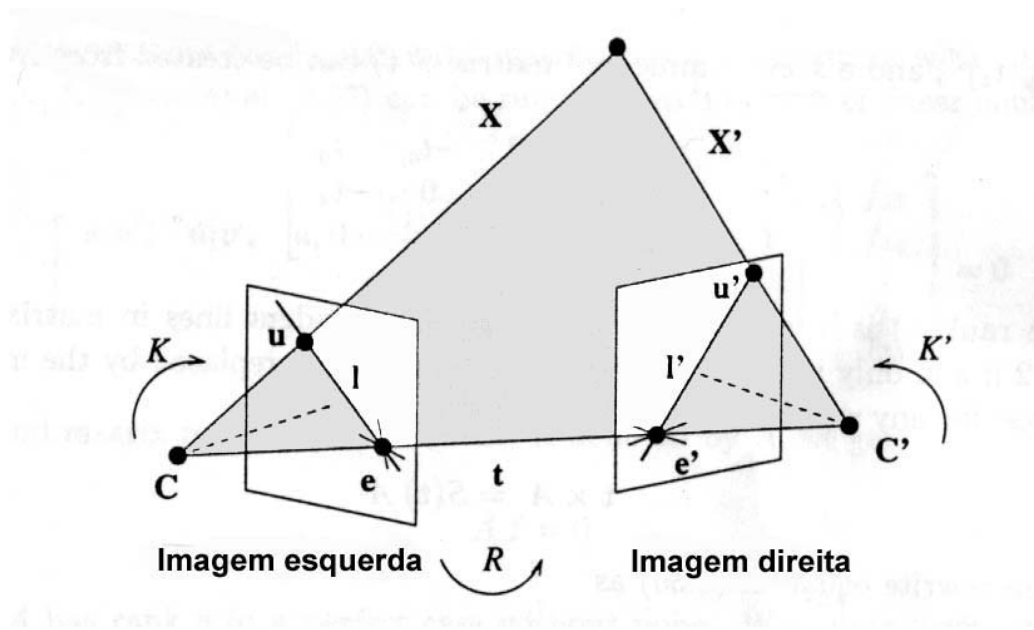


Figura 2.11 - Configuração de câmeras com eixos não paralelos.

$$X'_D = RX'_E \quad \text{Equação 2.8}$$

$$X'_E = R^{-1}X'_D \quad \text{Equação 2.9}$$

A Equação 2.9 expressa a co-planaridade onde substituindo $X_E = K^{-1}u$, $X'_D = (K')^{-1}u'$, e $X'_E = R^{-1}(K')^{-1}u'$ chega-se á Equação 2.10.

$$X_D^T(t \times X'_D) = 0 \quad \text{Equação 2.10}$$

$$(K^{-1}u)^T(t \times R^{-1}(K')^{-1}u') = 0 \quad \text{Equação 2.11}$$

Para simplificar a equação troca-se o vetor produzido pela matriz de inclinação simétrica $S(t)$ onde $t \neq 0$. Assim pode-se reescrever a Equação 2.11 conforme ilustra a Equação 2.12.

$$u^T (K^{-1})^T S(t) R^{-1} (K')^{-1} u' = 0 \quad \text{Equação 2.12}$$

A matriz fundamental é denotada pela Equação 2.13, e foi obtida através de relação bilinear.

$$F = (K^{-1})^T S(t) R^{-1} (K')^{-1} \quad \text{Equação 2.13}$$

Assim substituindo a Equação 2.13 na Equação 2.12 pode-se obter a Equação 2.14 que ilustra que através da matriz fundamental F pode-se adquirir toda a informação das imagens e o problema de correspondência de pontos é resolvido (LONGUET-HIGGINS, 1981).

$$u^T F u' = 0 \quad \text{Equação 2.14}$$

Outro problema do imagiamento estereoscópico está relacionado com a movimentação da câmera apresentada pela matriz essencial, que para o caso com duas câmeras é necessário que estejam calibradas e com o conhecimento da sua matriz de calibração K e K' , assim permitindo a normalização de ambas as imagens, da esquerda e da direita, que é denotada por $\overset{\cup}{u}$ e $\overset{\cup}{u}'$ conforme a Equação 2.15 e Equação 2.16, respectivamente.

$$\overset{\cup}{u} = k^{-1} u \quad \text{Equação 2.15}$$

$$\overset{\cup}{u}' = (K')^{-1} u' \quad \text{Equação 2.16}$$

Relacionando as Equações 2.15 e 2.16 com a Equação 2.12 tem-se Equação 2.17 que será simplificada por $E = S(t)R^{-1}$.

$${}^u u^T E {}^u u' = 0 \quad \text{Equação 2.17}$$

Sumarizando, para se obter a matriz essencial é necessária que se tenha as seguintes propriedades:

- A matriz essencial deve ter classificação 2;
- Se t é o vetor de translação e $t' = Rt$, então $Et' = 0$ e $t^T E = 0$.
- A decomposição por SVD (Decomposição de valor unitário) é dada por $E = UDV^T$ para uma diagonal D , conforme a equação:

$$D = \begin{bmatrix} k & 0 & 0 \\ 0 & k & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad \text{Equação 2.18}$$

O uso da geometria epipolar em sistema estereoscópico tem sido preferido por questão de facilidade na obtenção dos pontos de correspondência entre duas imagens automaticamente. Entretanto, ao se adquirir imagens em equipamentos estereoscópicos com eixos não paralelos é aconselhado que seja realizada uma retificação da imagem que irá resultar em um novo conjunto de imagens com linhas epipolares tipicamente paralelas.

A retificação de uma imagem é realizada quando cada pixel é recalculado utilizando-se a transformação linear da projeção do espaço.

A Figura 2.12 ilustra as imagens antes da retificação apresentada de forma pontilhada e a linha sólida representa a imagem com as linhas epipolares.




Figura 2.12 - Imagem retificada para alcançar linhas epipolares paralelas.

A retificação de imagens é realizada através de duas matrizes de transformação de tamanho 3×3 com as coordenadas dos pontos das imagens esquerda e direita, denotadas por $\overset{\cup}{u} = Au$ e $\overset{\cup}{u}' = Bu'$, respectivamente. Assim, através da matriz fundamental da Equação 2.19, que corresponde aos planos epipolares que se movem no eixo horizontal de ∞ a $-\infty$,

$$\overset{\cup}{F} = (A^{-1})^T FB^{-1} \quad \text{Equação 2.19}$$

Outro passo necessário é a criação de duas matrizes A (Equação 2.20) e B (Equação 2.21) que serão decorrentes da transformação das coordenadas das imagens obtidas, mas sem que se troque os eixos ópticos, onde, m_1 , m_2 e m_3 denotam um vetor criado a partir de M (matriz de projeção) da imagem esquerda. Similarmente tem-se m'_1 , m'_2 e m'_3 para a imagem direita.

$$A = \begin{bmatrix} ((C \times C') \times C)^T \\ (C \times C')^T \\ ((C - C') \times (C \times C'))^T \end{bmatrix} [m_2 \times m_3, m_3 \times m_1, m_1 \times m_2] \quad \text{Equação 2.20}$$

$$B = \begin{bmatrix} ((C \times C') \times C)^T \\ (C \times C')^T \\ ((C - C') \times (C \times C'))^T \end{bmatrix} [m'_2 \times m'_3, m'_3 \times m'_1, m'_1 \times m'_2] \quad \text{Equação 2.21}$$

Após a retificação das imagens será obtida a coordenada como é descrita na Equação 2.22.

$$\overset{\cup}{u} = \begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = A \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} \quad \overset{\cup}{u}' = \begin{bmatrix} X' \\ Y' \\ Z' \end{bmatrix} = B \begin{bmatrix} u' \\ v' \\ 1 \end{bmatrix} \quad \text{Equação 2.22}$$

Este procedimento é comumente utilizado pelo baixo esforço computacional (SONKA *et al.*, 1998).

Há casos em que a câmera de imagiamento produz movimentos desconhecidos como rotação e translação e é necessário que se encontre o ponto de correspondência entre as duas imagens. A estimação de ego-movimento permite recuperar a informação de rotação e translação a partir de duas câmeras calibradas. O algoritmo para este procedimento pode ser delineado pelos passos:

Passo 1 : encontrar pontos de correspondência entre os pontos u_i e u'_i , utilizados para a estimação da matriz fundamental.

Passo 2 : os dados devem ser normalizados – isto ajudará a minimizar o número de erros, pelas Equações:

$$\overset{\cup}{u} = H_1 u \quad \text{Equação 2.23}$$

$$\overset{\cup}{u}' = H_2 u' \quad \text{Equação 2.24}$$

onde:

$$H_1 = \begin{bmatrix} a_1 & 0 & c_1 \\ 0 & b_1 & d_1 \\ 0 & 0 & 1 \end{bmatrix} \quad \text{Equação 2.25}$$

$$H_2 = \begin{bmatrix} a_2 & 0 & c_2 \\ 0 & b_2 & d_2 \\ 0 & 0 & 1 \end{bmatrix} \quad \text{Equação 2.26}$$

Após a normalização, os dados devem ter uma ordem similar, isto é, $mean(\overset{\cup}{u}) = 0$ e $var(\overset{\cup}{u}) = [1, 1]^T$.

Passo 3 : computar a estimação da matriz fundamental \hat{F} usando algoritmo linear. Inexatidão numérica pode causar o não cumprimento da propriedade após SVD, $D = diag(k, k, 0)$.

Passo 4 : computar a matriz essencial \hat{E} através da matriz de calibração K e K' que são conhecidas, ou seja:

$$\hat{E} = K^T \hat{F} K' \quad \text{Equação 2.27}$$

Passo 5 : determinar a rotação R (Equação 2.28) e a translação t (Equação 2.29) a partir da estimação da matriz essencial \hat{E} usando SVD. A translação só é determinada até a escala, ou seja:

$$R = UGV^T \text{ ou } R = UG^T V^T \quad \text{Equação 2.28}$$

$$S(t) = VZV^T \quad \text{Equação 2.29}$$

onde, U e V são coordenadas homogêneas, t é o vetor de translação $t = [t_x, t_y, t_z]^T$, G e Z podem ser:

$$G = \begin{bmatrix} 0 & -1 & 0 \\ -1 & 0 & 0 \\ 0 & 0 & -1 \end{bmatrix} \quad \text{Equação 2.30}$$

$$Z = \begin{bmatrix} 0 & -1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad \text{Equação 2.31}$$

2.4 – Correspondência por blocos

Na maioria dos casos as câmeras utilizadas no imagiamento não são calibradas e não se possui informação sobre a forma que foi realizada a aquisição da imagem. Entretanto, é necessário que se encontre o ponto de correspondência das imagens e assim, construir a imagem 3D, o que será possível com o uso dos parâmetros intrínsecos e extrínsecos. Parâmetros intrínsecos de uma câmera, dizem respeito às

medidas métricas de uma imagem. Já os parâmetros extrínsecos de uma câmera dependem da orientação das coordenadas Euclidianas.

A matriz M expressa a projeção perspectiva da primeira imagem que será dividido pelos vetores m^{T_1} , m^{T_2} , m^{T_3} , o que ocorrerá similarmente na segunda imagem conforme apresentado nas Equação 2.32 e 2.33 e Q é a matriz de projeção derivada de M .

$$\text{Primeira imagem} \quad u = \begin{bmatrix} X \\ Y \\ Z \end{bmatrix} \cong MQ = \begin{bmatrix} m^{T_1} \\ m^{T_2} \\ m^{T_3} \end{bmatrix} Q \quad \text{Equação 2.32}$$

$$\text{Segunda imagem} \quad u' = \begin{bmatrix} h' \\ i' \\ j' \end{bmatrix} \cong M'Q = \begin{bmatrix} m'^{T_1} \\ m'^{T_2} \\ m'^{T_3} \end{bmatrix} Q \quad \text{Equação 2.33}$$

A partir das Equações 2.32 e 2.33 chega-se à matriz da Equação 2.34, a qual representa a calibração das câmeras (FAUGERAS e MOURRAIN, 1995).

$$\begin{bmatrix} hm_3^T - jm_1^T \\ im_3^T - jm_2^T \\ h'm_3^T - j'm_1^T \\ i'm_3^T - j'm_2^T \end{bmatrix} X = AX = 0 \quad \text{Equação 2.34}$$

Uma vez, calibradas as câmeras é necessário encontrar os pixels de correspondência de uma imagem na outra, ou seja, é necessário definir um ponto na primeira imagem e posteriormente encontrar o mesmo pixel na segunda imagem. Na Figura 2.13 é apresentado um

pseudo-código do sistema para reconhecimento de pixels correspondentes de uma imagem em outra, chamado de correspondência entre blocos.

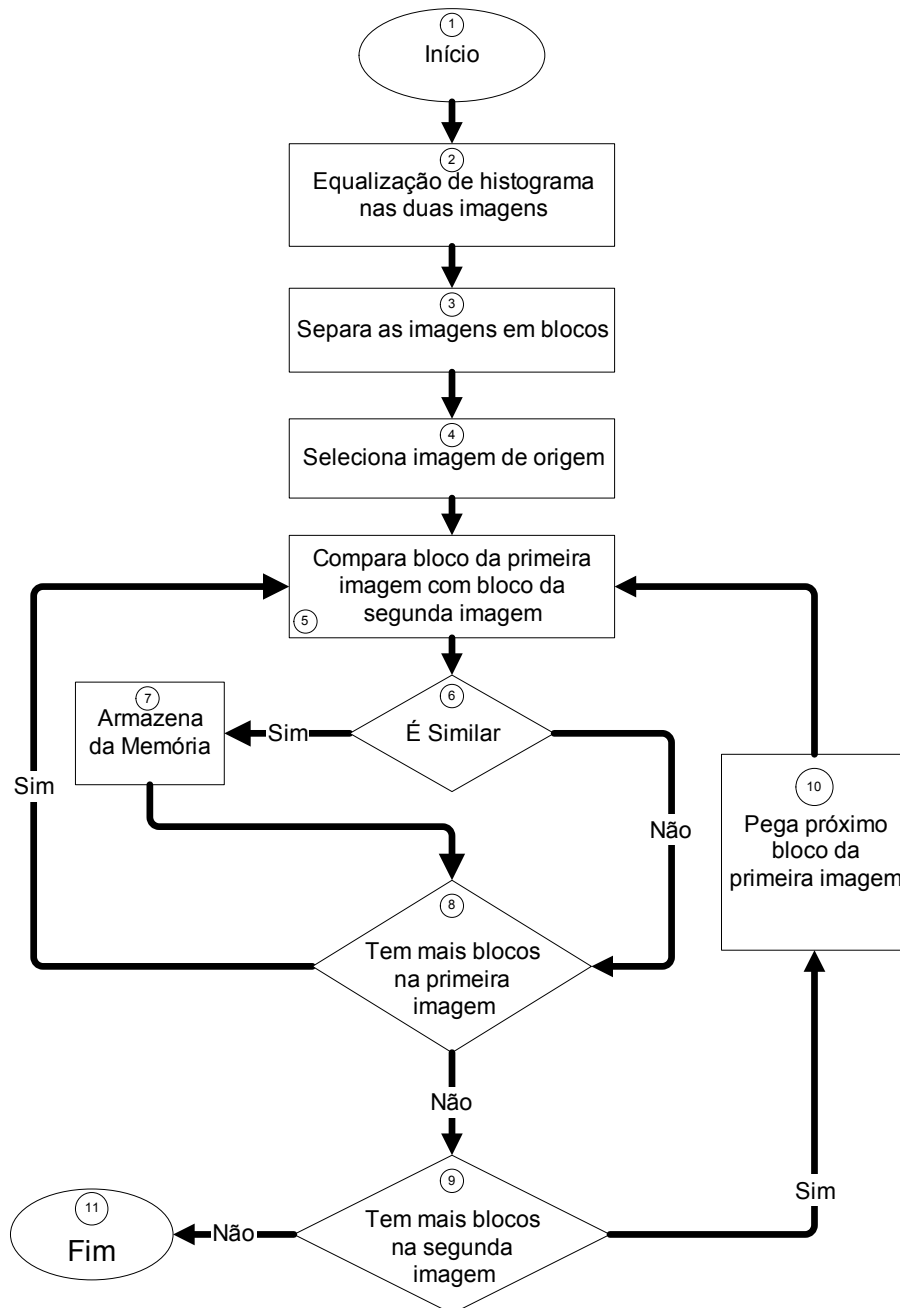


Figura 2.13 - Pseudo-código para reconhecimento de pontos correspondentes.

As medidas de similaridade entre os blocos tomadas no item 5 da Figura 2.13 podem ser, por exemplo, o erro quadrático médio entre as

intensidades dos pixels. A disparidade é obtida considerando as coordenadas onde o erro quadrático médio é mínimo. Este procedimento se apresenta lento, entretanto se as câmeras estiverem em uma superfície plana e com o sistema de coordenadas calibradas. O tempo de processamento para o procedimento com o cálculo de correspondência apenas de um bloco pode ser otimizado e as demais disparidades serão correspondentes à primeira coordenada encontrada (SONKA *et al.*, 1998).

Capítulo 3

Transformada de Hough para reconhecimento de padrões e definição de descritores

Nas técnicas de análise por imagem digital, um dos métodos considerado importante é o reconhecimento de padrões, o que viabiliza a identificação qualitativa e quantitativa de objetos presentes na imagem sob análise.

Diagramaticamente, a técnica de reconhecimento de padrões pode ser ilustrada conforme Figura 3.1, onde através de um diagrama simplificado é vista como uma ferramenta importante no processamento de imagens. Pode-se dizer que o problema de reconhecimento de padrões usualmente é denotado por uma discriminação ou classificação de regras de processamento ou eventos, ou seja, através da descrição física dos objetos a serem reconhecidos, assim gerando novas classes conforme o número de padrões da classe.

Há diferentes soluções de técnicas matemáticas para o reconhecimento de padrões que podem ser reunidas em duas diferentes abordagens: decisão teórica ou estática e abordagem sintética ou lingüística. Na decisão teórica estão as informações de medidas, chamadas de característica que será extraída para o padrão. Alguns problemas de reconhecimento de padrões estão relacionados com a informação estrutural, a qual não somente inclui a capacidade de classificá-lo, mas também a capacidade de descrever aspectos de

associação com outras classes. A informação estrutural pode ser representada por uma hierarquia, na qual cada padrão tem sub-padrões simples e que por sua vez também tem um sub-padrão e assim por diante. Este procedimento é chamado de abordagem sintática. (FU *et al.*, 1976)




Figura 3.1– Modelo para auxílio à tomada de decisão a partir do reconhecimento dos objetos em imagens digitais.

3.1 - Métodos Utilizados no Reconhecimento de Padrões

Como parte das técnicas de processamento de imagens digitais, tem-se a segmentação que é responsável pela subdivisão de uma imagem, em partes ou objetos constituintes, o qual será variável conforme o problema a ser resolvido (DUDA *et al.*, 2001). As chances de uma boa segmentação de uma imagem estão associadas aos cuidados com a especificação do objeto a ser segmentado.

3.1.1 - Métodos para Detecção de Pixels, Linhas e Bordas.

Os métodos de segmentação de imagens estão vinculados à aplicação desejada. Como exemplo, pode-se utilizar a limiarização (*thresholding*), que pode ser utilizada para segmentar uma imagem em tons de cinza e desta forma separar os objetos presentes do fundo, ou determinar bordas de objetos de uma cena, tais regiões são caracterizadas por uma variação brusca na intensidade dos pixels vizinhos em uma imagem e podem ser encontradas utilizando detectores de descontinuidades (detecção de pixels isolados, detecção de linhas e bordas).

A Figura 3. 2 apresenta uma máscara de convolução utilizada na detecção de pixels isolados e pode-se dizer que o pixel é encontrado onde a Equação 3.1 for verdadeira, ou seja:

$$\left| \sum_{i=0}^9 W_i z_i \right| > T \quad \text{Equação 3.1}$$

onde T é um limiar não-negativo.

-1	-1	-1
-1	8	-1
-1	-1	-1

Figura 3.2 – Um exemplo de máscara utilizada para detectar pixels isolados

As linhas que aparecem em uma imagem oferecem grandes possibilidades de identificação dos objetos nela presentes. A

Figura 3.3 mostra um conjunto de máscaras que pode ser utilizado para detectar linhas isoladas em imagens digitais.

-1	-1	-1	-1	-1	2	-1	2	1	2	1	1
2	2	2	-1	2	-1	-1	2	1	-1	2	1
-1	-1	-1	2	1	1	-1	2	1	-1	-1	2
(a)			(b)			(c)			(d)		

Figura 3.3 - Máscaras que podem ser utilizadas para detectar linhas isoladas nas direções (a) 00 (b) 450, (c) 900, (d)-450 (GONZALEZ & WOODS, 1993).

Ao contrário dos métodos de detecção de linhas e de *pixels* isolados, que não apresentam muitas funcionalidades em imagens digitais, as técnicas de bordas têm vasta aplicação na segmentação de uma imagem. As bordas dos elementos presentes em uma imagem são fundamentais no processo de análise de imagens. Isto ocorre porque as bordas delimitam o contorno dos objetos presentes nessa imagem.

A maioria dos processos de detecção de descontinuidade baseiam-se no fato de que tais descontinuidades são, na verdade, uma modificação do nível de cinza do pixel em estudo em relação a seus vizinhos, e assim, tal modificação pode ser determinada pela derivada do sinal no pixel.

A Figura 3.4 ilustra uma descontinuidade presente em uma imagem e o diagrama de sinais que correspondem a estas descontinuidades.




Figura 3.4 - (a) Imagens com descontinuidade, (b) Sinal da descontinuidade, (c) Primeira derivada do sinal e (d) Segunda derivada do sinal.

Também é ilustrada a primeira derivada a qual apresenta o máximo ou mínimo ocorrido. A segunda derivada também é ilustrada e neste caso, verifica-se uma característica de interesse para a detecção das descontinuidades. Como se observa, a segunda derivada ilustra uma passagem por zero (*zero crossing*) exatamente na localização da descontinuidade da intensidade na vizinhança dos pixels. A operação matemática para a segunda derivada é conhecida também como Laplaciano, sendo representada por :

$$\nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2} \quad \text{Equação 3.2}$$

Na prática, uma máscara de convolução pode ser construída de forma a se obter uma aproximação da derivada (utilizando diferenças).

3.1.1.1 - Operador de Sobel

O operador de Sobel que é um operador não-linear é utilizado para a detecção de bordas e apresenta a possibilidade de se determinar a direção da detecção e sua magnitude. A

Figura 3.5 ilustra máscaras que são utilizadas em filtragem de Sobel.

-1	0	1
-2	0	2
-1	0	1

G_x

1	2	1
0	0	0
-1	-2	-1

G_y

Figura 3.5 - Máscaras utilizadas no detector de Sobel.

As aplicações dos operadores G_x e G_y resultam nos gradientes da borda na direção x e y , respectivamente, tornando-se possível a obtenção da magnitude e da direção (ângulo) da borda em cada píxell conforme ilustra a

A magnitude e a direção das bordas são expressas pelas equações 3.3 e 3.4.

$$\text{Magnitude}_{G_x, G_y} = \sqrt{G_x^2 + G_y^2} \quad \text{Equação 3.3}$$

$$a = \arctan\left(\frac{G_x}{G_y}\right) \quad \text{Equação 3.4}$$




Figura 3.6 - Determinação da magnitude dos gradientes e também do ângulo.

É importante observar que, pela forma como que as máscaras do filtro de Sobel são construídas (baseadas no operador diferencial), as mesmas apresentam uma resposta nula em regiões homogêneas (onde a derivada é nula). Magnitudes de pequeno valor indicam que o pixel em estudo não pertence a uma borda bem definida (área mais homogênea).

3.1.2 - Técnicas de Limiarização (THRESHOLD)

O método de limiarização para ser eficiente deve ser capaz de fornecer automaticamente um valor (limiar), para o qual todos os *pixels* com valores de brilho inferiores a este limiar devem ser eliminados (magnitude igual a zero, e sem direção).

Existe um conjunto muito grande de técnicas para a obtenção de um valor limiar, e observa-se que cada uma delas utiliza um critério que considera importante para obter o valor limiar. Como limiarização global simples, P-Tile, Método de Pun, Método de Kapur, Sahoo e outros, Método de Johannsen e Bille, Método do Triângulo, (PARKER, 1994; SAHOO *et al.*, 1988).

Neste trabalho é descrito somente o método de limiarização simples, pois é o mesmo que será utilizado na implementação.

3.1.2.1 - Limiarização global simples

Esta técnica de limiarização é conhecida como a do particionamento do histograma da imagem por um limiar único T . A segmentação é então efetuada, varrendo-se a imagem, pixel a pixel, e rotulando-se cada pixel como sendo do objeto ou do fundo dependendo se o nível de cinza daquele pixel for maior ou menor que T . Uma imagem limiarizada $g(x,y)$ é definida como:

$$g(x,y) = \begin{cases} 1 & \text{se } f(x,y) > T \\ 0 & \text{se } f(x,y) \leq T \end{cases} \quad \text{Equação 3.5}$$

Com isso, pixels rotulados como 1 (ou qualquer outro nível de cinza conveniente) correspondem aos objetos, enquanto que aqueles rotulados com 0 correspondem ao fundo.

A Figura 3.7 ilustra um exemplo de limiarização global utilizando um limiar $T = 90$, que obteve uma segmentação “limpa”, eliminando as sombras e ruídos e deixou apenas os objetos. Os objetos de interesse, são mais claros que o fundo, de maneira que cada pixel com nível de cinza $\geq T$ foi rotulado de branco (255), enquanto que cada pixel com nível de cinza $< T$ foi rotulado de preto (0) (a relação preto e branco poderia ser invertida).




Figura 3.7 - Exemplo de limiarização global – (a) imagem original, (b) resultado da segmentação simples com limiar $T= 90$.

3.2 - O Processamento de Imagens com Reconhecimento de Padrões e suas implicações em reconhecimento de padrões circulares

Nos últimos 30 anos, consideráveis avanços têm ocorrido em reconhecimento de padrões, identificação de padrão e processamento de imagens com aplicações a sistemas de visão. Esses avanços têm levado a uma grande necessidade para o desenvolvimento de métodos, softwares e hardware experimentais para uso em projeto de sistemas de visão (DUDA & MORE, 1973; FUKUNAGA, 1985; FUKUNAGA, 1990; FONGA, 1996; GIACINTO *et al.*, 1997, COSTA *et al.*, 1999; CRUVINEL *at al.*,1999; DOOLEY *et al.*, 1999; CHAHL & SRINIVASAN, 2000; CHU & CHEN, 2001; GOLDBERG *et al.*, 2001). A partir dos conceitos iniciais do processamento de sinais e da teoria de sistemas o processamento de imagens dependia principalmente de filtros lineares e máscaras de convolução. Recentemente, processamento de imagens tem sido desenvolvido principalmente com análise em frequência, análise não-linear e filtragem espaço-variante.

3.3 - Uso da Transformada de Hough no reconhecimento de padrões

A Transformada de Hough (TH) é uma técnica muito utilizada em visão computacional. Sua aplicação até meados da década de 80 estava

muito comprometida devido principalmente a sua complexidade computacional de armazenamento e a dificuldade de um entendimento detalhado de suas propriedades. Contudo, nos últimos anos, muitas pesquisas têm sido realizadas, contribuindo, dessa forma para um melhor aproveitamento de seus recursos.

A utilização da transformada de Hough requer que se conheça um pouco sobre a localização das bordas da imagem, a fim de que sejam considerados apenas os pixels de fronteira. O método de Hough pode ser aplicado no reconhecimento de padrões de curvas desde que as mesmas possam ser descritas na forma paramétrica (linha reta, círculos, elipses, entre outras).


Vários autores têm desenvolvido novos algoritmos, derivados da transformada de Hough original, como (DUDA & HART, 1972; SHAPIRO, 1980; BALLARD, 1981; STOCKMAN & AGRAWALA, 1985; ILLINGWORTH & KITTLER, 1987; ROSENFELD *et al.*, 1988; YUEN *et al.*, 1989; RISSE, 1989; ILLINGWORTH & KITTLER, 1989; JOLIN & ROSENFELD, 1989; SCHALKOFF, 1989; BEN-TZVI & SANDLER, 1990; XU *et al.*, 1990; BEN-TZVI *et al.*, 1990; DAVIES, 1990; GRIMNSON & HUTTENLOCHER, 1990; KIRYATI *et al.*, 1991; DEMPSEY & MCVERY, 1992; HOU *et al.*, 1993; COSTA & SANDLER, 1993; XU & ERKKI, 1993; LEAVERS, 1993; COSTA, 1994a, COSTA, 1994b; HAN *et al.*, 1994; SILVA & GONZAGA, 1995; PEREIRA, 1995; RIBEIRO JUNIOR, 1995; JAIN *et al.*, 1995; COSTA, 1996; SILVA, 1996; ABDELAZEEM, 2002; BESSALAH *et al.*, 2002; ENRIQUE *et al.*, 2002; HAIYUAN *et al.*, 2002; KIMURA *et al.*, 2002; MARTINEZ, 2002; MARTINEZ & CRUVINEL, 2002; ZHU *et al.*, 2002; ZOU & SHI, 2002).

3.3.1 - Fundamentos

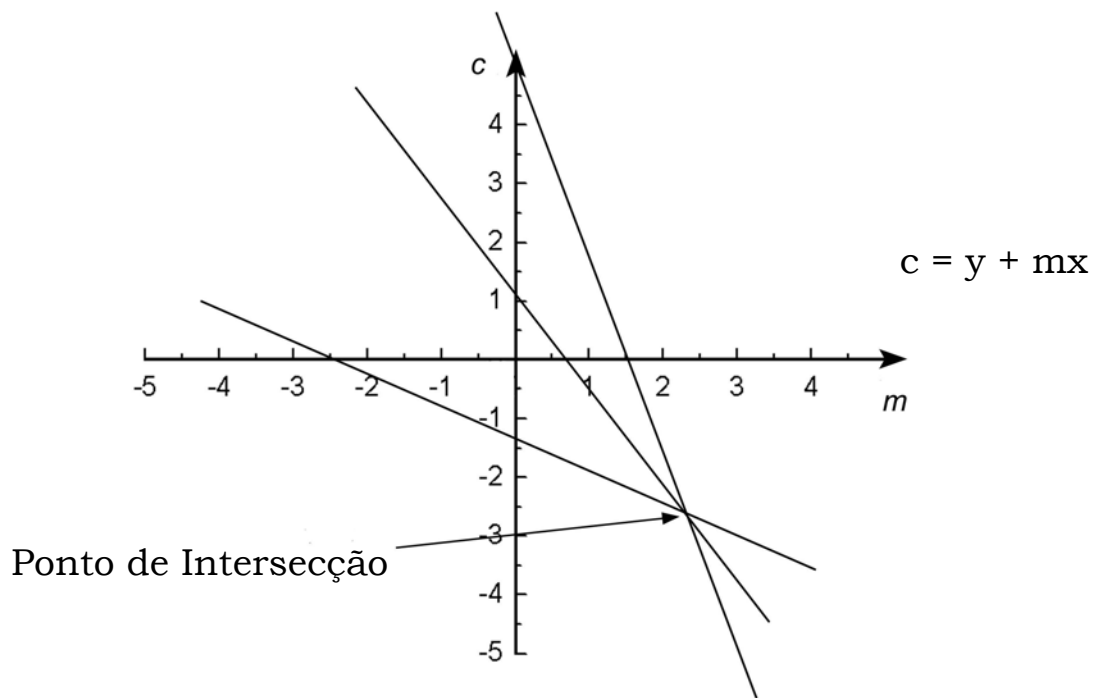
A transformada de Hough foi primeiramente proposta como um método para detecção de padrões complexos em imagens binárias, sendo introduzida por Hough em 1962, sendo publicada em forma de uma patente. Pela proposta de Hough a linha é mapeada usando os parâmetros Inclinação-Intersecção no espaço de parâmetros, definindo, assim, o ponto de intersecção. Todavia, tanto a inclinação como a intersecção, são ilimitadas e essa parametrização tem a desvantagem de ser sensível a escolha do eixo de coordenadas no plano da imagem, o que complica a aplicação da técnica. A Figura 3.8 ilustra um segmento de reta no espaço de imagem e seu correspondente no espaço de parâmetros.

Uma solução para o problema da aplicação da técnica, conforme citado acima, foi proposta por Duda e Hart em 1972, (DUDA & HART, 1972), onde utilizaram coordenadas polares para definir o segmento de reta, trabalhando com os parâmetros Ângulo-Raio ao invés de Inclinação-Intersecção. Com isso, os estudos tomaram outro ritmo com melhoramentos e perspectivas de grandes avanços. No plano da imagem, uma reta parametrizada pode ser representada por dois parâmetros: ρ sendo a distância da normal até a linha da origem da imagem e θ sendo o ângulo dessa normal como eixo horizontal conforme pode ser observado na Figura 3.9. A equação da reta correspondente a essa geometria é apresentada por:

$$\rho = x \cos \theta + y \sin \theta \qquad \text{Equação 3.6}$$

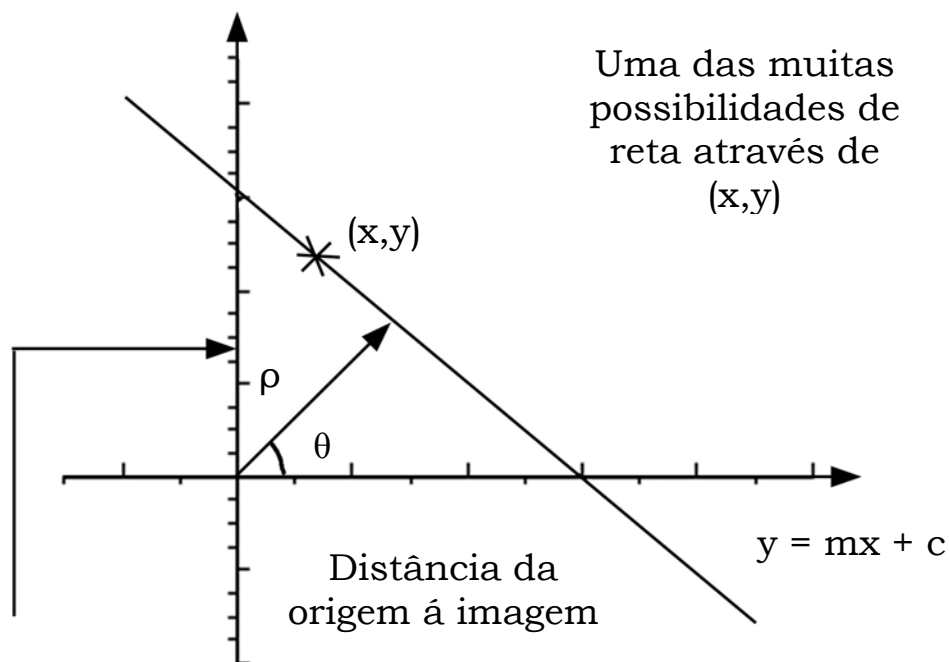


(a)




(b)

Figura 3.8 - A transformada de Hough a) espaço de imagem b) espaço de parâmetro (DUDA & HART, 1972).



(a)



(b)

Figura 3.9 - (a) Representação da equação da reta e, função de suas coordenadas polares. (b) Relação entre definição de reta em coordenadas polares.

Onde tem-se as equações para a Figura 3.9(b):

$$\left. \begin{aligned}
 \rho &= \frac{x}{\cos \theta} + (y - x \operatorname{tg} \theta) \operatorname{sen} \theta \\
 \rho &= \frac{x}{\cos \theta} + y \operatorname{sen} \theta - \frac{\operatorname{sen}^2 \theta}{\cos \theta} \\
 \rho &= x \left(\frac{1 - \operatorname{sen}^2 \theta}{\cos \theta} \right) + y \operatorname{sen} \theta \\
 \rho &= x \cos \theta + y \operatorname{sen} \theta
 \end{aligned} \right\} \text{Equação 3.7}$$

Os novos parâmetros utilizados para representar o espaço são definidos agora por ρ e θ . Logo, o problema de detectar pontos colineares pode ser convertido no problema de se encontrar curvas concorrentes.

As propriedades para se transformar ponto em curva são:

- **Propriedade 1** - Um ponto no plano da imagem corresponde a uma curva senoidal no espaço de parâmetros;
- **Propriedade 2** - Um ponto no espaço de parâmetros corresponde a uma reta no plano da imagem;

- **Propriedades 3** – Pontos pertencentes à mesma linha reta no plano da imagem correspondem a curvas através de um ponto no espaço de parâmetros;
- **Propriedades 4** - Pontos pertencentes à mesma curva no espaço de parâmetros correspondem a linhas através do mesmo ponto no plano da imagem.

Na Figura 3.10 tem-se esquematicamente apresentada a propriedade de reflexão, onde os pontos “A”, “B” e “C” se repetem quando a senoide inicia um novo ciclo, entretanto com sinal negativo.

Através das propriedades, é feito o mapeamento das curvas no arranjo acumulador (a construção do arranjo acumulador bidimensional é definida dentro de um erro aceitável em ρ e θ formando uma grade pré-estabelecida). Esta grade pode ser limitada no intervalo $0 \leq \theta \leq \pi$ e $-R \leq \rho < R$, onde R é o tamanho da célula, desde que pontos fora desse retângulo correspondam a linhas no plano da imagem que não cruzem a célula. Com a limitação de θ , toda linha no plano x - y corresponde a um único ponto no plano $(\rho$ - $\theta)$. Com a equação paramétrica do segmento de reta a cada ponto (x,y) do espaço imagem, a curva correspondente é colocada no arranjo incrementando-se de uma unidade o contador em cada célula ao longo da curva.

A análise do arranjo revela células que possuem números elevados de contagens. Esses valores de contagem representam, para cada célula, dentro de um erro de quantização, a quantidade de pontos coincidentes de uma reta. Portanto, o método da transformada de Hough requer a identificação desses máximos locais. Muitas vezes ocorrem vários picos altos próximos uns dos outros no arranjo. Com isso, existe a necessidade de utilizar um limiar pré-estabelecido para filtrar erros e promover aproximações, assim, busca-se identificar realmente os parâmetros da imagem.

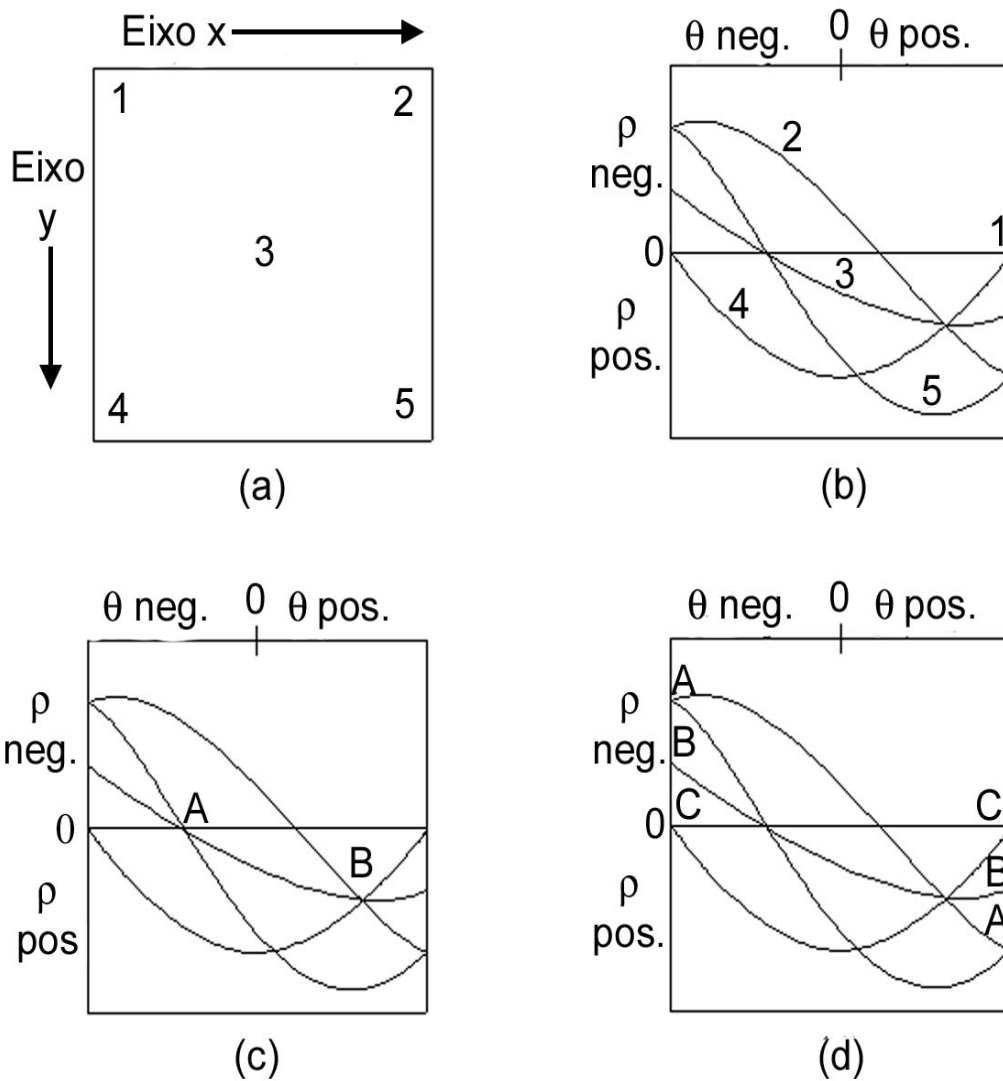


Figura 3.10 - Ilustração da aplicação da transformada de Hough. (a) Pontos no espaço da imagem. (b) Mapeamento dos pontos no espaço($\rho - \theta$). (c) Detecção das propriedades de colinearidade. Ponto A denota intersecção de curvas correspondentes aos pontos 1, 3 e 4.(d) Propriedade de reflexão da transformada de Hough.

Os valores de limiares estão diretamente relacionados às características de cada imagem.

3.3.2 - Generalização da Transformada de Hough e Rápida

A transformada de Hough Generalizada é uma variação da transformada de Hough original. Ballard em 1981, utilizou um mapeamento entre o espaço da imagem e o espaço da transformada de Hough (BALLARD, 1981). A imagem inicialmente é tratada por operadores de borda. Os operadores mais comuns são de dois tipos: o operador de Gradiente e o operador de Hueckel (HUECKEL, 1973), os quais transformam os níveis de cinza da imagem em uma rampa e um degrau, respectivamente. Com isso, cada pixel na imagem não contém mais informações do nível de cinza mas, ao contrário, cada pixel contém uma magnitude e direção representando a orientação da mudança do nível de cinza local.

Li e colaboradores (LI *et al.*, 1985) propuseram um novo enfoque à transformada de Hough, usando os princípios de formulação do hiperplano para o conjunto de pixels do espaço de parâmetros. Esses hiperplanos são divididos gradativamente por um algoritmo em hipercubos de baixa e alta resolução. Em seguida é realizada uma contagem nos hiperplanos e um valor de limiar, determinado inicialmente, o que limita a criação de subdivisões dos hipercubos. A decisão se um hipercubo recebe um voto de um hiperplano dependerá do hiperplano cruzar o hipercubo. Esse algoritmo foi chamado de Transformada Rápida de Hough. Esse enfoque hierárquico leva a uma redução significativa da complexidade computacional e o requerimento e armazenamento simultâneo.

3.3.2 - Transformada de Hough para objetos circulares

Em termos de objetos circulares Duda e Hart (DUDA & HART, 1972) sugeriram a utilização da transformada de Hough para retas adaptado para circunferências. Pode-se ter uma circunferência é apresentada por uma equação paramétrica e a transformada de Hough pode ser aplicada. A equação de uma circunferência é apresentada por:

$$(x - a)^2 + (y - b)^2 = c^2, \quad \text{Equação 3.8}$$

onde a e b são coordenadas do centro da circunferência e c o seu raio de curvatura.

Assim, em todos os pixels do plano da imagem e aplicando a equação:

$$(x_i - a)^2 + (y_i - b)^2 = c^2, \quad \text{Equação 3.9}$$

tem-se que cada pixel do plano da imagem irá gerar uma circunferência no espaço de parâmetros. A partir da transformação do espaço imagem, através de transformada de Hough circular, é gerado um espaço onde os pontos da imagem correspondem a circunferências no espaço de parâmetros. Os pontos (a, b) são assim, armazenados no arranjo acumulador. O cruzamento das circunferências traçadas no espaço de parâmetros (a, b) define as coordenadas do centro de uma circunferência e o valor acumulado nesta célula define quantos pixels pertencem à circunferência.

Em Low (LOW, 1991) encontra-se como detectar circunferências com Transformada de Hough, escolhendo a representação paramétrica da circunferência. Assim, mudando do plano de imagem para o espaço de parâmetros tem-se a Equação 3.10.

$$(a - X_i)^2 + (b - Y_i)^2 = c^2 \quad \text{Equação 3.10}$$

A aplicação da transformada de Hough consiste em mudar a imagem do plano cartesiano para o espaço de parâmetros. Isto significa que cada pixel do plano cartesiano (imagem) será convertido em circunferência no espaço de parâmetros.

Desta forma dada uma imagem com cinco pixels, como a apresentada na Figura 3.11 e querendo saber se existe pixels que possam compor a imagem de uma circunferência de raio igual a $1/\sqrt{2}$. Monta-se um arranjo acumulador com o espaço de parâmetros, conforme ilustra a Figura 3.12.




Figura 3.11– Imagem de uma circunferência, ilustrando os pixels no plano x, y .

Como foi realizado no caso de detecção de retas, define-se um arranjo acumulador, onde serão armazenadas as circunferências traçadas com centro nos pixels da imagem (plano cartesiano).




Figura 3.12 - Espaço de parâmetros a e b para circunferências.

O arranjo acumulador, em princípio pode ser definido com as dimensões iguais às da imagem no plano cartesiano, com tamanho $a.b$, onde o tamanho de a é igual ao tamanho b . Porém, observa-se que se existir um pixel no plano da imagem (cartesiano) que esteja ultrapassando os limites impostos pela borda (uma das quatro extremidades do plano da imagem), a colocação de uma circunferência gerada como centro na borda ultrapassaria os limites do arranjo acumulador, como pode-se observar na Figura 3.13.

Observa-se que neste caso haveria perda de informações. No entanto, para solucionar esse problema, são definidas as dimensões do arranjo acumulador de uma outra maneira, conforme explicado a seguir e ilustrado na Figura 3.14.




Figura 3.13 - Circunferência geradas com centro em pixels que ficam nas bordas da imagem.

Adota-se as suas dimensões nas faixas:

$$-raio \leq a \leq (X_{máx} + raio) \text{ e } -raio \leq b \leq (Y_{máx} + raio) \quad \text{Equação 3.11}$$

Logo, as dimensões do arranjo acumulador serão dadas por:

$$ARRANJO [X_{máx} + 2 \cdot raio] \cdot [Y_{máx} + 2 \cdot raio] \quad \text{Equação 3.12}$$

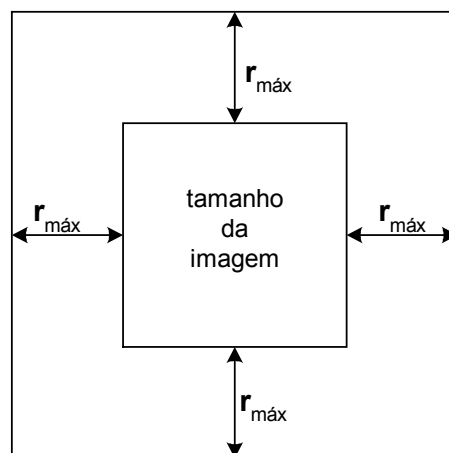


Figura 3.14 - Dimensões do arranjo acumulador.

Tomando cada um dos cinco pixels da Figura 3.11, obtem-se o traçado conforme a Figura 3.12, que lançados no arranjo acumulador obtêm valores entre 0 (zero) e 4 (quatro). O valor quatro é exatamente onde cruzam quatro das cinco circunferências traçadas. Observa-se que o lugar onde cruzam as quatro circunferências possui coordenadas $P[(3,5), (3,5)]$, sendo pixel único. Isto quer dizer que 4 (quatro) pixels no plano imagem pertencem à uma circunferência, cujo centro se encontra nas coordenadas (a, b), que correspondem às coordenadas $P[(3,5),(3,5)]$ e cujo raio de curvatura é $1/\sqrt{2}$ unidades.

Neste exemplo, a imagem era composta de cinco pixels com coordenadas:

$$P1 = [(3),(4)]$$

$$P2 = [(4),(4)]$$

$$P3 = [(5),(3,5)]$$

$$P4 = [(4),(3)]$$

$$P5 = [(3),(3)]$$

O processamento desses pixels gerou o $P[(3,5),(3,5)]$ que é o centro da circunferência e o raio escolhido foi de $1/\sqrt{2}$ unidades. Logo, foi possível localizar uma circunferência e obter a sua Equação, ou seja:

$$(X - 3,5)^2 + (Y - 3,5)^2 = (1/\sqrt{2})^2 \quad \text{Equação 3.13}$$

Neste caso, procura-se apenas circunferências com um determinado valor de raio ($1/\sqrt{2}$ unidades), e para tanto utilizou-se um

arranjo acumulador bidimensional, isto é, com as dimensões $(X_{máx} + 2*raio)$ por $(Y_{máx} + 2*raio)$.

Porém, quando existe uma imagem a ser analisada, e deseja-se detectar possíveis circunferências que possam ter raios de curvaturas de um determinado tamanho (raio mínimo) até um outro valor de raio (raio máximo). Isto se obriga a concluir que se deve prever um conjunto de planos de arranjos, cada um deles para um valor de raio de curvatura. Tem-se agora que trabalhar com um arranjo acumulador tridimensional, isto é, com as duas dimensões já citadas mais uma referente aos possíveis raios de curvatura das circunferências, Arranjo (a, b, c) .

Com o exemplo ilustrado na Figura 3.14 e pesquisando se existem circunferências com raios compreendidos na seguinte faixa: raio mínimo = 0,1 e raio máximo = 3, isto é, $0,1 \leq raio \leq 3$.

Tomando-se o pixel P1 (3, 4) e calculando as circunferências para todos os raios possíveis na faixa supra citada, vai-se armazenar em cada plano do arranjo acumulador uma circunferência traçada com um dos valores de raio. Observando o arranjo tridimensionalmente nota-se a formação de um tronco de cone indo de raio = 0,1 até raio = 3. Então um único pixel no plano da imagem gera um tronco de cone no arranjo acumulador. Ao repetir isto para os demais pixels, obtém-se a formação de cinco cones (troncos de cones) no arranjo acumulador. Tem-se também o cruzamento (interceptação) de quatro cones em um único pixel, que corresponde aos valores: $a = 3,5$, $b = 3,5$, $c = 1/\sqrt{2}$, que são respectivamente às coordenadas do centro da circunferência e de seu raio; determinando os parâmetros já vistos anteriormente .

Este método, permite detectar circunferências no plano imagem, mesmo que esta seja descontínua ou incompleta, como mostra a Figura 3. 15.

Para esta situação geral, as dimensões do arranjo acumulador

estão compreendidas entre:

$$-r_{m\acute{a}x} \leq a \leq (X_{m\acute{a}x} + r_{m\acute{a}x}) \quad \text{Equação 3.14}$$

$$-r_{m\acute{a}x} \leq b \leq (Y_{m\acute{a}x} + r_{m\acute{a}x}) \quad \text{Equação 3.15}$$

$$r_{min} \leq c \leq r_{m\acute{a}x} \rightarrow \text{arranjoacumulador}(a,b,c) \quad \text{Equação 3.16}$$




Figura 3. 15- Circunferências fracionada e incompleta.

No exemplo inicial particularizado para o valor do raio igual a $1/\sqrt{2}$ o arranjo acumulador tinha suas dimensões acrescidas de duas vezes o raio. Com esta nova óptica têm-se suas dimensões acrescidas de duas vezes o raio máximo e a dimensão correspondente ao raio variando de raio mínimo até raio máximo. O que propicia ter o arranjo acumulador com tamanho de dimensão:

$$ARRANJO(X_{m\acute{a}x} + 2 \cdot r_{m\acute{a}x}) \cdot (Y_{m\acute{a}x} + 2 \cdot r_{m\acute{a}x}) \cdot (r_{m\acute{a}x} - r_{min} + 1) \quad \text{Equação 3.17}$$

Para desenvolver um algoritmo que trace as circunferências no arranjo acumulador pode-se utilizar vários métodos. Um dos métodos consistente em utilizar a equação da circunferência diretamente; outro é utilizando o algoritmo de “Bresenhan”. Em qualquer dos métodos o traçado da circunferência é realizado ou para um quadrante apenas ou para um octante apenas, e em seguida basta rebater ou transladar estes pixels calculados para os demais quadrantes ou octetos por simetria.

O algoritmo de Bresenhan é descrito em Low (LOW, 1991) como um método que consiste em calcular o deslocamento pixel a pixel para traçar a circunferência admitindo que do pixel anterior para o posterior (seu sucessor) deslocamos um dx ou um dy ou ambos. E sempre para o primeiro quadrante esse $dy = +1$ ou $dy = 0$ e $dx = -1$ ou $dx = 0$.

Kimme e colaboradores (KIMME *et al.*, 1975) propuseram a implementação de outro método utilizando Hough para detecção de circunferência da seguinte maneira: dado um conjunto de pixels em que se queira detectar uma circunferência, usando a indicação sugerida por Duda (DUDA & HART, 1972) computa-se para cada pixel da imagem digitalizada as operações $r \cos\theta$, $r \sin\theta$, para um dado r fixado, enquanto é incrementado de um valor $\Delta\theta$. Onde $\Delta\theta$ é função de r . Para todo o processamento, isto é, para todos os valores de raio adotados, o produto $(r * \Delta\theta)$ é sempre constante, pois isto permite que todo comprimento de arco entre dois pixels traçados no arranjo acumulador sejam iguais. Então o processamento de cada circunferência exige um número de operações igual a $2\pi/\Delta\theta$. Como o tempo de processamento era significativo, para minimizá-lo foi utilizado gradientes de direção para selecionar a porção de circunferência a ser traçada no arranjo acumulador. O processo constitui em tomar um conjunto de pixels e avaliar a direção central deles, isto é, a direção do possível centro e traçar somente arcos de circunferência com seus limites voltados apenas para a posição central dos pixels da imagem.

Conseqüentemente, ao invés de traçar uma circunferência total, traça-se os arcos com tamanhos pequenos, o que diminui o tempo de processamento e produz menos votos acumulados no arranjo acumulador. Após este procedimento, faz-se um “*threshold*” no arranjo acumulador e obtêm-se os possíveis centros da circunferência. Com estes centros acham-se as circunferências da imagem.

3.4 - Definição e classes nas técnicas de reconhecimento de padrões

Gonzalez e Woods (GONZALEZ & WOODS, 1993) afirmam que reconhecimento de padrões em um determinado nível é fundamental em análise de imagens. Um padrão é uma descrição quantitativa ou estrutural de um objeto ou alguma outra entidade de interesse em uma imagem. Em geral padrão é formado por um ou mais descritores. Entretanto, um padrão é geralmente visto como um arranjo de descritores.

Ao longo do tempo, as técnicas de reconhecimento de padrões produziram para o reconhecimento e a classificação de objetos utilizando imagens digitais. Muitos métodos desenvolvidos no passado trabalhavam bem em objetos 2D ou objetos 3D em diferentes posições, mas ainda continuavam apresentando problemas para um caso tridimensional. Isto gerou muitas pesquisas, as quais levou ao campo de visão computacional dos dias atuais (TRUCCO & VERRI, 1998).

Um padrão é uma estrutura de medidas quantitativas e qualitativas que representam alguma entidade na imagem origem. Um descritor é uma das medidas que compõem a estrutura do padrão. Em geral um padrão é formado de vários descritores, na quantidade necessária para classificá-lo, arranjado de forma a fornecer informações

adequadas a respeito do padrão em questão (FU & MUI, 1981; GIACINTO *et al.*,1997).

Uma das abordagens mais utilizadas na etapa de reconhecimento de padrões é a que faz uso de medições (descritores) sobre os objetos. No caso as medidas podem ser realizadas sobre regiões da imagem ou sobre objetos identificados na etapa de segmentação.

Uma classe é uma família de padrões que possuem características semelhantes entre si (DEVIJVE & KITTLER, 1987), como alunos de uma sala de aula, onde sua principal característica é que todos estão numa mesma série na mesma classe, com idades semelhantes e próximas entre si. A

Figura 3. 16 ilustra classes de padrões e seus descritores.

Classe de Padrões: Animais	Classe de Padrões: Fruta
1 – Espécie	1 – Tipo
2 – Idade	2 – Cor
3 – Raça	3 – Peso

Figura 3. 16 - Representação de classes de padrões e seus descritores.

Os padrões de uma classe são representados na forma de vetores de atributos, com suas descrições quantitativas anexadas a cada linha do vetor, e todos os exemplos de aprendizado da amostra organizado em colunas consecutivas, da forma:

$$\begin{array}{c}
 \text{Amostras} \\
 \xrightarrow{\hspace{10em}} \\
 \mathbf{x} = \begin{pmatrix} x_1 & \cdot & \cdot & \cdot & \cdot & \cdot \\ x_2 & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ x_n & \cdot & \cdot & \cdot & \cdot & \cdot \end{pmatrix} \\
 \downarrow \\
 \text{Atributos}
 \end{array}
 \qquad \text{Equação 3.18}$$

onde cada componente x_i representa um descritor, e n é o número total de descritores do vetor. Cada coluna do vetor representa uma amostra para aprendizado, padrões extraídos da natureza. A dimensão do vetor então será limitada pelo número de descritores que se possa encontrar.

As diversas classes com amostras x , podem ter descritores formando decisões em árvores, cada uma adequada à sua classificação, sendo esta uma poderosa ferramenta na análise de dados. É possível classificar uma amostra de fotografia de satélite para saber qual tipo de plantação, ou se a região corresponde a uma cidade, e se for cidade separar as ruas das casas, tudo baseado em descritores adequados à classificação e organizados em árvores. O nível de resolução destes descritores estará na capacidade do sistema de subdividir e resolver problemas para diferentes regiões na imagem (FU *et al.*, 1976).

3.4.1 - Alguns Descritores usuais

3.4.1.1 - Medida sobre regiões

As medidas sobre regiões dos valores dos pixels são definidas pela

média e pela variância, as quais são dadas respectivamente por:

$$\overline{p(i, j)} = \frac{1}{m \cdot n} \sum_{i=1}^m \sum_{j=1}^n p(i, j) \quad \text{Equação 3.19}$$

$$s^2 = \frac{1}{m \cdot n} \sum_{i=1}^m \sum_{j=1}^n (p(i, j) - \overline{p(i, j)})^2 \quad \text{Equação 3.20}$$

Nesta abordagem os valores obtidos para os parâmetros acima são utilizados para definir o nível da semelhança entre as regiões.

3.4.1.2 - Medidas sobre objetos

Medidas sobre objetos têm recebido uma maior atenção, o que pode ser comprovado pelo grande número de trabalhos que têm sido apresentados na literatura.

Um descritor bastante utilizado para formas ruidosas é o que faz uso de assinaturas, onde dado um objeto, são obtidos sinais unidimensionais. Normalmente é utilizada uma amostragem sobre o contorno do objeto em determinados valores de intervalos τ , denotados $\tau_1, \tau_2, \dots, \tau_n$, gerando os vetores de padrões como $x_1 = r(\tau_1), x_2 = r(\tau_2), \dots, x_n = r(\tau_n)$. Esses vetores tornam-se pontos no espaço euclidiano n -dimensional (GONZALEZ & WOODS, 1993).

A Figura 3.17 ilustra as assinaturas de dois objetos bastante simples (círculo e quadrado).


O reconhecimento dos objetos é realizado comparando as suas assinaturas, no caso utiliza-se alguma métrica para medir as diferenças entre elas. É importante observar que este descritor apresenta invariância com relação à rotação, sendo também possível um tratamento com relação à escala.

3.4.1.3 - Esqueletização


Uma forma alternativa para representar a estrutura de um objeto consiste em reduzi-lo a um grafo, uma das possibilidades para obtenção desse grafo é através da utilização de algum algoritmo de afinamento (também chamado esqueletização).

Costa e Cesar salientam que embora não exista uma definição formal satisfatória para esqueletos, uma maneira informal de defini-los é como sendo a representação da forma tão fina quanto for possível (COSTA & CESAR, 2000).

O esqueleto de uma região pode ser definido pela transformação do eixo médio (*“medial axis transform”* - MAT). A MAT de uma região R com borda B é definida da seguinte maneira: para cada ponto p em R , encontra-se seu vizinho mais próximo em B . Se p tiver mais de um vizinho desse tipo, diz-se que ele pertence ao eixo médio (ou esqueleto) de R . O conceito de “mais próximo” depende da definição de distância e, portanto, os resultados de uma MAT são influenciados pela escolha da medida de distância. A Figura 3.18 ilustra alguns exemplos adotando-se a distância euclidiana.



(a)



(b)

Figura 3.17- Duas fronteiras simples e suas correspondentes assinaturas (distância em função do ângulo) (GONZALEZ & WOODS, 1993).

Embora a MAT de uma região resulte em um esqueleto aceitável intuitivamente, sua implementação direta é tipicamente proibitiva quanto aos aspectos computacionais. A implementação envolve potencialmente o cálculo da distância de cada ponto interior a cada ponto de fronteira de uma região. Numerosos algoritmos para melhorar a eficiência computacional do cálculo da MAT de uma região têm sido propostos. Trata-se tipicamente de restrições segundo as quais a eliminação desses pontos não deve: (1) remover pontos extremos; (2) quebrar a conectividade; (3) causar a erosão excessiva da região.




Figura 3.18 - Eixo médio de três regiões simples.

Em seguida é apresentado um algoritmo, descrito em Gonzalez e Woods (GONZALEZ & WOODS, 1993) para o afinamento de regiões binárias. Em tais regiões os pixels representando o objeto possuem valor 1, enquanto que os pixels de fundo assumem valor 0. O método consiste na aplicação sucessiva de dois passos aos pontos do contorno da região, sendo que um ponto de contorno é definido como um pixel de valor 1 que possua pelo menos um vizinho, em uma vizinhança de oito com valor 0. Tomando-se a definição de vizinhança de 8 ilustrada na

Figura 3.19, o primeiro passo determina que um ponto de contorno p deve ser eliminado se as seguintes condições forem satisfeitas:

- Condição (a): $2 \leq N \leq (p_1) \leq 6$;
- Condição (b): $S(p_1) = 1$;
- Condição (c): $p_2 \cdot p_4 \cdot p_6 = 0$;
- Condição (d): $p_4 \cdot p_6 \cdot p_8 = 0$

em que $N(p_1)$ é o número de vizinhos não-nulos de p_1 , ou seja:

$$N(p_1) = p_2 + p_3 + \dots + p_8 + p_9$$

$S(p_1)$ é o número de transições 0 - 1 na seqüência ordenada $p_2, p_3, \dots, p_8, p_9, p_2$.

A Figura 3.19 ilustra um exemplo para $N(p_1) = 4$ e $S(p_1) = 3$.

0	0	1
1	P_1	0
1	0	1

Figura 3.19 – Ilustração para atendimento às condições a e b. Descrever novamente $N(p_1) = 4$ e $S(p_1) = 3$.

O primeiro passo deve ser aplicado a cada pixel da borda da região binária em consideração, sendo que, se uma ou mais das condições (a)-(d) forem violadas, o valor do pixel em questão não deve

ser modificado. Se todas as condições forem satisfeitas, então o ponto deve ser marcado para ser apagado. No entanto, o ponto não deve ser efetivamente apagado até que todos os pontos da borda tenham sido processados. Esse atraso previne que a estrutura dos dados não seja mudada durante a execução do algoritmo. Uma vez que o primeiro passo tenha sido aplicado a todos os pontos da borda, aqueles que tiverem sido marcados são apagados (ou seja, iguais a 0). Em seguida, o segundo passo deve ser aplicado aos dados resultantes.

No segundo passo, as condições (a) e (b) continuam as mesmas, mas as condições (c) e (d) são modificadas para:

- Condição (c'): $p_2 \cdot p_4 \cdot p_8 = 0$;
- Condição (d'): $p_2 \cdot p_6 \cdot p_8 = 0$;

Alguns passos do processo são ilustrados na Figura 3.20, sendo que em (a) tem seu resultado da aplicação do primeiro passo na fronteira de uma região simples. Os pontos indicam os pixels marcados e subseqüentemente eliminados no final do primeiro passo. Em (b) tem-se os resultados obtidos com o segundo passo, enquanto que em (c) tem-se, finalmente, o esqueleto obtido depois de varias iterações desses dois passos. O esqueleto de uma região com propriedades menos regulares é ilustrado na Figura 3.21.

A importância dos esqueletos no reconhecimento de padrões levou a busca de outras técnicas para a obtenção dos mesmos, destacando-se a transformada da distância e métodos morfológicos. (PARKER, 1994). Em Betelu e Tannenbaum (BETELU *et al.*, 2001), é discutido uma nova abordagem para o cálculo de esqueletos baseado em distâncias afins, sendo portanto invariante a transformações afins.

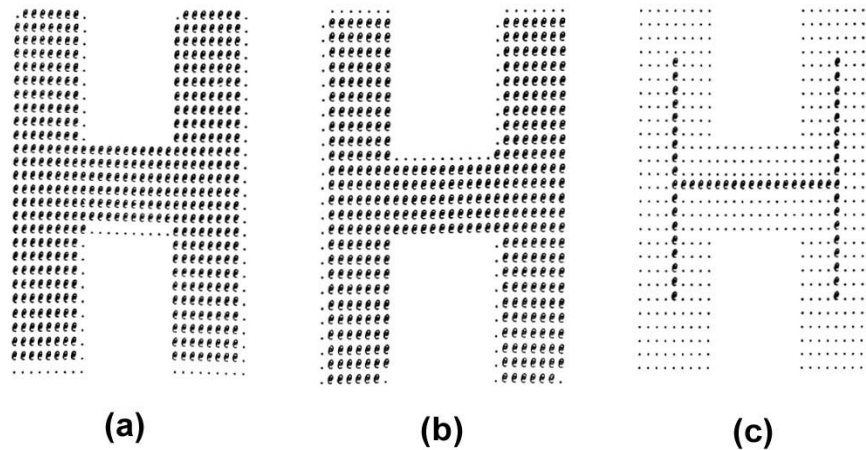


Figura 3.20 - (a) Resultado após aplicação do primeiro passo do algoritmo de afinamento durante a primeira iteração pela região; (b) Resultado após aplicação do segundo passo; (c) Resultado final. (GONZALEZ & WOODS, 1993)



Figura 3.21- Exemplo de afinamento de uma imagem (GONZALEZ & WOODS, 1993)

Após a obtenção dos esqueletos é realizada uma comparação, levando em consideração o número de terminações, os comprimentos das ligações, o número de conexões e outras características existentes nos esqueletos. O reconhecimento dos objetos é feito caso sejam obtidos valores semelhantes nestas características citadas.

3.4.1.4 - Deficiência convexa

A deficiência convexa é melhor empregada quando a fronteira do objeto conter uma ou mais concavidades significativas que carreguem informações sobre a forma. A Figura 3.22 ilustra uma região *S* e após a obtenção do eixo convexo, é identificada a deficiência convexa do objeto (em cinza).

As fronteiras digitais tendem a serem irregulares devido à digitalização (amostragem), ruídos e variações na segmentação. Esses efeitos resultam em uma deficiência convexa possuindo pequenos componentes não significativos espalhados aleatoriamente pela fronteira. A eliminação dessas irregularidades pode ser feita através de um pós-processamento ou utilizar a suavização de fronteira antes do particionamento.

Quando aplicada no reconhecimento de padrões, a deficiência convexa é utilizada da seguinte forma: dado dois objetos que se deseja verificar se são semelhantes (reconhecer um a partir do outro), obtém-se as deficiências convexas de ambos e verifica-se a quantidade de deficiências que ocorrem em cada um; conclui-se que os objetos são iguais se possuírem a mesma quantidade.




Figura 3.22 - A região (S) e sua deficiência convexa (em cinza).

3.4.2 - Descritores de Fronteiras

Os seguintes descritores de fronteiras são vistos na literatura como descritores simplificados e de rápida resposta, ou seja: Descritor para comprimento do contorno, diâmetro do objeto, curvatura e descritores de Fourier.

Quanto ao descritor para comprimento do contorno tem-se que ele é um dos descritores mais simples que pode ser utilizado para calcular o comprimento do contorno. Neste caso, o comprimento poderia ser obtido da seguinte forma: escolhe-se um ponto de partida no contorno do objeto, em seguida busca-se o seu vizinho, somando-se o valor 1, caso o mesmo se encontre em uma vizinhança 4, ou soma-se o valor $\sqrt{2}$, caso seu vizinho esteja na vizinhança diagonal. Este processo continua até que todo o contorno tenha sido percorrido.

O descritor trivial é o diâmetro do objeto, que pode ser obtido por:

$$\text{Diam}(B) = \max_{i,j} [D(p_i, p_j)] \quad \text{Equação 3.21}$$

sendo que $D(p_i, p_j)$ é a medida de distância entre p_i e p_j que são pontos no contorno de B . Tanto o valor do diâmetro, como também a orientação da linha que conecta os dois pontos extremos que definem o diâmetro (*maior eixo* do objeto) podem ser utilizados como descritores do objeto.

A curvatura é um dos mais importantes atributos que podem ser extraídos de um contorno (COSTA & CESAR, 2000), sendo definida por:

$$k(t) = \frac{\left(\frac{dx(t)}{dt} \cdot \frac{dy(t)}{dt} \right) - \left(\frac{dx(t)}{dt} \cdot \frac{dy(t)}{dt} \right)}{\left(\frac{d^2x(t)}{dt^2} + \frac{d^2y(t)}{dt^2} \right)^{3/2}} \quad \text{Equação 3.22}$$

onde se supõe o contorno como sendo uma curva paramétrica

$$c(t) = (x(t), y(t)) \quad \text{Equação 3.23}$$

Em geral, a obtenção de medidas confiáveis da curvatura de um ponto em uma fronteira digital é difícil, visto que tais fronteiras tendem a ser localmente não contínuas. Entretanto, a utilização da diferença entre as inclinações de segmentos adjacentes de fronteira (que tenham

sido representados como segmentos de retas) como um descritor da curvatura no ponto de interseção dos segmentos.

No reconhecimento de padrões as curvaturas podem ser utilizadas de varias maneiras, entre as quais de modo semelhante a assinaturas. Além disso, vários outros descritores podem ser obtidos a partir da curvatura, tais como: Curvatura Máxima, Curvatura Mínima, Pontos de Inflexão e Energia de Dobramento (também conhecida como Energia da Borda).

Os Descritores de Fourier são capazes de capturar a essência geral de uma fronteira. Essa propriedade possui grande valor, uma vez que esses coeficientes carregam informação sobre a forma. Portanto, eles podem ser usados para diferenciar formatos de fronteiras distintas. Em seguida é apresentado o modo como esses descritores são obtidos a partir dos pontos de uma fronteira digital.

A Figura 3.23 ilustra uma fronteira digital de N pontos no plano xy . Começando de um ponto arbitrário (x_0, y_0) , pode-se encontrar os pares coordenados $(x_0, y_0), (x_1, y_1), (x_2, y_2), \dots, (x_{N-1}, y_{N-1})$ ao longo da fronteira no sentido anti-horário. Essas coordenadas podem ser expressas na forma $x(k) = x_k$ e $y(k) = y_k$. Com essa notação, a própria fronteira pode ser representada como uma seqüência de coordenadas $s(k) = [x(k), y(k)]$, para $k = 0, 1, 2 \dots N-1$. Além disso, cada par coordenado pode ser tratado como um número complexo da forma:

$$s(k) = x(k) + jy(k) \qquad \text{Equação 3.24}$$

para $k = 0, 1, 2, \dots, N-1$. Ou seja, o eixo x é tratado como o eixo real, enquanto que o eixo y como o eixo imaginário de uma seqüência de números complexos. Embora a interpretação da seqüência tenha sido reformulada, a própria natureza da fronteira não foi mudada.

Obviamente, essa representação possui uma grande vantagem: ela reduz um problema de duas dimensões a uma dimensão.

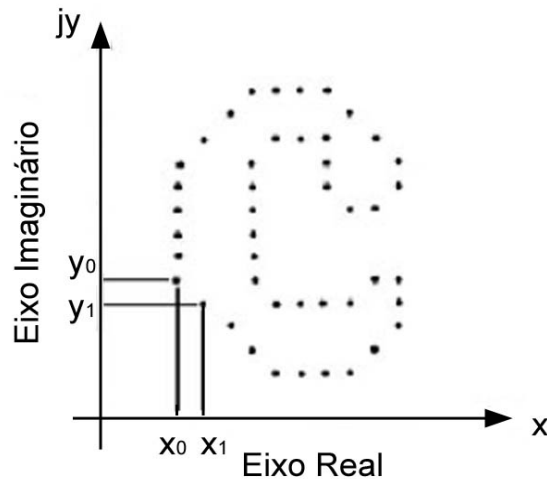


Figura 3.23 - Uma fronteira digital e sua representação por uma seqüência complexa. Os pontos (x_0, y_0) e (x_1, y_1) são (arbitrariamente) os dois primeiros pontos da seqüência.

A transformada discreta unidimensional de Fourier de $s(k)$ é definida como:

$$A(u) = \frac{1}{N} \sum_{k=0}^{N-1} s(k) \exp\left[\frac{j2\pi uk}{N}\right] \quad \text{Equação 3.25}$$

para $u = 0, 1, 2, \dots, N - 1$. Os coeficientes complexos $A(u)$ são chamados de *descritores de Fourier* da fronteira. A transformada inversa de Fourier de $A(u)$ reconstrói $s(k)$, ou seja:

$$S(k) = \sum_{u=0}^{N-1} A(u) \exp\left[\frac{j2\pi uk}{N}\right] \quad \text{Equação 3.26}$$

para $k = 0, 1, 2, \dots, N - 1$. Supondo, entretanto, que no lugar de todos os valores $A(u)$, apenas os primeiros M coeficientes sejam usados. Isso é equivalente a igualar $A(u) = 0$ para $u > M - 1$ na equação acima como resultado, a seguinte aproximação de $s(k)$ pode ser considerada:

$$s(k) = \sum_{u=0}^{M-1} A(u) \exp\left[\frac{j2\pi uk}{N}\right] \quad \text{Equação 3.27}$$

para $k = 0, 1, 2, \dots, N - 1$. Deve ser observado que quanto menor for o valor de M , mais detalhes serão perdidos na fronteira. A Figura 3.24 ilustra um objeto original ($N = 64$) e as suas reconstruções com valores de M variando de 2 até 62.

A sensibilidade dos descritores, quanto à rotação, translação e mudança de escala podem ser tratadas com o auxílio de algumas propriedades básicas dos descritores de Fourier, ou seja:

- a) Transformação de Identidade com Fronteira $s(k)$ e Descritor de Fourier $A(u)$;
- b) Transformação de Rotação com Fronteira $s_r(k) = s(k)e^{j\theta}$ e Descritor de Fourier $A_r(u) = A(u) e^{j\theta}$;
- c) Transformação de Translação com Fronteira $s_t(k) = s(k) + \Delta_{xy}$ e Descritor de Fourier $A_t(u) = A(u) + \Delta_{xy} \delta(u)$;
- d) Transformação de Mudança de Escala com Fronteira $s_s(k) = as(k)$ e Descritor de Fourier $A_s(u) = a A(u)$;

- e) Transformação de Pontos de Partida com Fronteira $s_p(k) = s(k - k_0)$ e Descritor de Fourier $A_p(u) = A(u) e^{-j2\pi k_0 u/N}$.




Figura 3.24- Exemplos de reconstrução de descritores de Fourier para vários valores de M .

3.4.2.1 - Descritores Regionais

Os descritores regionais podem ser definidos por áreas, fronteiras e compacidade.

Entre os descritores regionais a área da região é um dos mais imediatos, sendo definida pelo número de pixels contidos dentro de sua fronteira.

O perímetro é um outro descritor simples, consistindo no tamanho da fronteira do objeto, sendo definido de maneira equivalente ao comprimento.

Há também o descritor de compacidade que é obtido com uma combinação dos dois anteriores e definido conforme a Equação 3.28.

$$\text{Compacidade} = \frac{(\text{perímetro})^2}{\text{área}} \qquad \text{Equação 3.28}$$

Uma importante característica deste descritor é a sua invariância à mudanças de escala e também de rotação.

3.4.2.2 - Descritores topológicos

Os descritores topológicos atuam segundo as propriedades básicas a topologia, que garantem que se uma região (objeto de interesse) contem um certo número de buracos. A quantidade não é alterada caso ocorram rotações ou esticamentos.

A Figura 3.25 exhibe uma região com 2 buracos. Nota-se entretanto que, o esticamento da figura afeta as distâncias e portanto, não se deve depender desse parâmetro para o processamento.




Figura 3.25- H_1 e H_2 representam número de buracos.

Uma outra propriedade topológica útil para a descrição de regiões é o número de componentes conexos. Um componente conexo é um subconjunto de tamanho máximo tal que quaisquer dois pontos nesse subconjunto possam ser unidos por uma curva conexa que também pertença completamente ao subconjunto. A Figura 3.26 mostra uma região com três componentes conexos.




Figura 3.26- C_1 , C_2 e C_3 representam o número de componentes complexos.

O número de buracos H e de componentes conexos C em uma imagem podem ser utilizados na definição do *número de Euler* E , que é uma propriedade topográfica, dada por:

$$E = C - H \qquad \text{Equação 3.29}$$

O número de Euler é útil se caracterizar topologicamente uma imagem.

Capítulo 4

Desenvolvimento do sistema para tomada de decisão baseado na geração de imagens estereoscópicas e reconhecimento de padrões circulares

Neste capítulo é apresentado a metodologia desenvolvida e a descrição do sistema de imagem tridimensional utilizando técnicas de imageamento estereoscópico e reconhecimento de padrões circulares com auxílio da transformada de Hough.

4.1 – Modelagem de objetos do sistema para tomada de decisão baseado em imageamento estereoscópico.

A implementação do sistema para tomada de decisão baseado em imageamento estereoscópico foi realizada com base no uso de computador do tipo IBM-PC sob plataforma Microsoft Windows XP® com ferramenta de programação *Borland Builder 5.0*®.

O sistema é apresentado em cinco blocos conforme ilustra a Figura 4.1. O primeiro bloco chamado de Bloco de Entrada é responsável pelas

entradas e aquisições das imagens respectivas a cada uma das câmeras.

O próximo bloco é o de Pré-processamento individual, o qual é responsável pela adequação e melhorias em cada uma das imagens adquiridas com cada uma das câmeras.

Com as imagens preparadas e adequadas a elas são aplicados os métodos de pré-processamento coletivos que possibilitam a extração das informações necessárias para a reconstrução tridimensional como o reconhecimento de pixels de correspondência para aplicação dos cálculos do imageamento estereoscópico e reconhecimento de padrões circulares.

O sistema permite a armazenagem das informações durante o processamento como por exemplo, das imagens de entrada, intermediárias, de saída e do relatório final.

Finalmente, o último bloco é o responsável pela apresentação dos resultados após cada uma das etapas.

4.2 Entrada do Sistema

A entrada do sistema é realizada através de duas câmeras idênticas do tipo *WebCam* de marca *Creative®* conectadas através da *Universal Serial Bus (USB)*. Ambas as câmeras são posicionadas com uma distância conhecida e calibradas.

A porta de comunicação *USB* foi criada para revolucionar a conexão de dispositivos externos como gravadores de CD, câmeras fotográficas digitais, câmeras vídeo dentre outros, em computadores com maior facilidade e rapidez.

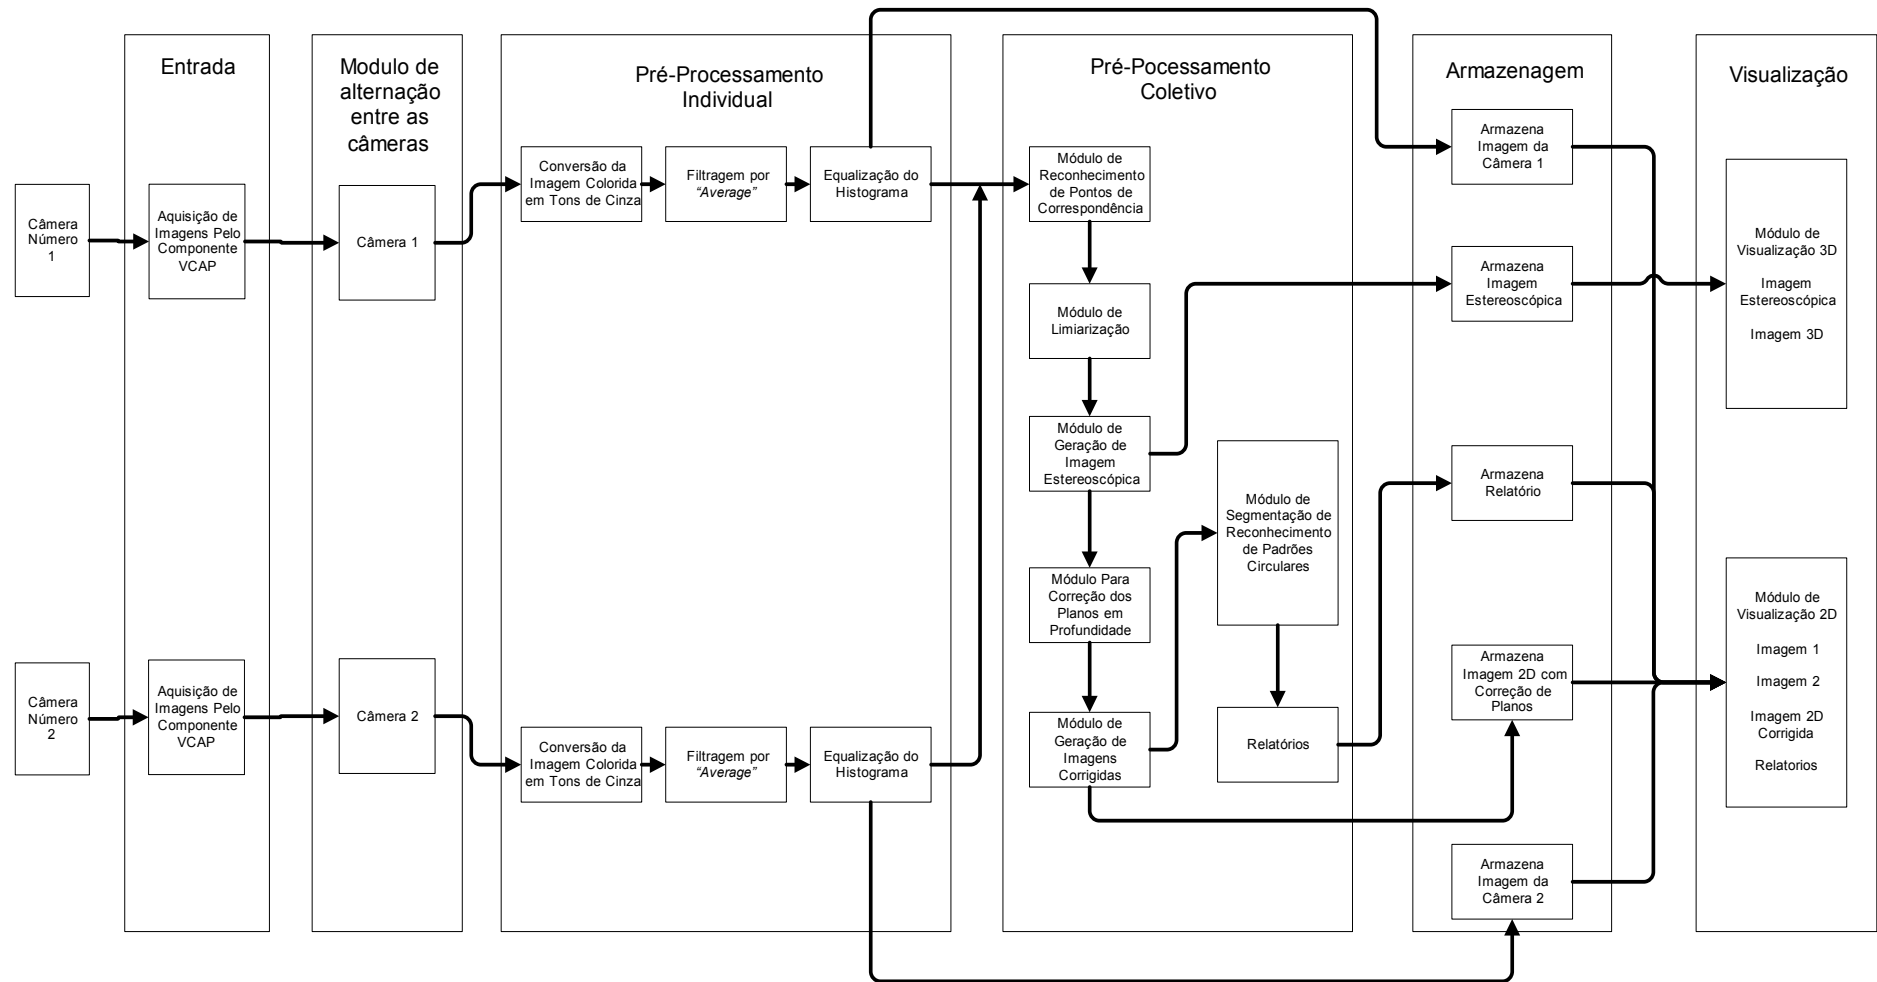


Figura 4.1 - Diagramação do sistema de imagiamento estereoscópico com reconhecimento de padrões circulares.

Atualmente, existem dois tipos básicos de USB, a versão 1.1 criada inicialmente com capacidade de transmissão de 12 *megabits* por segundo, e a versão 2.0 que atualmente vem sendo difundido com taxa de transmissão podendo a chegar a 480 *megabits* por segundo. A distância do cabo que conecta o dispositivo a porta de *USB* convenientemente não pode ultrapassar o tamanho de 5m. (*USB IMPLEMENTERS FORUM*, 2003)

A câmera utilizada no projeto tem como especificações um sensor colorido CMOS 352x288, controle de exposição a claridade automático e interface de comunicação *USB V 1.1*, conforme ilustrado na Figura 4.2.



Figura 4.2 - Foto ilustrativa da câmera WebCam Creative®.

A Tabela 1 apresenta as principais características da *Webcam Creative®*.

Tabela 1 - Principais características da WebCam Creative®.

Números de Quadros por Segundo	Cor	Número de Pixels da Imagem
1 – 30	24 bits	160x120
	20 bits	176x144
	12 bits	320x240
		352x288

As imagens são adquiridas através do componente *Visual Component Library (VCL)*, VCAP desenvolvida por *Egor Averchenkov* em 2001. Esta componente visual proporciona a exibição e a captura de ambas as câmeras.

O componente VCAP possui rotinas prontas para a aquisição de imagens no formato *Bit Map Picture (BMP)*, captura de vídeo com ou sem compressão, exibição direta das câmeras e rotinas de tratamento de erros. Cada uma destas rotinas prontas são independentes assim possibilitando o acionamento ou não das mesmas através de uma classe chamada *TGraphConfig* conforme ilustra a Figura 4.3.

```
Class PASCALIMPLEMENTATION TGraphConfig : public System::TObject
{
    typedef System::TObject inherited;

public:
    AnsiString VCapSource;
    AnsiString ACapSource;
    AnsiString VComp;
    AnsiString AComp;
    TACapMode ACapMode;
    TVCapMode VCapMode;
    AnsiString VCompState;
    bool WantCapture;
    bool WantPreview;
    bool WantBitmaps;
    bool WantAudio;
    bool WantDVAudio;
    bool WantAudioPreview;
    Graphics::TPixelFormat PixelFormat;
    TDVResolution DVResolution;
    AnsiString CaptureFileName;
    bool UseTempFile;
    AnsiString TempCaptureFileName;
    bool DoPreallocFile;
    unsigned PreallocFileSize;
    void __fastcall Clear(void);
    void __fastcall RestoreGraph(AnsiString layout);
    bool __fastcall RestoreGraphFromStream(Classes::TStream* Stream);
    AnsiString __fastcall SaveGraph();
    bool __fastcall SaveGraphToStream(Classes::TStream* Stream);
    __fastcall TGraphConfig(void);

public:
    #pragma option push -w-inl
    /* TObject.Destroy */ inline __fastcall virtual ~TGraphConfig(void) {}
    #pragma option pop
};
```

Figura 4.3 - Código da Classe TGraphConfig de configuração do componente VCAP.

Da classe *TGraphConfig* é utilizado somente as variáveis *WantPreview* para exibição em tempo real da câmera, *WantBitmaps* para a aquisição de imagens de exibição da câmera, *VCapSource* que listas os *drivers* de todas as câmeras instaladas no computador e *VCapMode* que lista todos os modos disponível para a câmera selecionada. O sistema apenas utiliza a exibição e a captura de imagens no formato BMP.

Quando o sistema é iniciado é realizada a pesquisa sobre todos os dispositivos de câmeras instalados, conforme ilustrado pelo fluxograma da Figura 4.4.

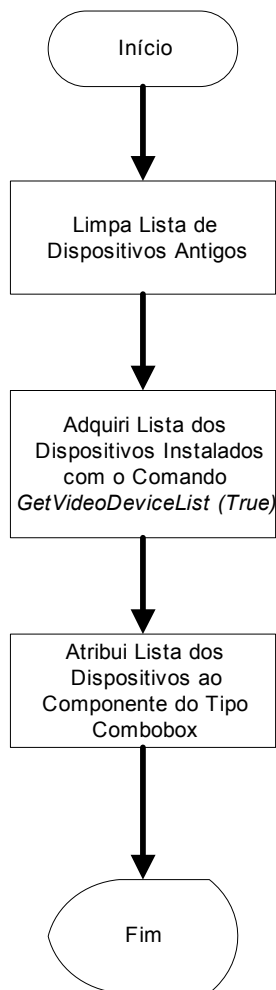


Figura 4.4 - Fluxograma de atualização da lista de dispositivos de câmeras instalado.

Quando o *driver* da câmera é alterado, automaticamente o componente VCAP aciona a propriedade *OnChangeDevice*. Nesta propriedade são executadas a listagem de todos os novos modos de exibição do novo *driver* como apresentado na Figura 4.5.

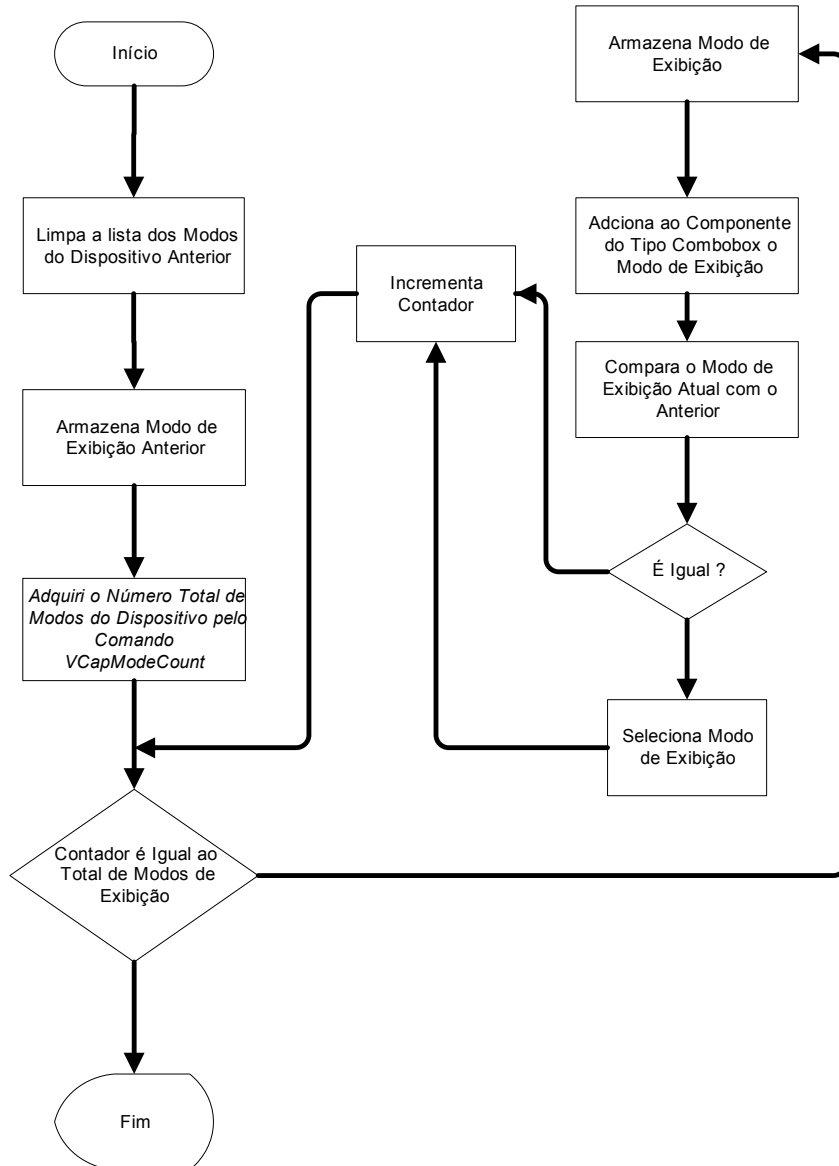


Figura 4.5 - Fluxograma de atualização de modos de exibição.

Outra propriedade utilizada é a *OnBitmapGrabbed* que possibilita a aquisição das imagens da câmera ativa em exibição. O componente VCAP é utilizado para ambas as duas câmeras, assim cada uma das

imagens são armazenadas com o pré-nome “Cam1” e “Cam2”, respectivos a câmera 1 e câmera 2 seguido do contador respectivo a imagem que esta sendo adquirida e finalmente a extensão (*.bmp).

O número de imagens que serão adquiridas é definido previamente pelo usuário do sistema. Durante a execução do programa esse número é multiplicado por dois para que possa considerar ambas as câmeras no processo. As imagens são adquiridas de forma alternada, chaveando os *drivers* das câmeras para garantir maior confiabilidade no reconhecimento dos blocos de correspondência.

4.3 – Pré-Processamento Individual

Neste módulo do sistema ocorre a melhoria das imagens para os passos de reconhecimento de pontos de correspondência. Por esta razão este é um dos principais módulos que compõe o sistema de imageamento estereoscópico.

A primeira etapa do pré-processamento individual é a conversão da imagem de entrada em tons de cinza conforme fluxograma que é apresentado na Figura 4.6.

Com as imagens em tons de cinza é aplicado o filtro de *Average*. Este filtro baseia-se na média dos pixel de imagens adquiridas de uma mesma câmera. Visando maior flexibilidade do sistema o filtro é aplicado nas duas entradas e repetido conforme condição pré-estabelecida pelo usuário. Sempre ocorre que a imagem com a média obtida é processada com as novas entradas. A Figura 4.7 ilustra as etapas da filtragem por *Average*, onde para cada uma das entradas é repetido para cada uma das câmeras.

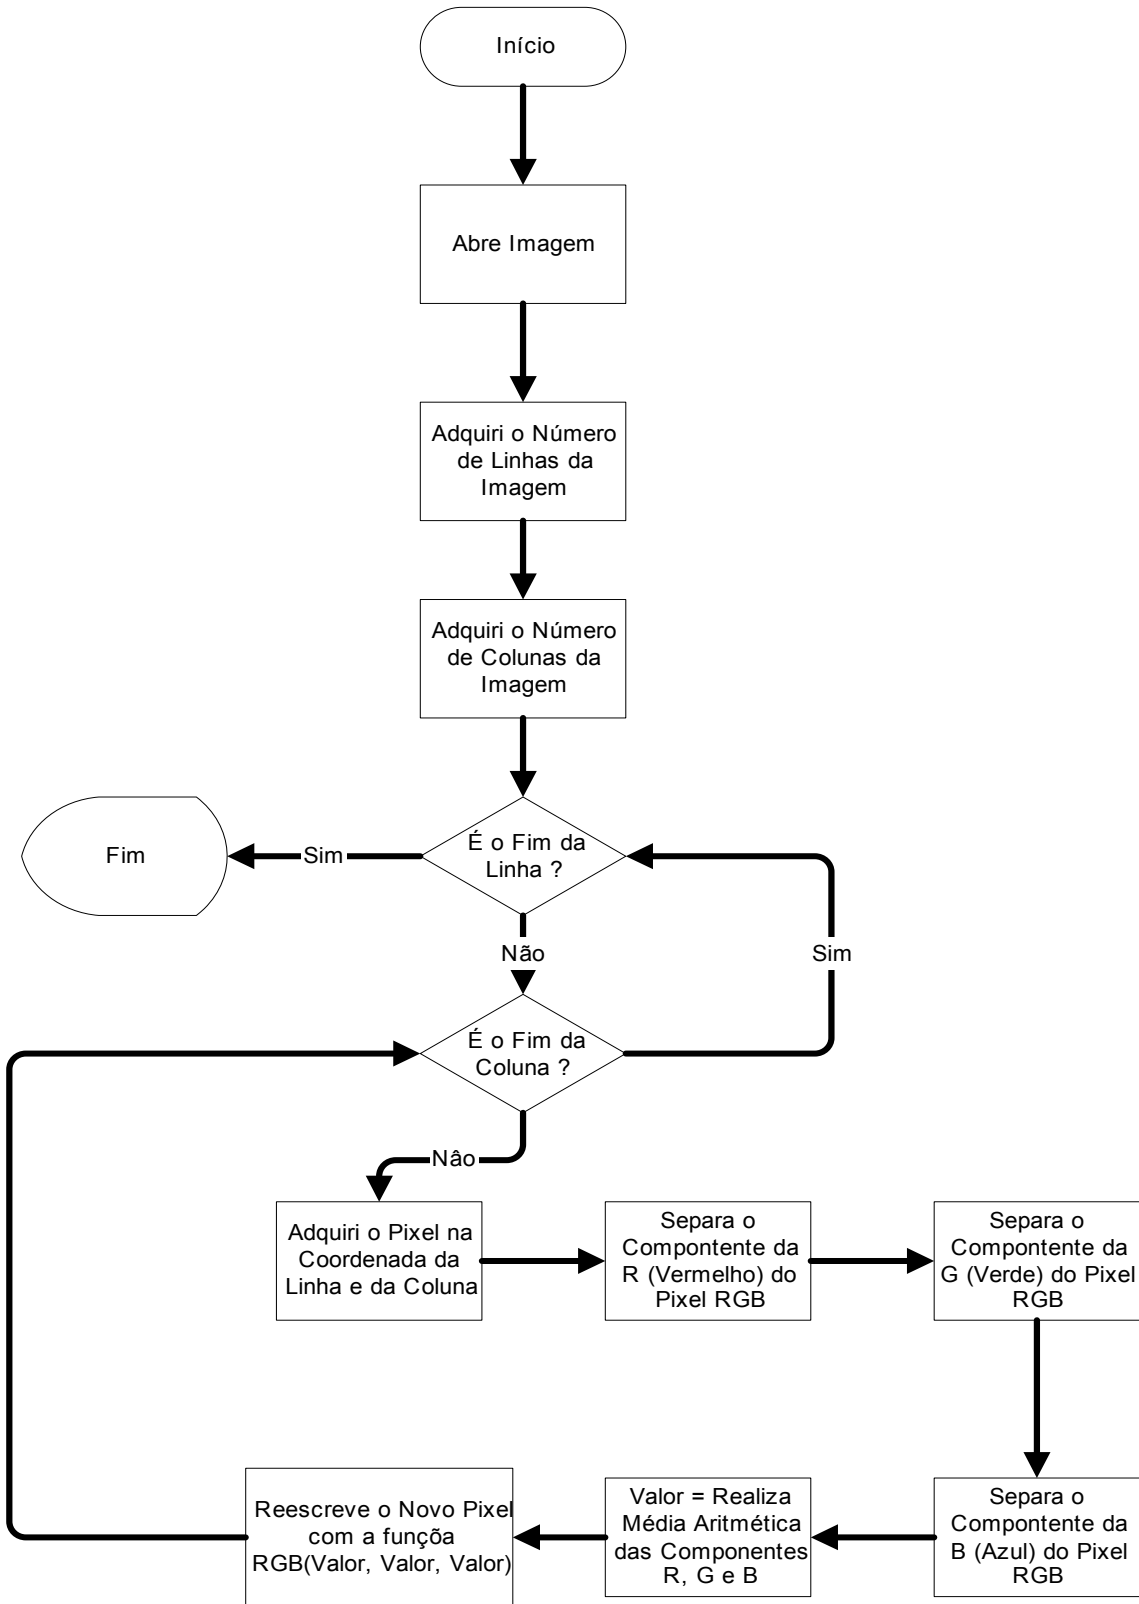


Figura 4.6 - Fluxograma de conversão de uma imagem colorida em uma imagem com tons de cinza.

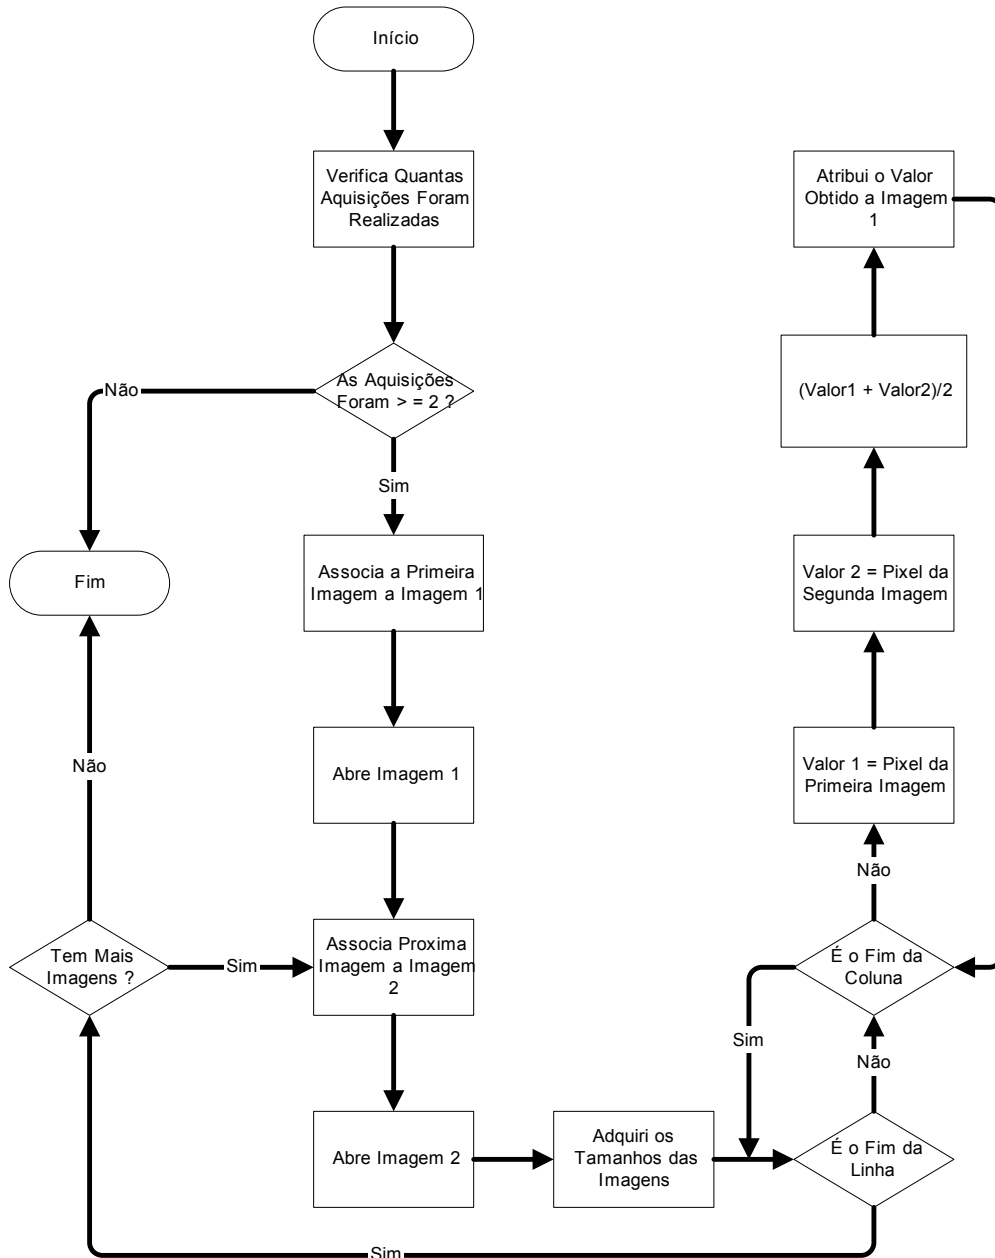


Figura 4.7 - Fluxograma da filtragem por Average de imagens.

A equalização de histograma é aplicada para ajustar o contraste das imagens e melhorar a resposta do reconhecimento de pixels que farão parte dos blocos de correspondência. A equalização de histograma baseia-se na análise da distribuição dos níveis de cinza. Uma imagem está com seu histograma completamente equalizado se houver uma

distribuição uniforme de todos os níveis de cinza. A Figura 4.8 ilustra o fluxograma para a operação de equalização do histograma.

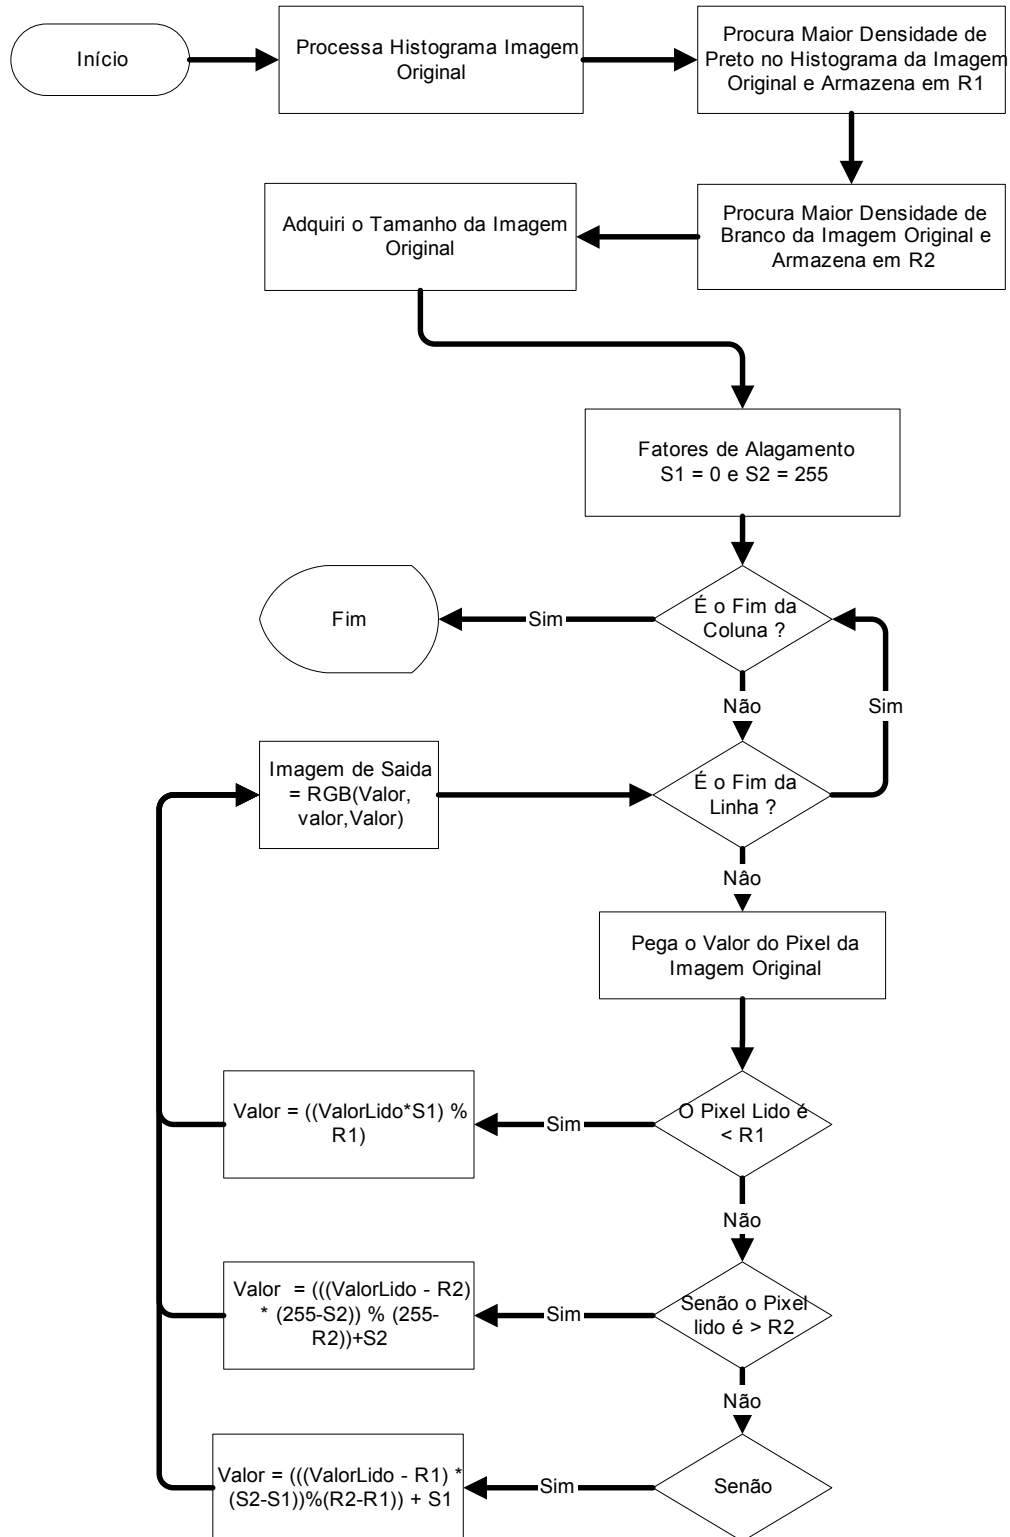


Figura 4.8 – Fluxograma do procedimento para equalização do histograma.

4.4 – Pré-Processamento Coletivo

O imageamento estereoscópico é baseado em cálculos simplificados, entretanto, para a realização dos cálculos é necessário encontrar os pixels de correspondência na primeira imagem da segunda imagem conforme ilustrado na Figura 4.9. A técnica utilizada para este propósito é a de correspondência por blocos, conforme fluxograma ilustrado na Figura 4.10.

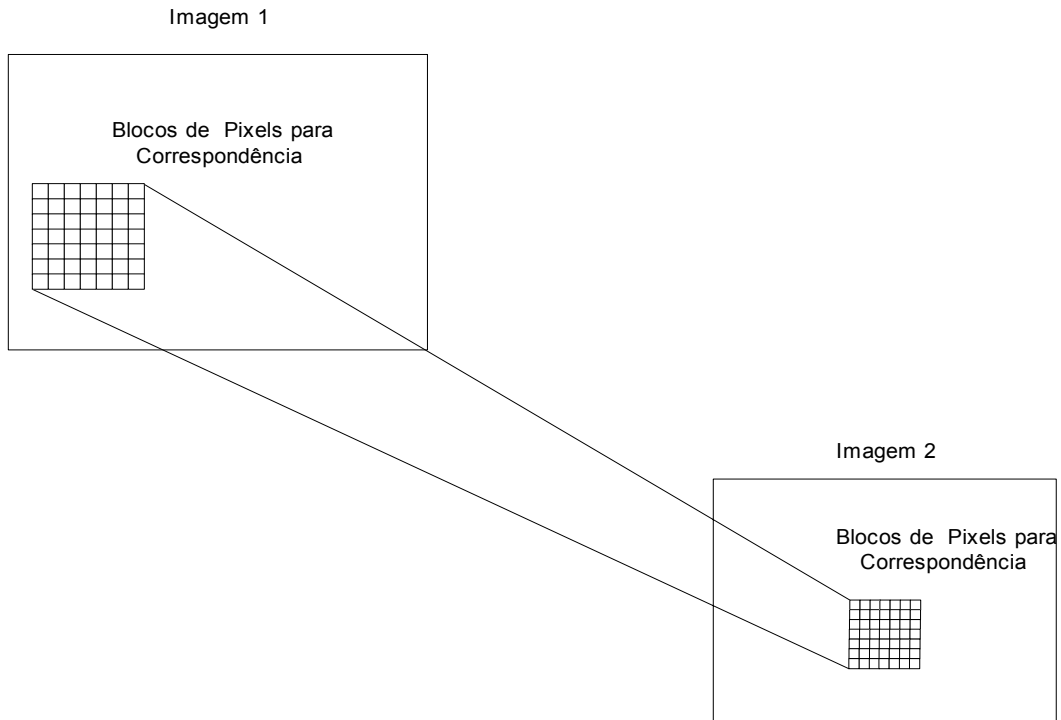


Figura 4.9 - Modelos de correspondência por blocos.

Como pode ser observado na Figura 4.10, a correspondência entre as imagens é calculada apenas para um bloco da primeira imagem. Este procedimento é adotado porque as câmeras são perfeitamente calibradas e alinhadas. Assim, a correspondência encontrada para o primeiro bloco da primeira imagem será válido para os demais blocos.

Este método é adotado para diminuir o esforço computacional que estes procedimentos em geral exigem.

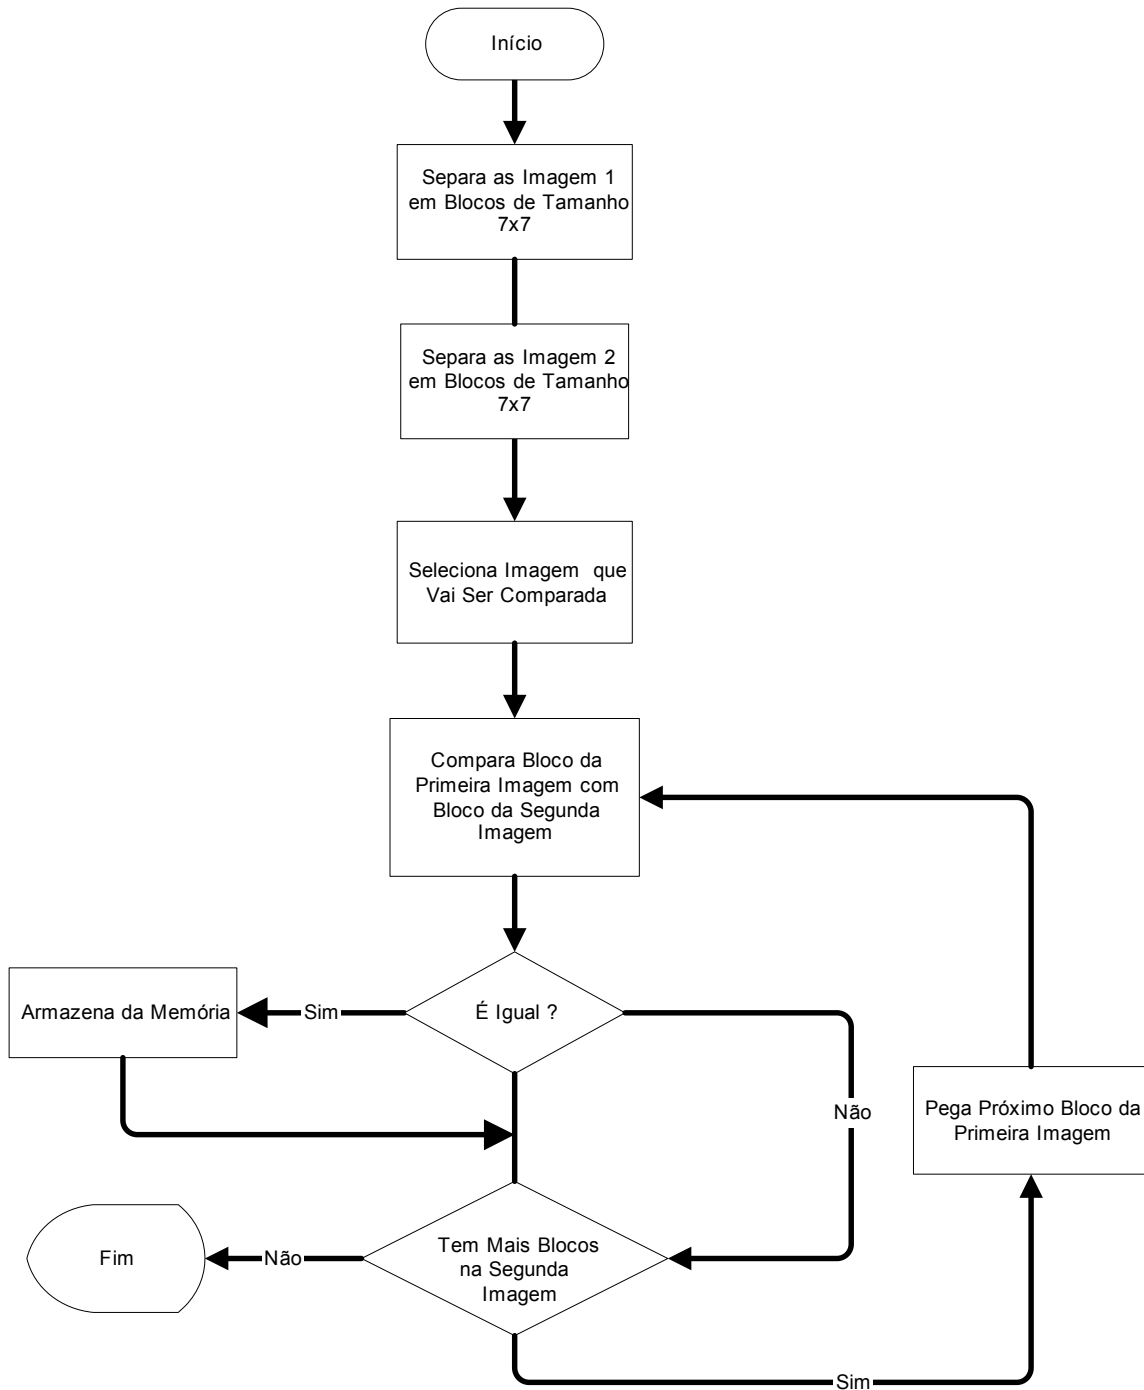


Figura 4.10 - Fluxograma do procedimento de correspondência por blocos.

Antes de aplicar o imageamento estereoscópico é necessário que as informações que não são inerentes ao reconhecimento de padrões circulares sejam extraídas da imagem. O procedimento de limiarização é utilizado para extração destas informações a partir de um limiar previamente definido pelo usuário do sistema conforme ilustrado na Figura 4.11.

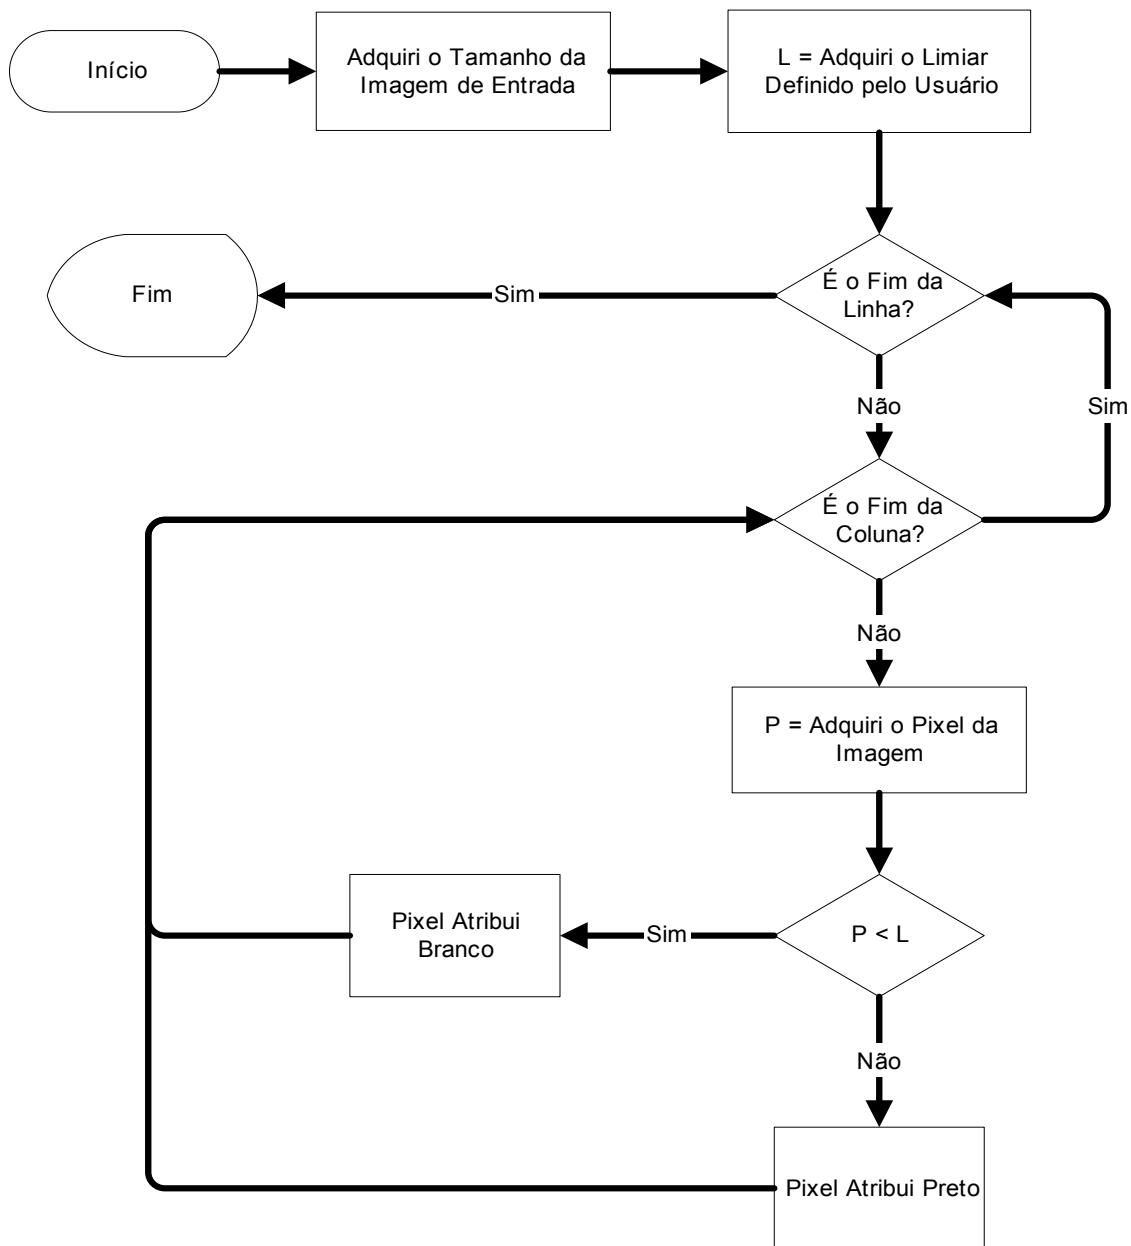


Figura 4.11 - Fluxograma da técnica de limiarização.

Com os pontos de correspondência definidos e a limiarização executada são aplicados os cálculos para o imageamento estereoscópico conforme ilustra o fluxograma apresentado na Figura 4.12.

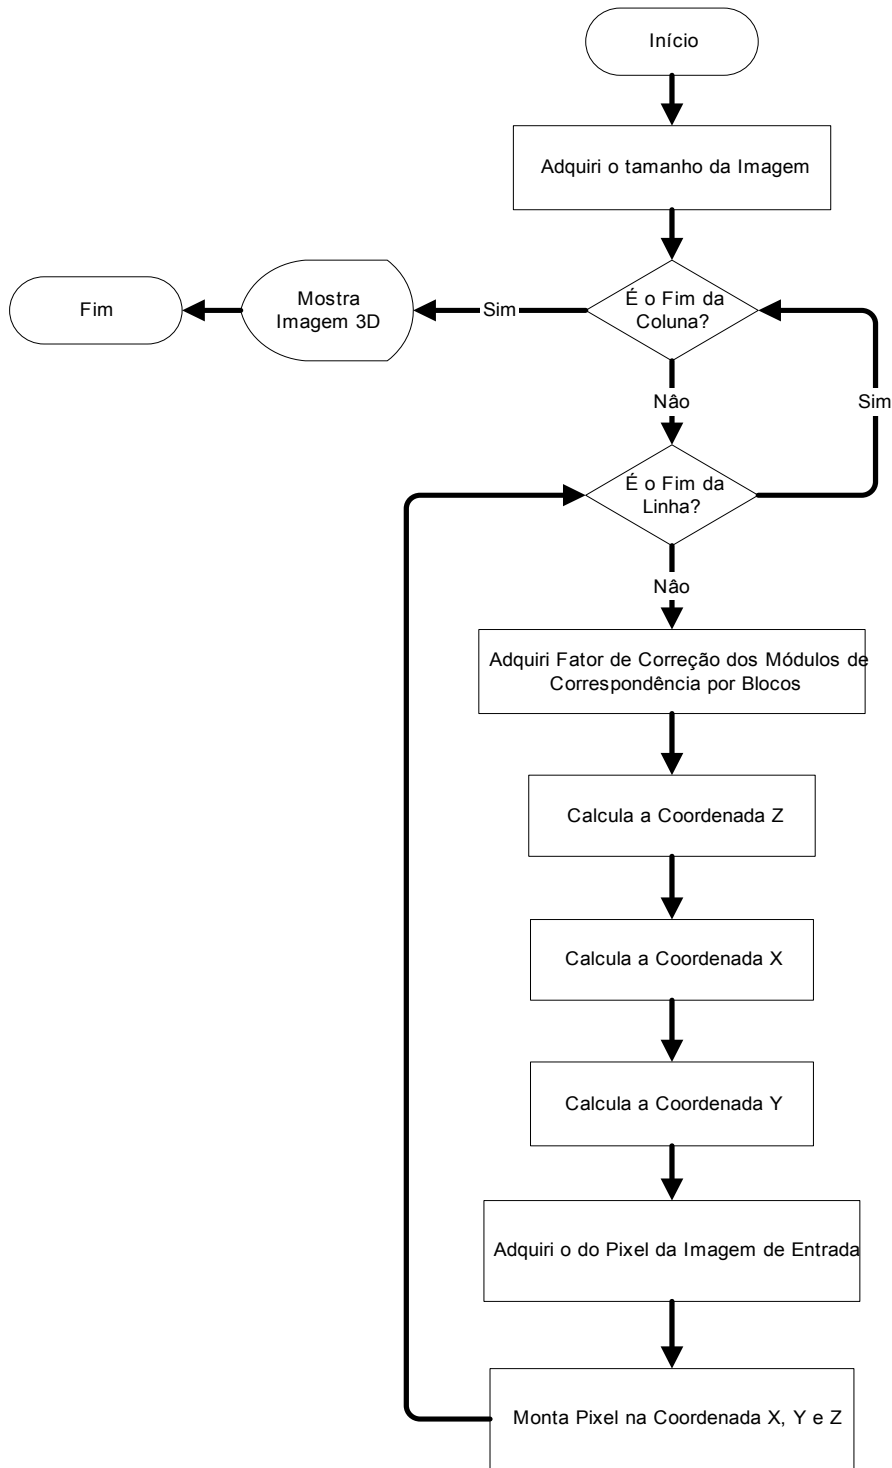


Figura 4.12 - Fluxograma de reconstrução tridimensional.

A imagem reconstruída terá três dimensões, ou seja, as componentes corrigidas das coordenadas X e Y e a coordenada de profundidade Z. A correção de planos trabalha com a coordenada Z. Assim, supondo que seja selecionado a posição zero da coordenada Z, todos os pixels que estiverem à frente ou atrás desta posição serão compensadas, e assumirão sua nova posição como referência. A Figura 4.13 ilustra o fluxograma para o procedimento de correção de planos.

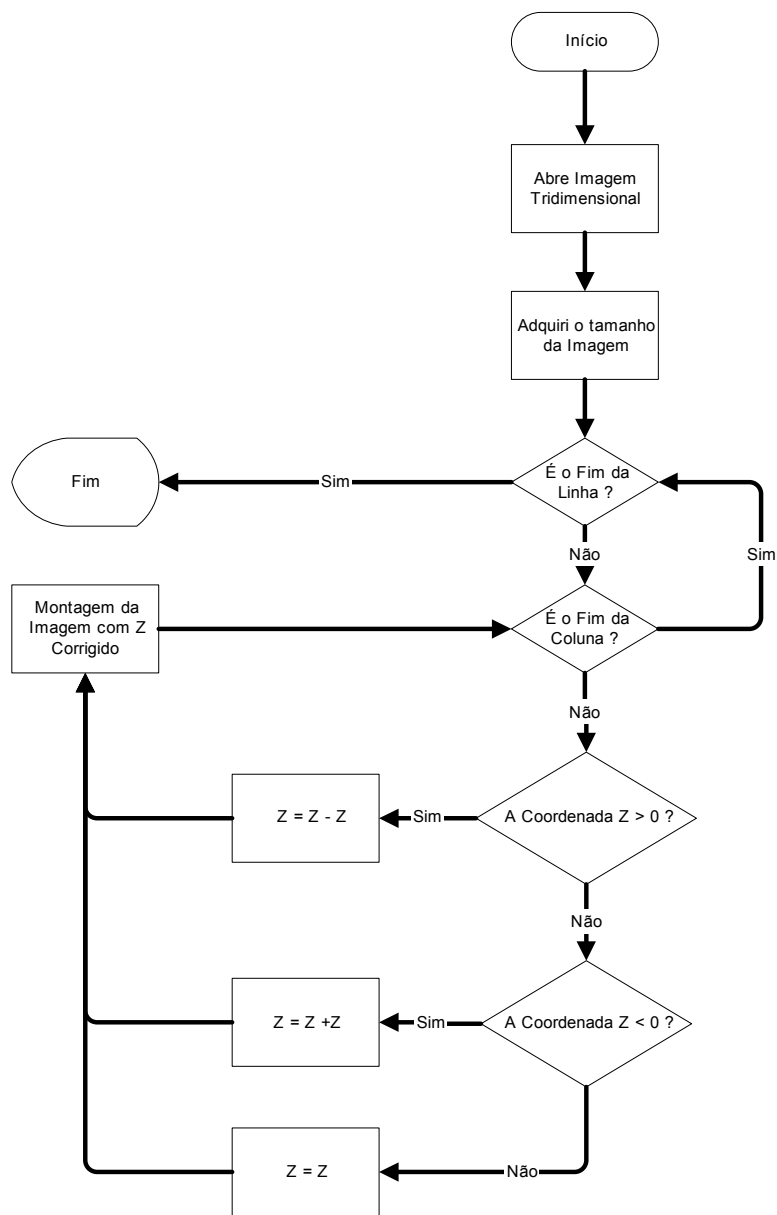


Figura 4.13 - Fluxograma do procedimento de correção do planos da imagem.

Esta correção é realizada para que os mesmos os objetos que tenham o mesmo tamanho, porém que estejam posicionados uns na frente dos outro, tenham um fator de correção para que o sistema possa interpretar corretamente as informações na imagem estereoscópica gerada.

A imagem tridimensional corrigida é novamente convertida para uma imagem bidimensional corrigida para posterior reconhecimento dos padrões circulares através da transformada de Hough, conforme ilustrado na Figura 4.14.

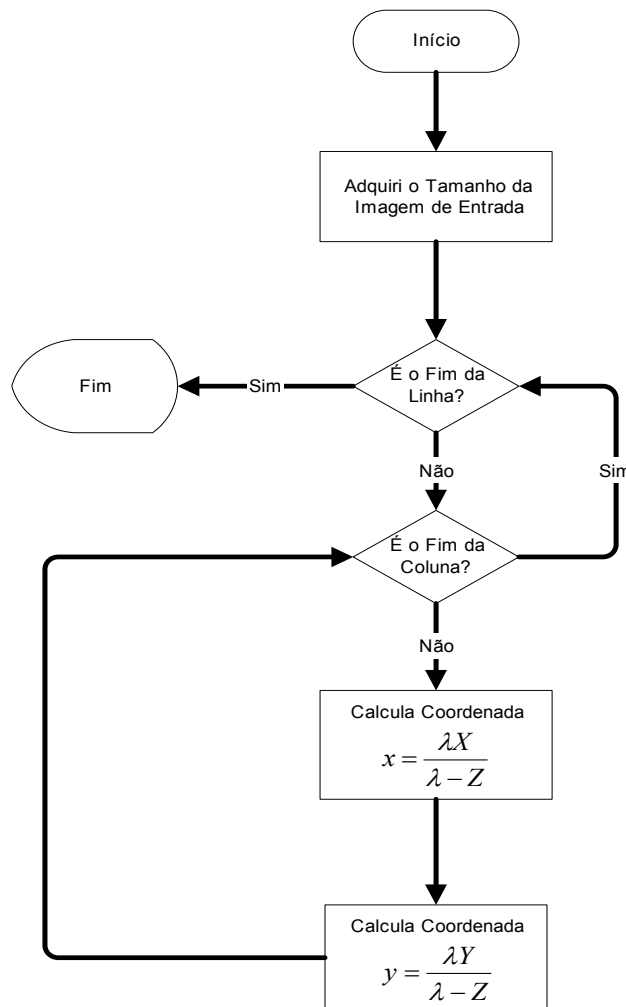


Figura 4.14 - Fluxograma de transformação da imagem tridimensional para uma imagem bidimensional.

O reconhecimento de padrões circulares que é realizado através da transformada de Hough, necessita de um procedimento de correção, pois este método apresenta a geração de falsos picos. Os picos são definidos como pontos (circunferências no espaço de imagem) que na realidade são decorrentes de pixels vizinhos do raio central da circunferência, os quais geram altos valores no arranjo acumulador fazendo com que apareçam circunferências que na realidade não existem.

Como solução dos problemas de falsos picos relacionados com a transformada de Hough foi apresentado por Gering e Klein (GERING & KLEIN, 1986), conhecida como Backmapping que proporciona meios para reduzir os falsos picos. Essa técnica consiste na realização da transformada de Hough produzindo um arranjo acumulador (Acc), seguida da repetição do cálculo da Transformada de Hough sobre a mesma imagem de entrada. O arranjo acumulador (Acc) é procurado em cada circunferência formada, definindo o segundo arranjo acumulador (Acc2) incrementando apenas alguns picos. Do Backmapping pode facilmente se estender para outras parametrizações, onde tem-se a formulação da geração do arranjo acumulador para a transformada de Hough circular. A Figura 4.15, ilustra o fluxograma com etapas dos procedimentos para a organização do arranjo acumulador

A geração do arranjo acumulado tridimensional pode ser definido pela Equação 4.1.

$$\sum_{x=0}^P \sum_{y=0}^E \sum_{r=rini}^{rfim} arranjo(a,b,r) = \begin{cases} 1 & \text{se } f(x,y) = 255 \\ 0 & \text{se } f(x,y) = 0 \end{cases} \quad \text{Equação 4.1}$$

onde:

$$a = x - \cos(\theta)$$

$b = y - \text{sen}(\theta)$
 $r = [\text{rmin}, \text{rmáx}]$
 $P = \text{largura da imagem}$
 $E = \text{altura da imagem}$
 $\text{arranjo} = \text{arranjo acumulador gerado}$
 $f(x,y) = \text{um píxel da imagem}$

Quando utiliza-se a técnica de *Backmapping* sendo estendido para a Equação 4.2.

$$\sum_a \sum_b \sum_{rini}^{rfim} \text{arranjo}_2(\max_a, \max_b) = \begin{cases} 1 & \text{se } \max(\text{arranjo}(a,b,r)) \\ 0 & \end{cases} \quad \text{Equação 4.2}$$

onde:

\max_a e \max_b = valor máximo de a computado pelo $\max(\text{arranjo}(a,b,r))$;
 arranjo_2 = novo arranjo acumulador, inicialmente vazio;
 Max_Acc = maior valor do arranjo acumulador, inicialmente com valor -10.000 , para que ao iniciar a execução do algoritmo, o faça assumindo o primeiro valor do arranjo acumulador.

A transformada de Hough envolve mapeamento de pixels da imagem com um espaço de parâmetro espacialmente quantizado (arranjo acumulador), isto é, cada pixel da imagem define uma circunferência no espaço de parâmetro e todos os pontos do arranjo acumulador nesta faixa de parâmetros serão incrementados. Conseqüentemente, intersecções entre tais faixas aparecem como picos no arranjo acumulador, assim indicando possíveis exemplos de circunferência segmentadas na imagem.

As intersecções irregulares não podem ser usadas para executar amostras ideais de raios. Para resolver este problema é necessário um algoritmo da transformada de Hough sofisticado, incluindo técnica de Backmapping e a análise da vizinhança.

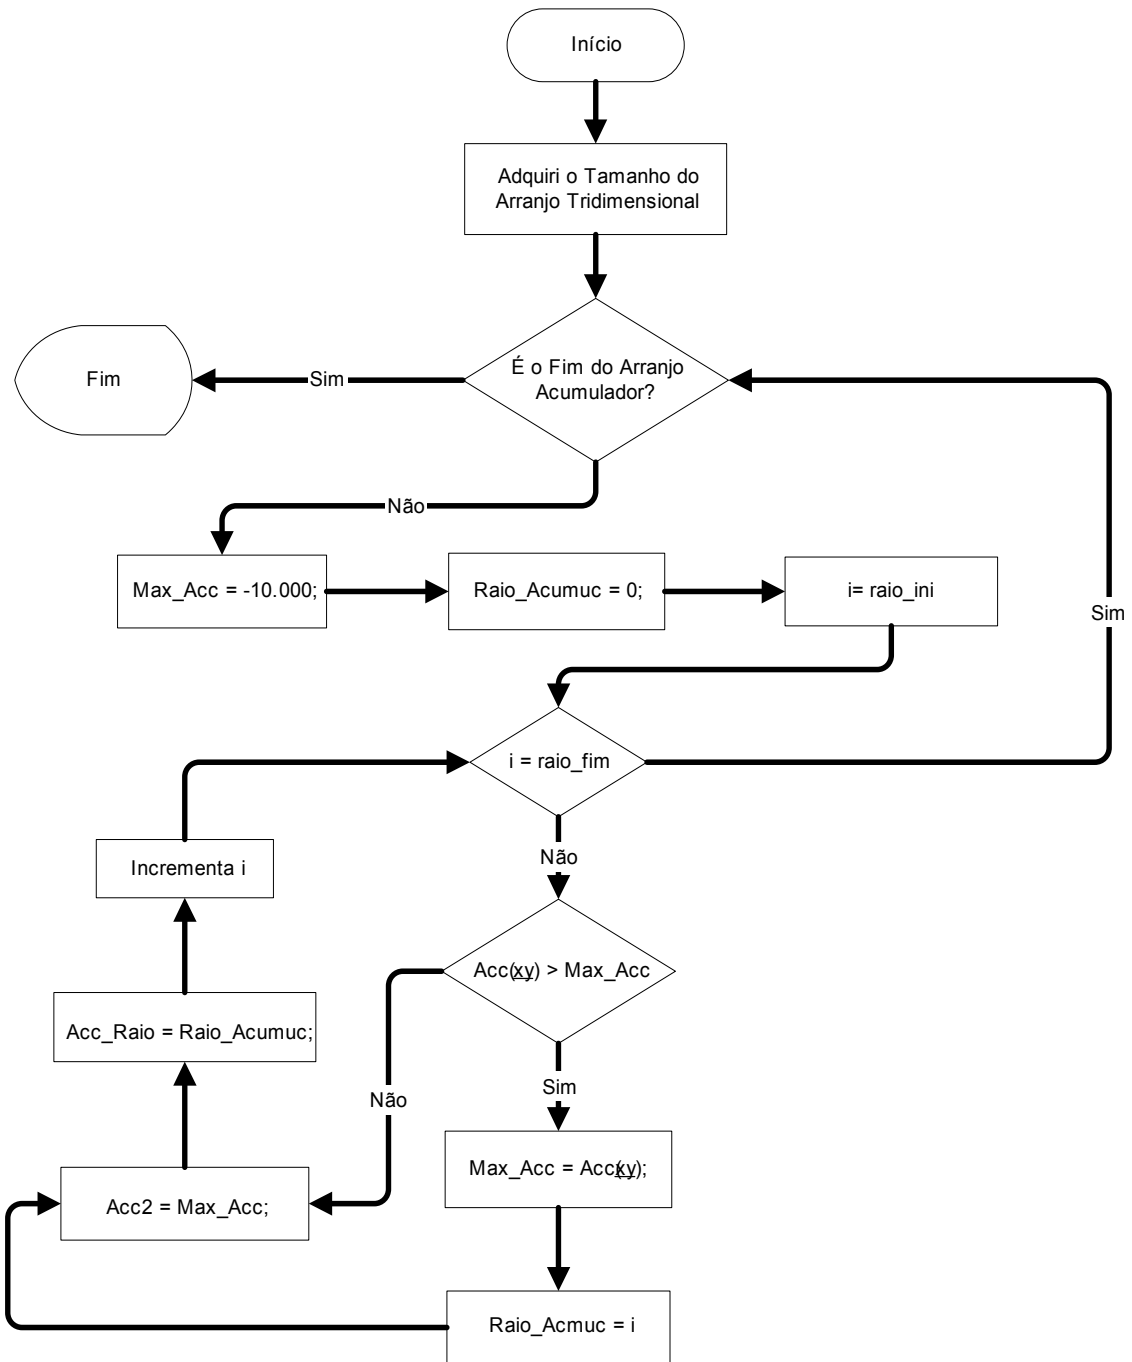


Figura 4.15 - Fluxograma do arranjo acumulador.

Para o aperfeiçoamento do Backmapping utiliza-se um limar e a análise da vizinhança dos picos próximos resultantes do Backmapping. Assim, encontrando a média entre esses picos e gerando com isso apenas um pico com o valor na média eliminaram-se os falsos picos no arranjo acumulador e conseqüentemente, obteve-se um raio central.

A função matemática para seleção dos máximos da vizinhança é descrita pela Equação 4.3.

$$\sum_a \sum_b \max\left(\sum_{i=-v}^v \sum_{j=-v}^v \text{arranjo}_2(a+i, b+j)\right) \quad \text{Equação 4.3}$$

onde:

$v = \text{região de vizinhança.}$

Com os raios centrais podem-se detectar as circunferências na imagem original mesmo que estas possuam raios diferentes. Varrendo-se um intervalo de raios, obtêm-se seus arranjos acumuladores e encontram-se os picos mais relevantes em cada um.

A definição de um alto pico no arranjo acumulador é o resultado dos picos do arranjo acumulador com intensidade igual ao número de pontos na imagem, formando a faixa de parâmetros (COSTA & CÉSAR, 2000). Desta maneira valores globais não expressam a conectividade do pico da imagem, um conjunto escasso de pontos, ou um conjunto de linhas segmentadas colineares traçam um pico no arranjo acumulador, até mesmo se os picos correspondentes para uma linha segmentada na imagem não provê nenhuma informação sobre seus pontos finais. Estudou-se uma simples aproximação, ou seja, uma análise de conectividade de picos de um grande faixa, capaz de minimizar todos

estas faltas. (ATIQUZZAMAN & AKHTAR, 1995; AGRAWAL *et al.*, 1996; ATIQUZZAMAN, 1992; CHATZIS & PITAS, 1997; OLSON, 1998).

Um exemplo de uma implementação do procedimento para remover grupos conectados de pixels menores que *min_comprimento* está presente Figura 4.16.

A Figura 4.17, ilustra o fluxograma para a detecção de extremidades.

Os fluxogramas da Figura 4.18 e Figura 4.19 apresentam respectivamente, o algoritmo de transformada de hough para reconhecimento de padrões circulares e o algoritmo de *backmapping*.

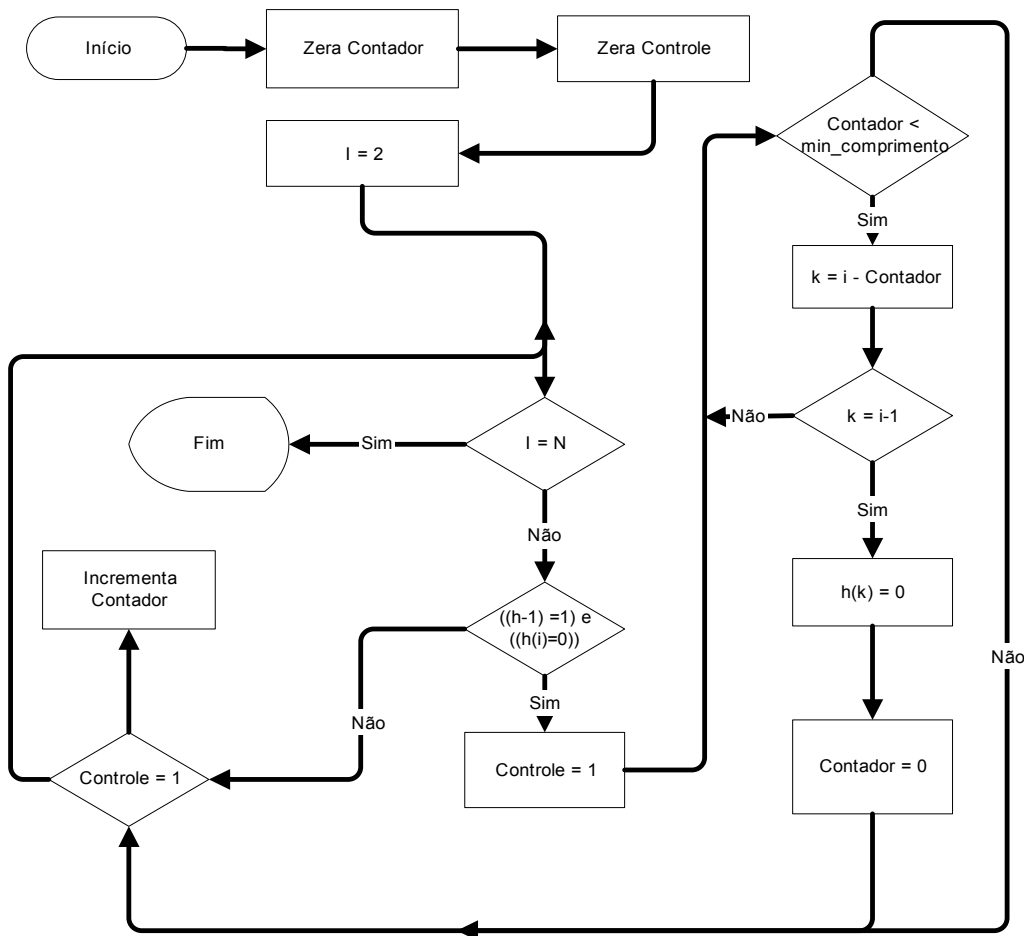


Figura 4.16 - Fluxograma para eliminação de pequenos grupos.

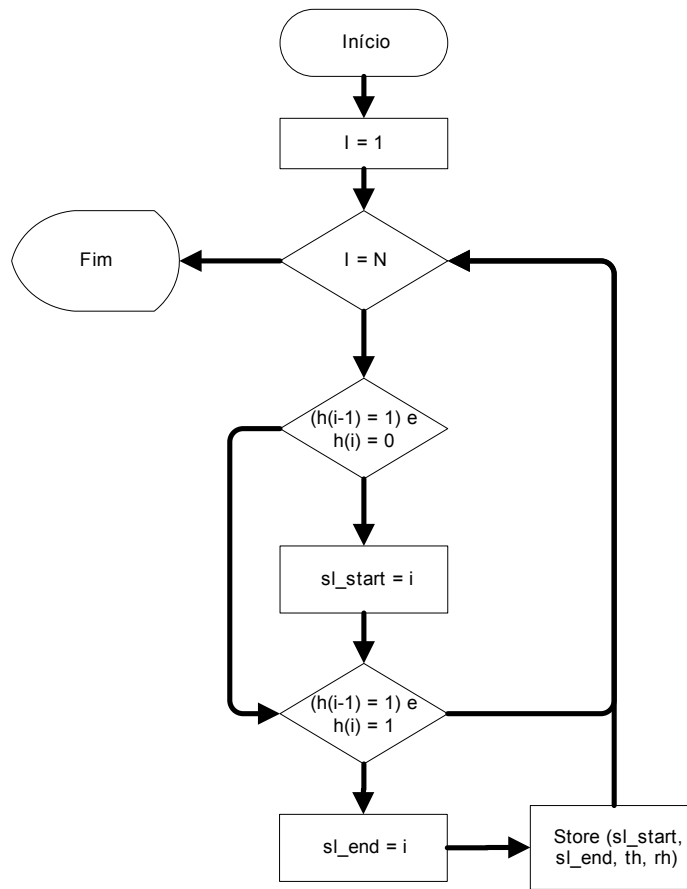


Figura 4.17 - Fluxograma para detecção de extremidades.

O procedimento *store* armazena linha segmentada obtida com uma lista de linhas segmentadas. Observa-se que é suficiente para armazenar somente as coordenadas projetadas das extremidades, como outras coordenadas podem ser obtidas considerando o armazenamento normal pelos parâmetros *th* e *rh* das respectivas grandes faixas. De fato, já que dois pontos nas extremidades não definem uma única linha segmentada na ortogonal entrelaçada, torna-se muito precisa para representar uma linha segmentada em termos de coordenadas projetadas destas extremidades e parâmetros normais. Então, uma linha será representada e armazenada em termos do vetor DSLS = $(\theta, \rho, sl_start, sl_end)$. Observa-se que o tipo de projeção (sobre os eixos *x* ou *y*) podem ser imediatamente dados pela inspeção do valor de θ .

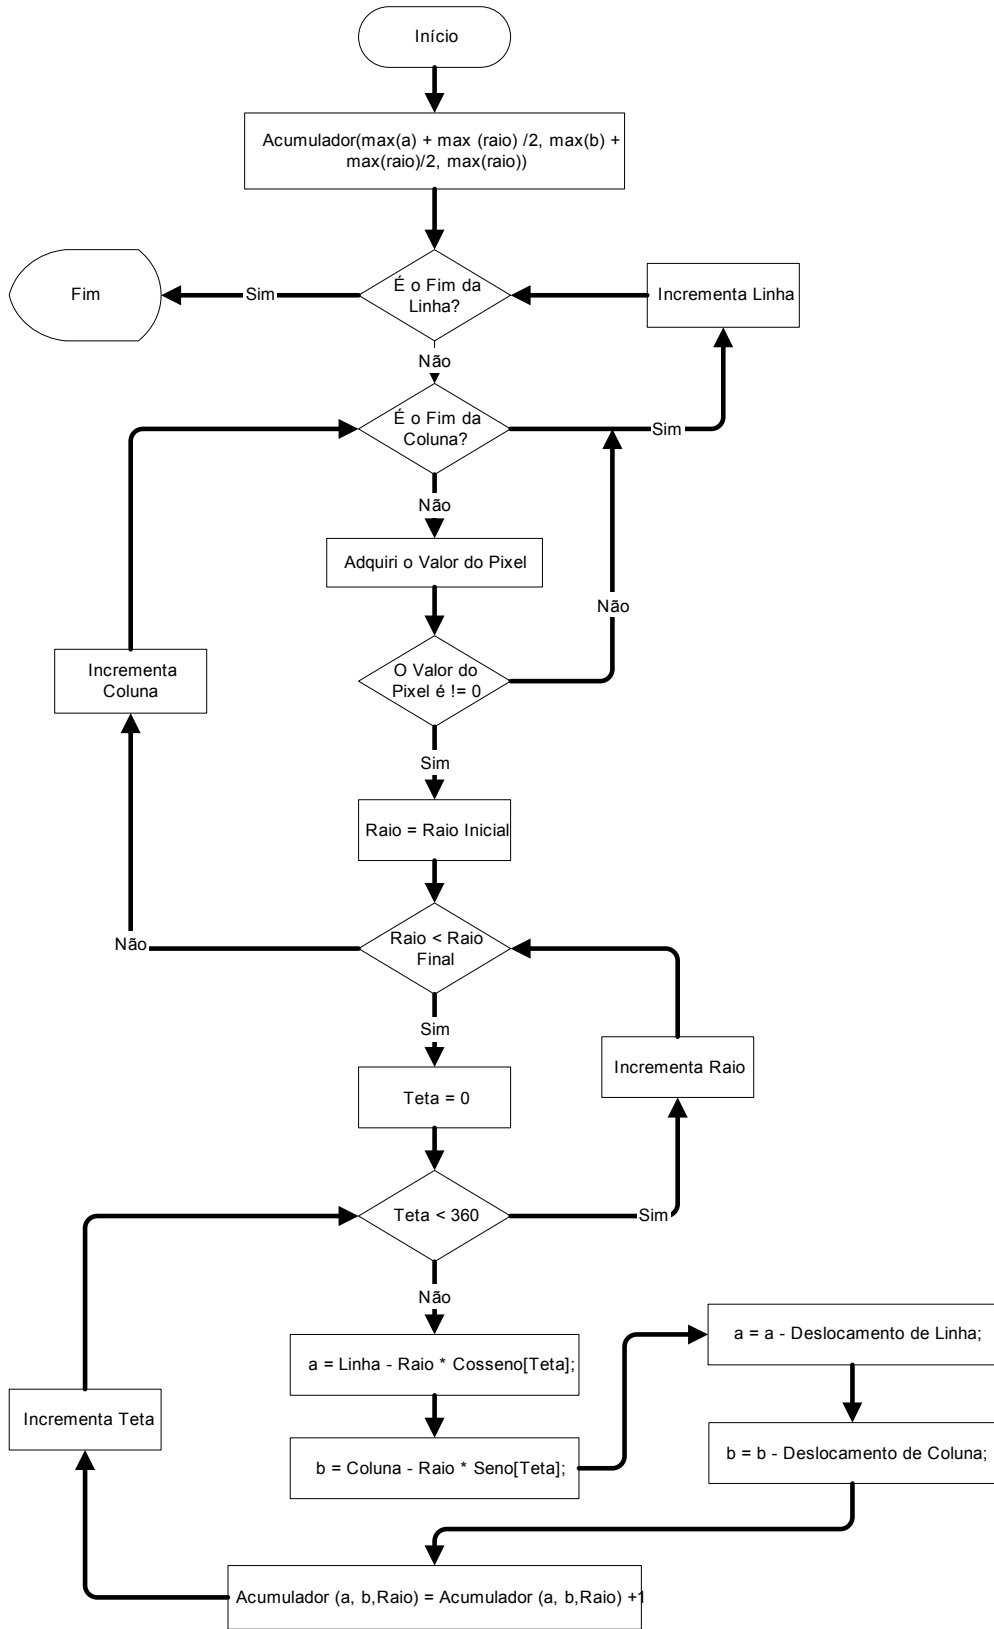


Figura 4.18 - Fluxograma para reconhecimento de padrões circulares com a transformada de Hough.

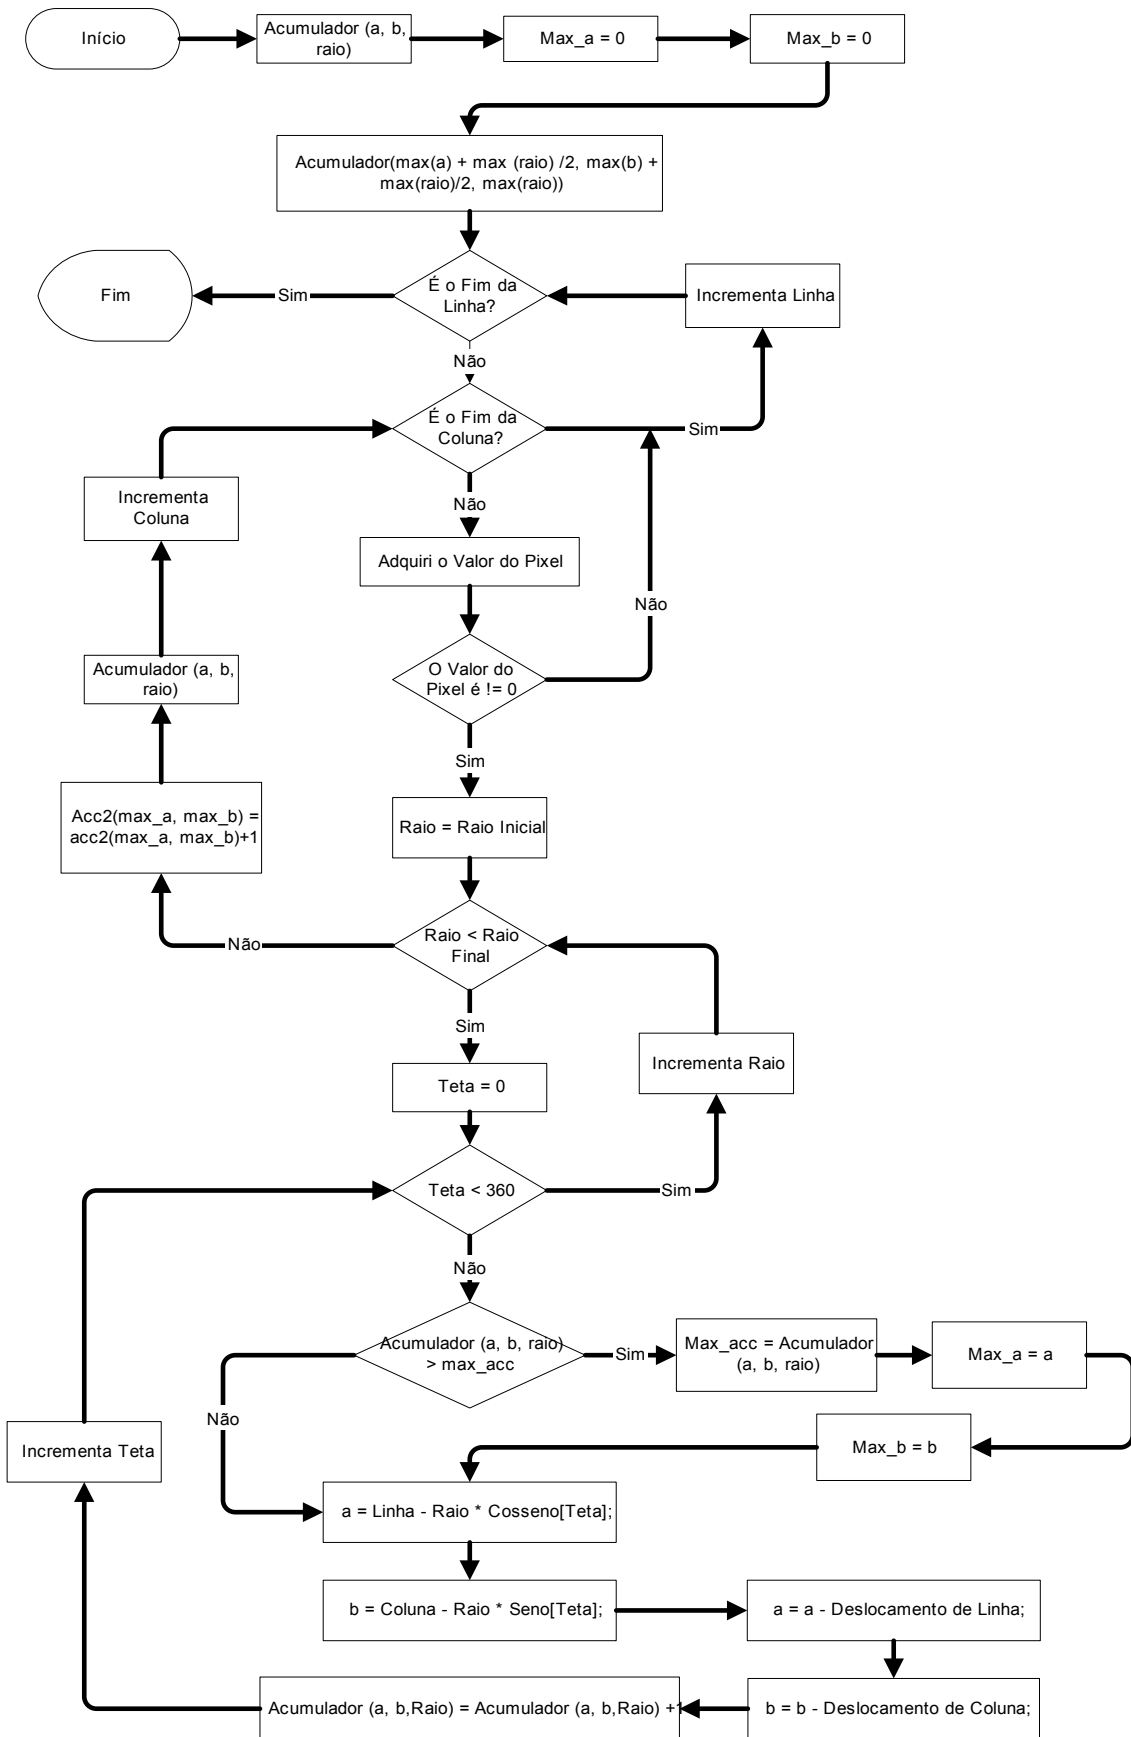


Figura 4.19 - Fluxograma do algoritmo de *Backmapping*.

A informações inerentes as principais etapas como, por exemplo, o número de amostras encontradas de cada um dos tamanhos identificados pelo sistema são armazenadas em forma de relatórios de texto e de gráfico.

4.5 – Armazenagem

O procedimento permite que os estágios do sistema, como a imagem da câmera 1, imagem da câmera 2, imagem estereoscópica, imagem com os planos de profundidade corrigido e os relatórios de cada uma das imagens processadas possam ser armazenadas.

O armazenamento da imagem da câmera 1 é realizado de forma automática o termino da fase de pré-processamento individual em formato BMP, com nome de identificação de qual das câmeras é referente e a data em que foi realizado o processamento.

Semelhantemente ao armazenamento da imagem adquirida da câmera 1 tem-se a aquisição da câmera 2 que utiliza o mesmo procedimento alterando somente a especificação do nome para identificação da câmera 1. A Figura 4.20 ilustra o procedimento para armazenamento automático dessas imagens.

Os relatórios são armazenados no formato do componente *QuickReport*[®] que são gerados de forma individual para cada processamento. Nestes relatórios estão presentes todas informações de análise de quantidade dos padrões circulares como o diâmetro de cada um e a imagem que foi submetida à análise.




Figura 4.20 - Fluxograma do procedimento de armazenamento das imagens adquiridas pelas câmeras 1 e 2.

A imagem tridimensional gerada pelo imagiamento estereoscópico é armazenada em arquivo texto que contém informações sobre a malha de polígonos que será utilizada na reconstrução do objeto com a ferramenta *Visual ToolKit* (VTK).

A imagem bidimensional com a correção dos planos é armazenada em formato de imagem BMP de forma semelhante a apresentada para armazenamento da aquisição das imagens.

4.6 - Visualização

Para visualização de resultados, o sistema possibilita duas formas básicas. A primeira é em tempo de execução, as imagens são adquiridas e já entram em rotina de análise e reconhecimento ou a segunda que é utilizada quando o sistema foi utilizado somente para aquisições das imagens e posteriormente é necessária à análise dos dados.

Em cada uma das opções oferecidas pelo sistema tem-se mais dois tipos de visualizações, a bidimensional e a tridimensional. A bidimensional é realizada através de uma componente chamado, de *TImage* que ao ser associado a uma imagem exibe-a no sistema. Já para as imagens tridimensionais foi utilizado uma ferramenta baseado em *openGL*[®] chamada de *VTK*, a qual possui diretivas simplificadas das funções da *openGl*[®]. A imagem estereoscópica é exibida com ferramentas adicionais implícitas como o zoom, rotação e translação.

Capítulo 5

Resultados e conclusões

Neste capítulo são apresentados à avaliação da interface com o usuário, os resultados obtidos com o sistema e as conclusões.

5.1 - Avaliação da Interface com o usuário

O sistema foi realizado no ambiente visual C++ Builder 5.0 e buscou-se flexibilidade operativa visando uma maior interação com o usuário.

A Figura 5.1 ilustra a tela principal, onde na região 1 são apresentados os resultados de análises para os processos em avaliação e de aquisição. Cada resultado é apresentado em sua respectiva aba. Na região 2, são observadas as funcionalidades de ajuste para as funções como a *limiarização* ou o *Backmapping* que somente serão disponibilizados ao usuário quando selecionado. Também podem ser observados alguns botões que facilitam a utilização do sistema como por exemplo, identificação de padrões circulares e imagens sendo adquiridas em tempo real. O menu principal é composto por cinco tipos de diferentes opções, onde se tem como primeiro item a opção *Arquivo* conforme ilustrado na Figura 5.2. Este menu oferece ao usuário diversas funcionalidades, como por exemplo a opção abrir imagens que serão processadas conforme ilustra a Figura 5.3 ou que já foram processadas, conforme opções selecionadas pelo usuário, ou salvar

imagens processadas conforme ilustrado na Figura 5.4. O sistema opera tanto imagens em tons de cinza como RGB. Outra funcionalidade oferecida no menu *Arquivo*, é a equalização automática de histogramas, a qual é responsável pela melhor distribuição das densidades, oferecendo maior uniformidade e auxílio na eficiência do algoritmo de correspondência por blocos conforme ilustrado na Figura 5.5. O procedimento utilizado para a correspondência por blocos pode ser dividido em duas partes: reconhecimento de um único pixel da imagem 1 ou por seleção. Estes procedimentos de correspondência são disponibilizados ao usuário conforme o tipo de seleção apresentada na região 2, como ilustrados na Figura 5.6 .

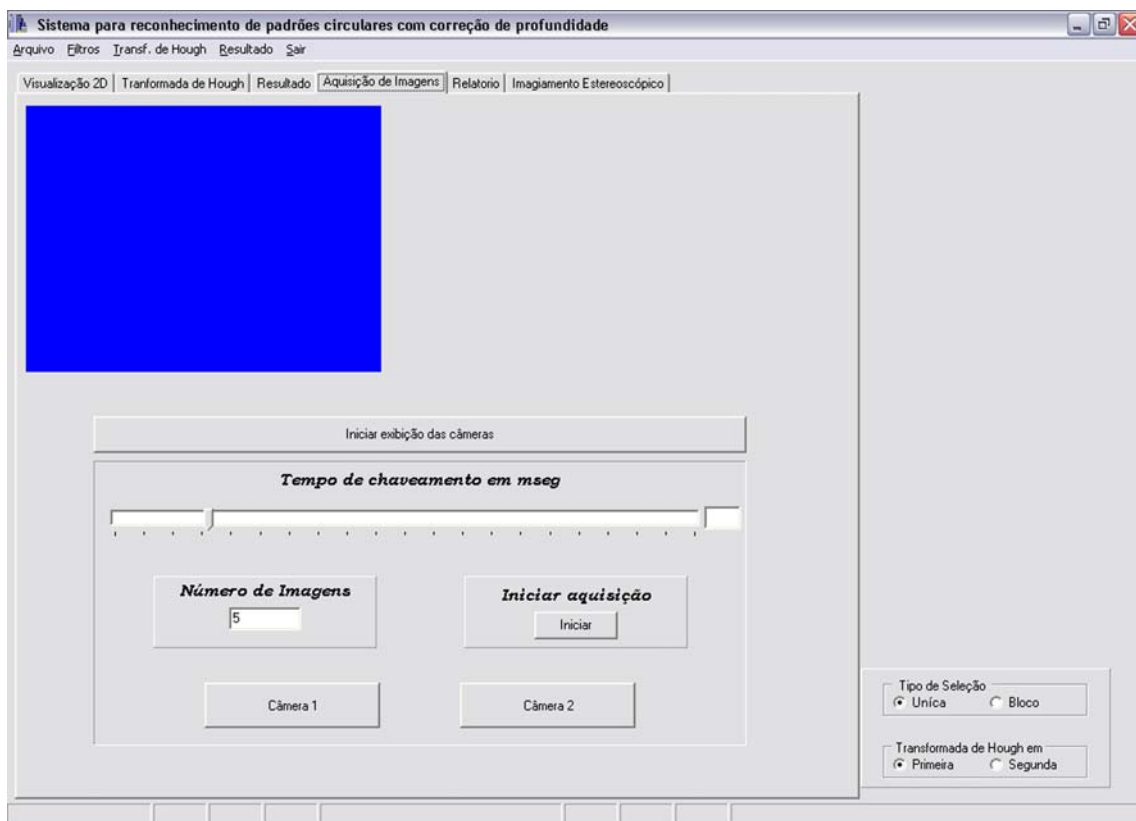


Figura 5.1 - Tela principal do sistema de reconhecimento de padrões circulares com correção de profundidade.

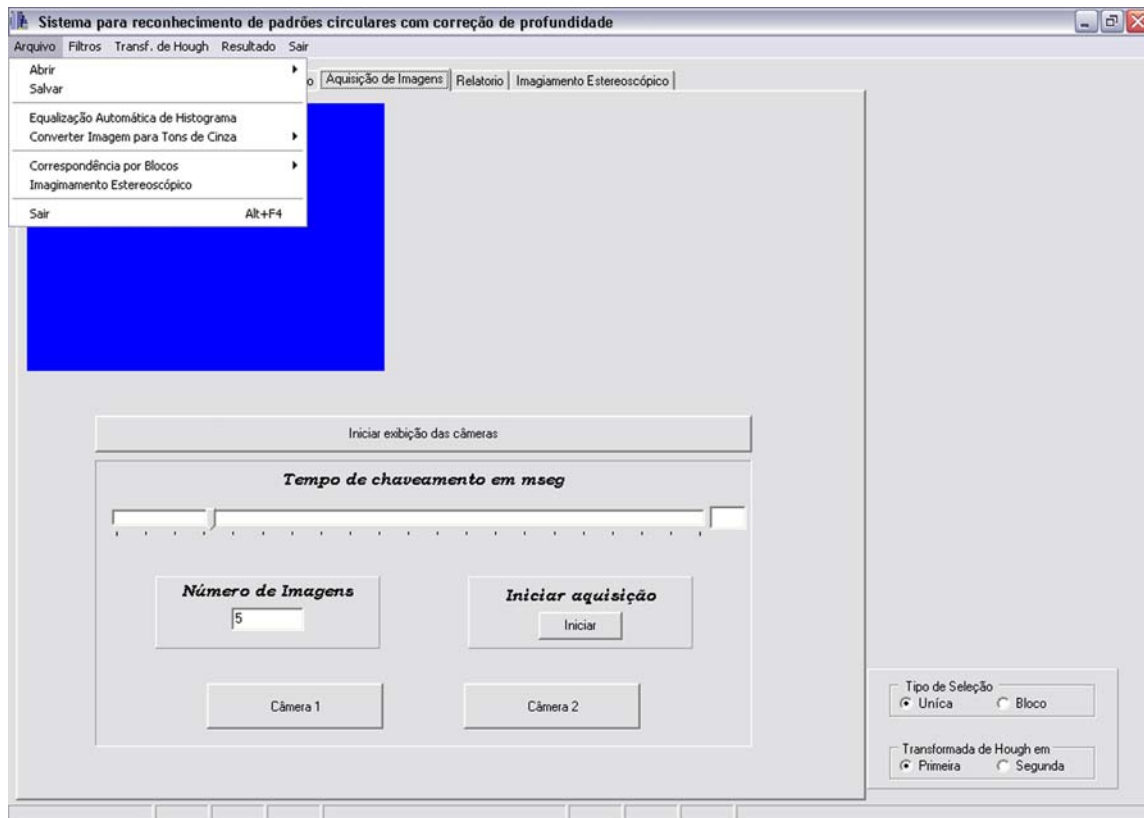


Figura 5.2 - Ilustração dos itens oferecidos pelo menu iniciar.

Com o ponto de correspondência encontrado é realizado o cálculo do imageamento estereoscópico, que irá retornar as coordenadas X, Y e Z tridimensionais conforme ilustrado na Figura 5.7. O fator de interesse é a coordenada Z que representa a profundidade do objeto em relação à lente da câmera.

Para a utilização do sistema é necessário seguir os passos, conforme ilustrados e discutidos a seguir. A operação inicia-se com a escolha de duas imagens para o processamento, como exemplo, as imagens ilustradas na Figura 5.8, através do menu *Arquivo* ou de forma automática através da seleção do menu *Filtro* com a opção *Média*.

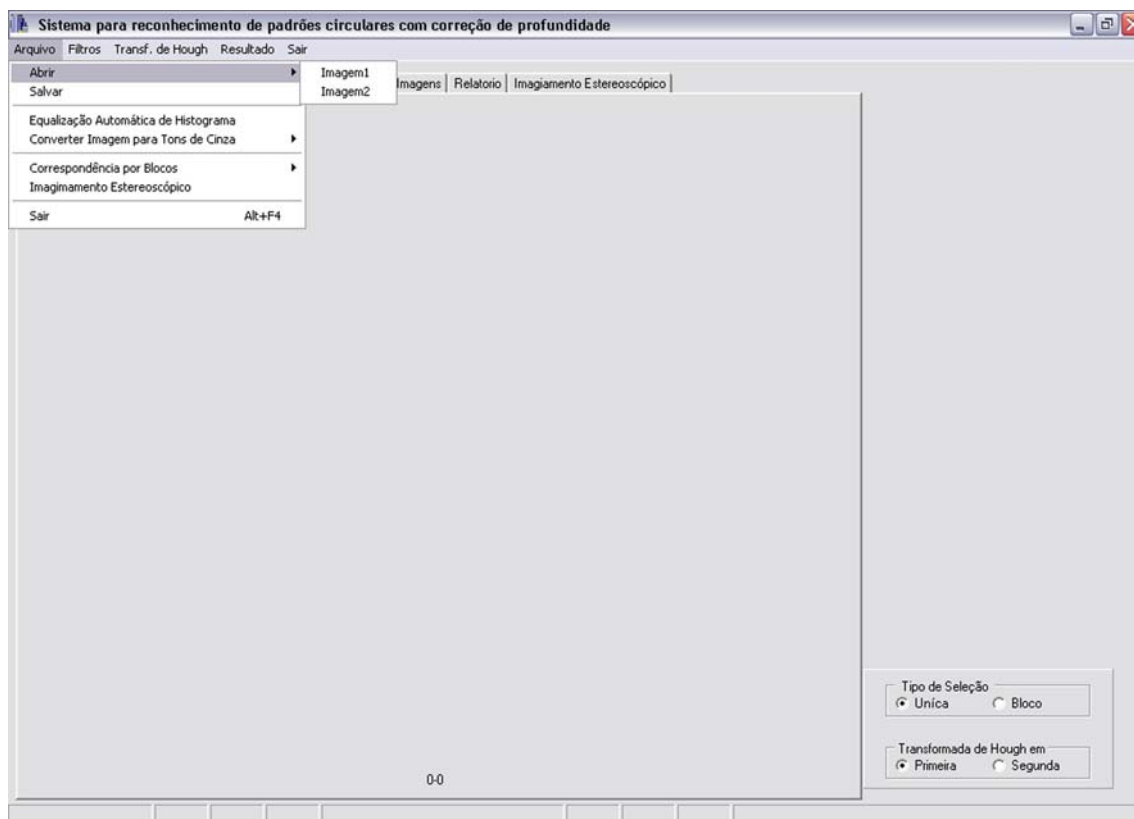


Figura 5.3 – Seleção da forma que a imagem será aberta, ou seja, de forma formal como foi digitalizada ou convertendo-a em tons de cinza.

A Figura 5.8 ilustra o resultado decorrente do processamento automático do histograma. Após este processamento é selecionado o ponto que será reconhecido na segunda imagem, conforme ilustrado na Figura 5.9 onde o resultado de correspondência de um ponto da imagem, representado por um ponto vermelho na primeira imagem definida pelo usuário, é um ponto vermelho da segunda imagem localizada pelo sistema.

Com o ponto de correspondência é então aplicado o cálculo do imagiamento estereoscópico o qual apresenta em uma tabela gerada cada ponto X, Y, Z calculado conforme ilustrado na Figura 5.11.

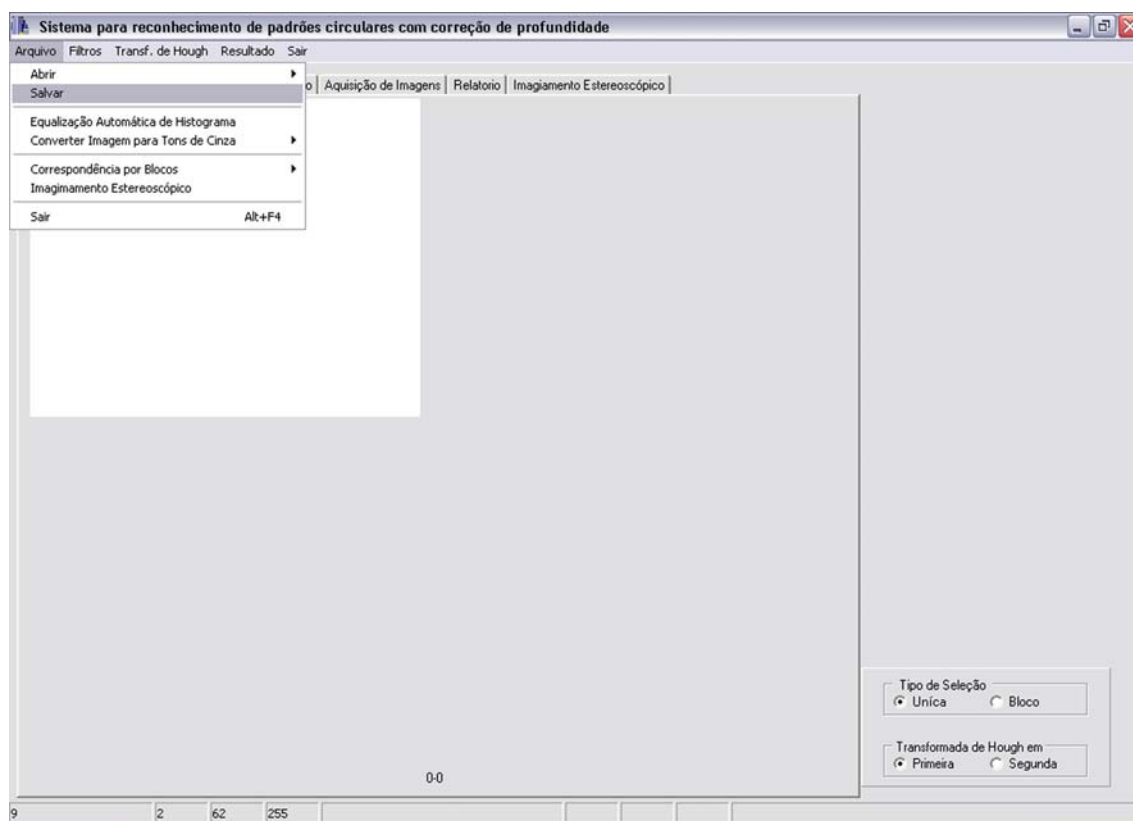


Figura 5.4 - Opção de salvar oferecida pelo menu Arquivo.

O sistema oferece três tipos básicos de filtros como por exemplo, *Threshold* (Limiarização), *Laplaciano* e de *Média*. A limiarização é obtido com um filtro que possibilita a remoção de informação não desejada na transformada de Hough. O filtro *Laplacino* tem como característica a extração de bordas de objetos da cena. Finalmente, o filtro de *Média*, é utilizado na entrada do sistema para que as imagens adquiridas pela Webcam apresenta melhor relação sinal/ruído. A Figura 5.10 ilustra os filtros disponíveis no sistema.

Na Figura 5.12, o resultado da limiarização de cada uma das imagens reais é apresentado e, conforme ocorrem alterações na barra de rolagem, uma nova imagem limiarizada é obtida no mesmo local.

Após a limiarização da imagem, é executado o filtro Laplaciano para a detecção das bordas, conforme visualizado na Figura 5.13. O filtro *Laplaciano* é executado a partir da imagem limiarizada e o resultado é exibido sobre a mesma.

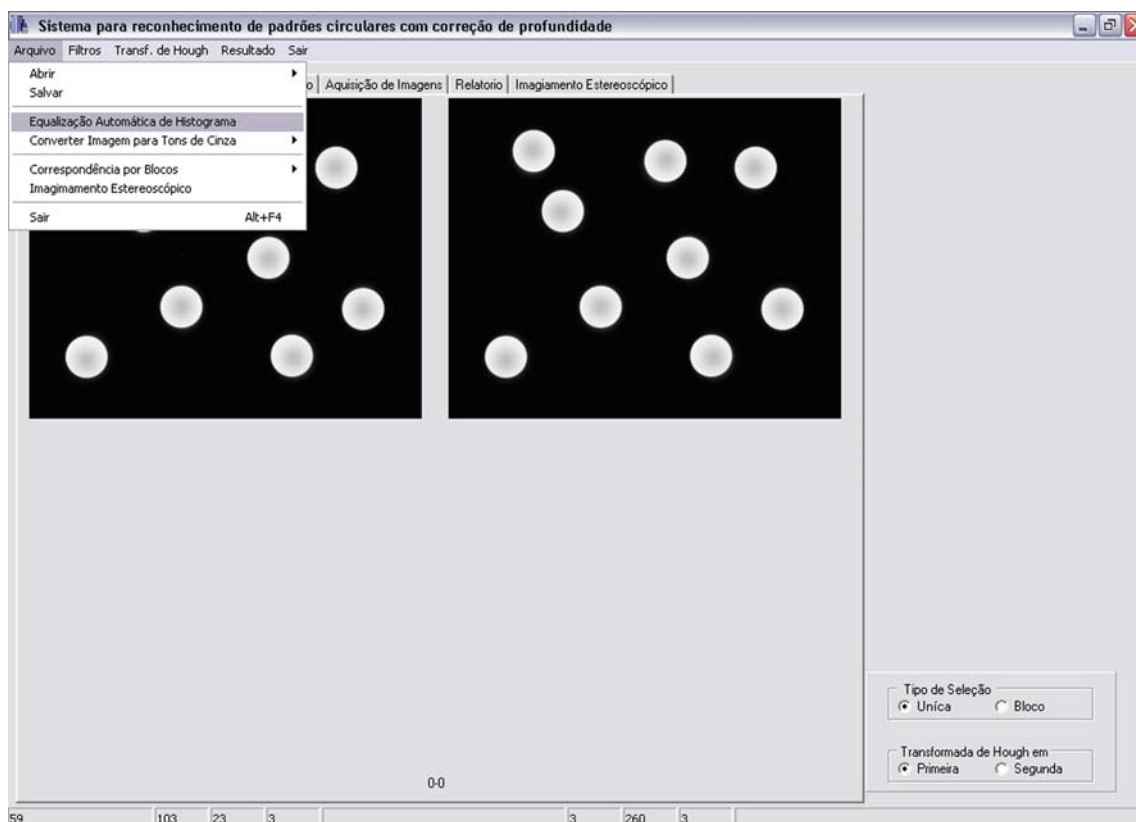


Figura 5.5 - Chamada da função de equalização automática de histogramas.

O passo seguinte é desenvolvido com a execução da transformada de Hough circular e para tanto se utiliza o menu *transformada de Hough* executando a opção *Manual*. Na Figura 5.14 pode-se observar na aba transformada de Hough, que gera resultados da transformada de Hough para objetos circulares. Este procedimento pode ser aplicado tanto para a primeira imagem como para a segunda imagem, adquirida no início de cada processo. Como um padrão de análise optou-se por aplicar a transformada de Hough na primeira imagem adquirida por

processo, após identificada sua probabilidade, que é obtida pelo imageamento estereoscópico.




Figura 5.6 – Chamada da função de correspondência por blocos.

Para a execução do *Backmapping* é necessário a indicação de um valor de limiar para o mesmo, o qual é escolhido utilizando-se a barra de rolagem. Após a escolha do valor, o botão *Backmapping* deve ser acionado para o iniciar da execução do processo.

Realizado o *Backmapping*, a etapa seguinte é obtida com a análise da vizinhança que é executada a partir do botão *Vizinhança*. A imagem resultante é apresentada sobre a imagem obtida com a operação *Backmapping*, conforme pode ser observado na Figura 5.15.

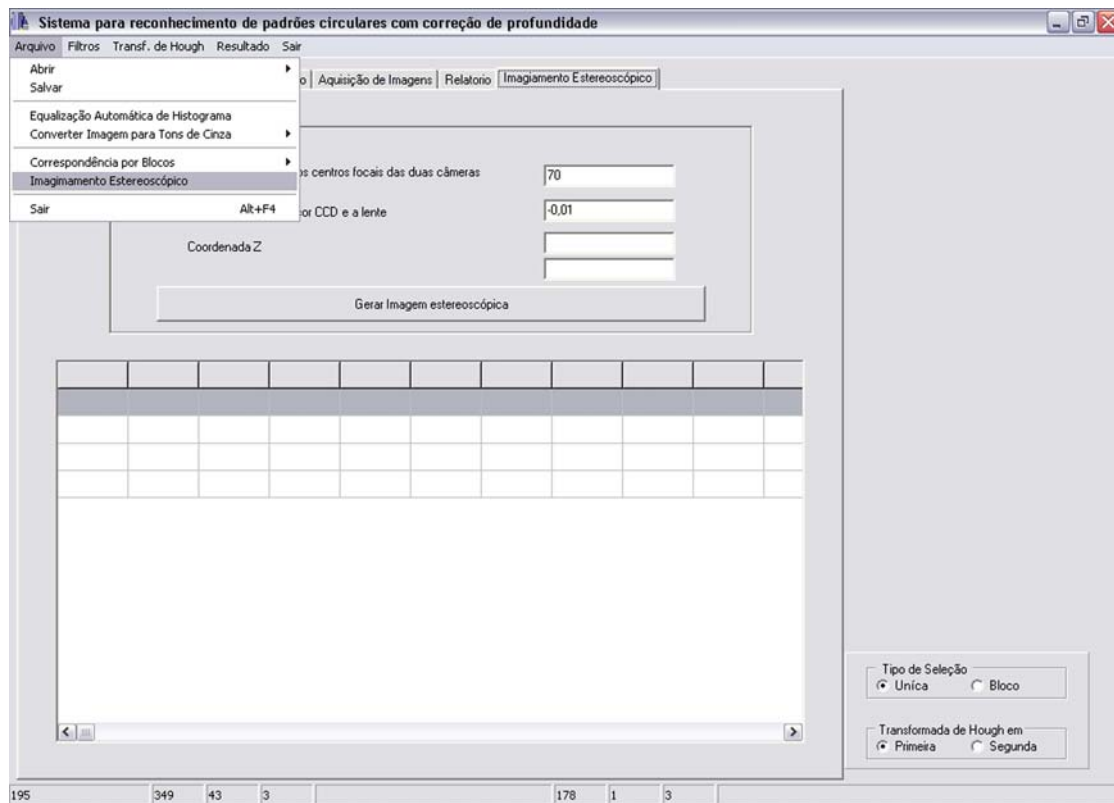


Figura 5.7 - Procedimento para recuperação da coordenada Z através de técnica de imagiamento estereoscópico.




Figura 5.8 - Tela do sistema com o resultado da equalização automática do histograma.




Figura 5.9 - Resultado do procedimento de ponto de correspondência através de um único ponto.




Figura 5.10 – Tela do sistema com a opção de filtros oferecidos.

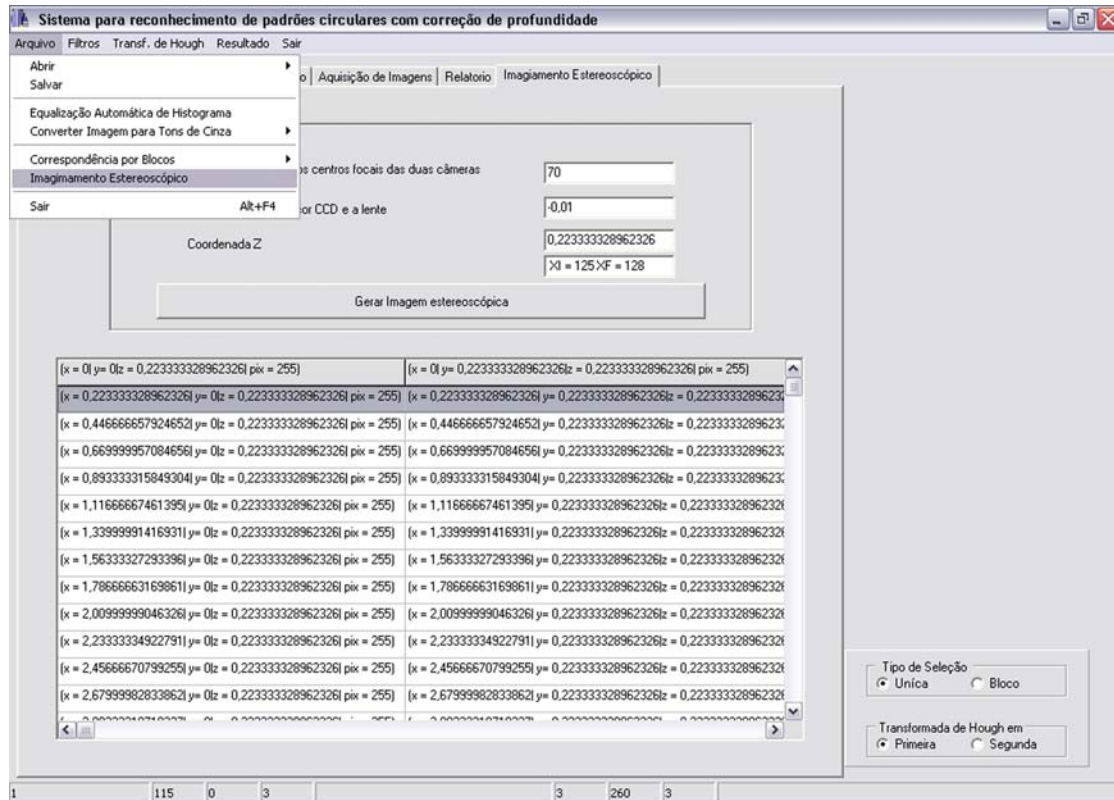


Figura 5.11 – Tela de saída com a ilustração de um exemplo de resultado obtido através dos cálculos de imagiamento estereoscópico.

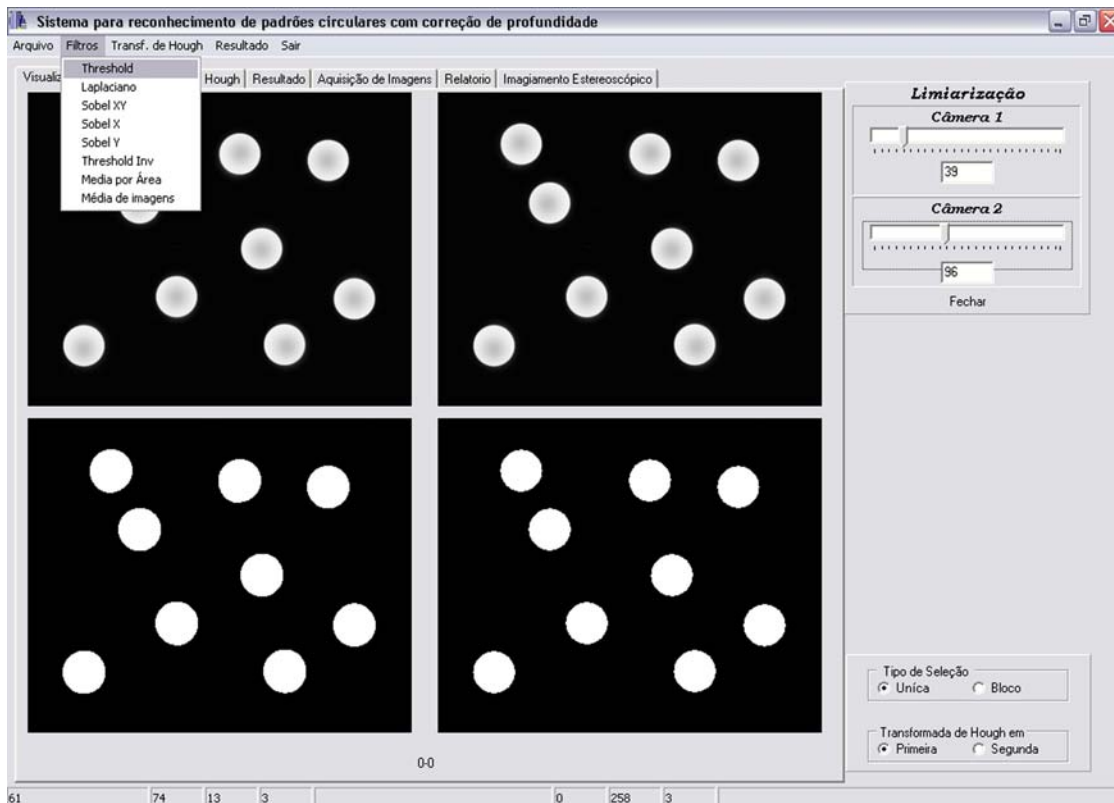


Figura 5.12 - A limiarização para cada uma das imagens funciona de forma independente, podendo ser ajustado uma limiar para cada uma das imagens.




Figura 5.13 – Resultado após aplicação do filtro *Laplaciano* em cada uma das imagens.

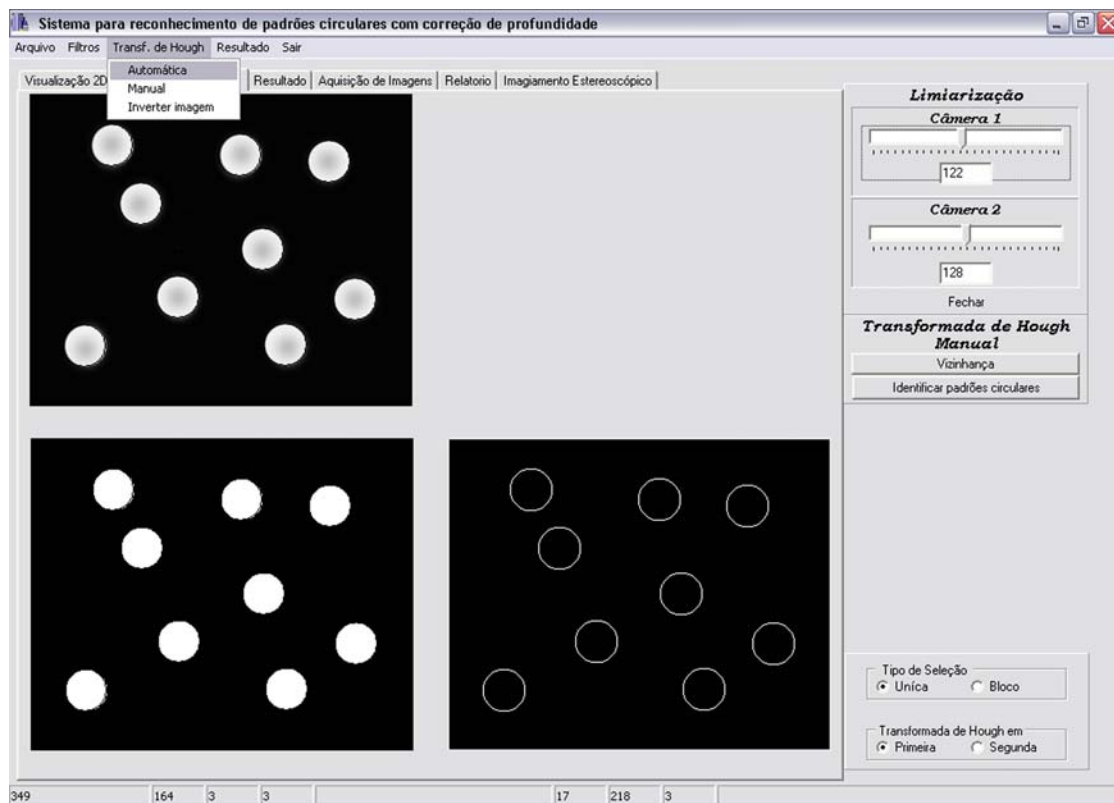


Figura 5.14 - Tela com resultados da aplicação da transformada de Hough.

Após se analisar a vizinhança é iniciado o processo de detecção de padrões circulares acionando-se o botão que identifica objetos circulares. No processo de detecção cada padrão circular detectado é apagado da imagem limiarizada. É então traçada a partir daí, uma circunferência sobre os padrões circulares detectados na imagem real. Isto é repetido até que a detecção de todos os supostos padrões circulares sejam identificados.

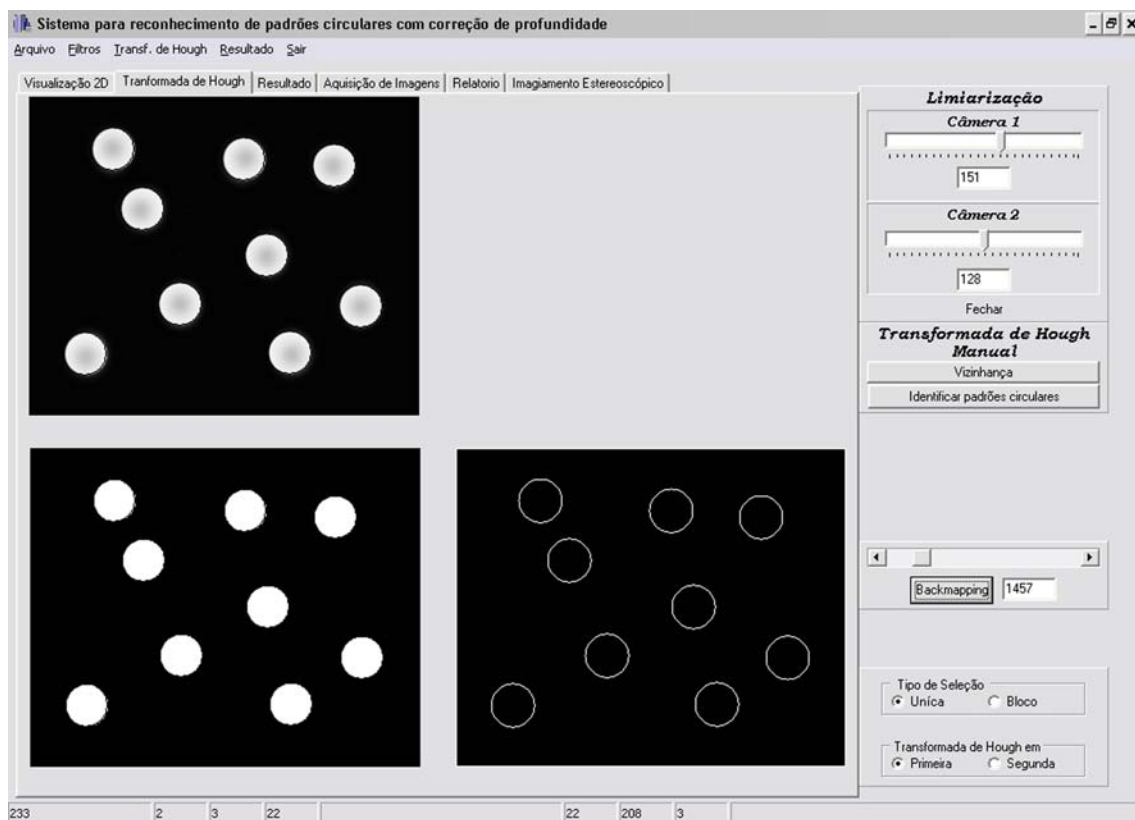


Figura 5.15 – Tela de acesso à definição do *Backmapping* e do algoritmo de vizinhança.

Uma vez detectados todos os padrões circulares, realiza-se o somatório dos dados obtidos, acionando-se o botão *Gera Resultados*. Também, pode ser apresentado um histograma da distribuição dos padrões circulares detectados. O histograma é apresentado na aba *Resultados* com uma tabela que especifica da tamanhos de padrões

circulares em função do raio e quantidades, conforme ilustra a Figura 5.16.

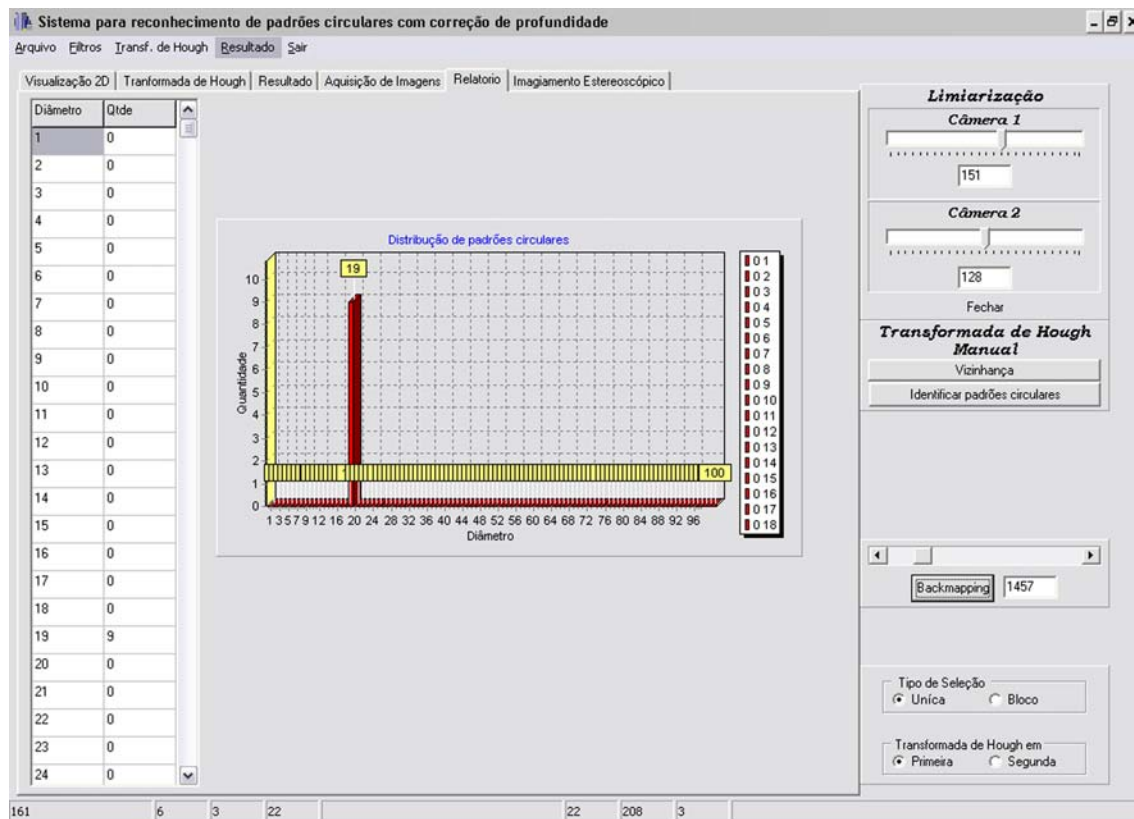


Figura 5.16 - Relatório em forma de tabela e histograma de distribuição de padrões circulares.

O processo de análise descrito anteriormente na forma de execução passo a passo pode ser executado automaticamente pelo sistema utilizando-se o menu transformada de Hough na opção *Automático*. Ao selecionar esta opção o sistema irá solicitar ao usuário que informe o limiar que será utilizado para o procedimento de limiarização. Outro fator importante é que a transformada de Hough identifica padrões circulares escuros em um fundo claro, assim caso haja a necessidade, é possível inverter as cores através do menu transformada de Hough opção Inverter cores.

5.2 – Calibração para medida de padrões circulares em imagens bidimensionais.

Para a calibração do sistema implementado foram geradas imagens com padrões circulares a partir de raio 18 pixels até 85 pixels conforme ilustrado na Figura 5.17.




Figura 5.17 - Padrões de imagens para calibração do sistema de medida, onde (a) representa o menor tamanho (raio de 18 pixels) e (b) o maior tamanho (raio de 85 pixels).

Neste estudo de caso para validação dos padrões foram avaliados em intervalos de 17 em 17 imagens formando-se quatro tabelas (tabelas 2, 4, 6 e 8) com os resultados de erro verdadeiro, erro aparente, erro relativo, erro percentual, erro médio percentual, desvio médio, desvio padrão, desvio quadrático médio, variância e erro tolerável.

Tabela 2 -Dados gerados das imagens analisadas com diâmetros no intervalo de 18 à 34 pixels.

Análise de dados com padrões gerados por simulação					
Intervalo: raios de 18 pixels à 34 pixels.					
Raio do padrão do padrão circular determinado	Raio do padrão circular gerado para calibração	Erro Verdadeiro	Erro Aparente	Erro Relativo	Erro Porcentual
35,123	35,000	0,123	0,123	0,004	0,35
36,234	36,000	0,234	0,234	0,007	0,65
37,568	37,000	0,568	0,568	0,015	1,54
38,221	38,000	0,221	0,221	0,006	0,58
39,112	39,000	0,112	0,112	0,003	0,29
40,345	40,000	0,345	0,345	0,009	0,86
41,124	41,000	0,124	0,124	0,003	0,30
42,221	42,000	0,221	0,221	0,005	0,53
43,112	43,000	0,112	0,112	0,003	0,26
44,121	44,000	0,121	0,121	0,003	0,28
45,321	45,000	0,321	0,321	0,007	0,71
46,741	46,000	0,741	0,741	0,016	1,61
47,144	47,000	0,144	0,144	0,003	0,31
48,454	48,000	0,454	0,454	0,009	0,95
49,121	49,000	0,121	0,121	0,002	0,25
50,147	50,000	0,147	0,147	0,003	0,29
51,141	51,000	0,141	0,141	0,003	0,28

A Tabela 3 ilustra uma síntese da análise realizada e apresentada na Tabela 2.

Tabela 3– Síntese da análise para padrões circulares com diâmetros na faixa de 18 pixels à 34 pixels.

Medidas	
Erro Médio Percentual %:	1,970
Desvio Médio:	0,519
Desvio Quadrático Médio:	0,256
Desvio Padrão:	0,264
Variância:	0,070
Erro Tolerável:	0,209

Tabela 4 - Dados gerados das imagens analisadas com diâmetros no intervalo de 35 à 51 pixels.

Análise de dados com padrões gerados por simulação					
Intervalo: raios de 35 pixels à 51 pixels					
Raio do padrão do padrão circular determinado	Raio do padrão circular gerado para calibração	Erro Verdadeiro	Erro Aparente	Erro Relativo	Erro Porcentual
35,123	35,000	0,123	0,123	0,004	0,35
36,234	36,000	0,234	0,234	0,007	0,65
37,568	37,000	0,568	0,568	0,015	1,54
38,221	38,000	0,221	0,221	0,006	0,58
39,112	39,000	0,112	0,112	0,003	0,29
40,345	40,000	0,345	0,345	0,009	0,86
41,124	41,000	0,124	0,124	0,003	0,30
42,221	42,000	0,221	0,221	0,005	0,53
43,112	43,000	0,112	0,112	0,003	0,26
44,121	44,000	0,121	0,121	0,003	0,28
45,321	45,000	0,321	0,321	0,007	0,71
46,741	46,000	0,741	0,741	0,016	1,61
47,144	47,000	0,144	0,144	0,003	0,31
48,454	48,000	0,454	0,454	0,009	0,95
49,121	49,000	0,121	0,121	0,002	0,25
50,147	50,000	0,147	0,147	0,003	0,29
51,141	51,000	0,141	0,141	0,003	0,28

A Tabela 5 ilustra uma síntese da análise realizada e apresentada na Tabela 4.

Tabela 5 - Síntese da análise para padrões circulares com diâmetros na faixa de 35 pixels à 51 pixels.

Medidas	
Erro Médio Percentual %:	0,590
Desvio Médio:	0,250
Desvio Quadrático Médio:	0,175
Desvio Padrão:	1,183
Variância:	0,033
Erro Tolerável:	0,098

Tabela 6 - Dados gerados das imagens analisadas com diâmetros no intervalo de 52 à 68 pixels.

Análise de dados com padrões gerados por simulação					
Intervalo: raios de 52 pixels à 68 pixels					
Raio do padrão do padrão circular determinado	Raio do padrão circular gerado para calibração	Erro Verdadeiro	Erro Aparente	Erro Relativo	Erro Porcentual
52,252	52,000	0,252	0,252	0,005	0,485
53,258	53,000	0,258	0,258	0,005	0,487
54,245	54,000	0,245	0,245	0,005	0,454
55,987	55,000	0,987	0,987	0,018	1,795
56,541	56,000	0,541	0,541	0,010	0,966
57,757	57,000	0,757	0,757	0,013	1,328
58,641	58,000	0,641	0,641	0,011	1,105
59,412	59,000	0,412	0,412	0,007	0,698
60,222	60,000	0,222	0,222	0,004	0,370
61,797	61,000	0,797	0,797	0,013	1,307
62,014	62,000	0,014	0,014	0,000	0,023
63,210	63,000	0,210	0,210	0,003	0,333
64,011	64,000	0,011	0,011	0,000	0,017
65,222	65,000	0,222	0,222	0,003	0,342
66,666	66,000	0,666	0,666	0,010	1,009
67,000	67,000	0,000	0,000	0,000	0,000
68,306	68,000	0,306	0,306	0,004	0,450

A Tabela 7 ilustra uma síntese da análise realizada e apresentada na Tabela 6.

Tabela 7 - Síntese da análise para padrões circulares com diâmetros na faixa de 52 pixels à 68 pixels.

Medidas	
Erro Médio Percentual %:	0,657
Desvio Médio:	0,385
Desvio Quadrático Médio:	0,288
Desvio Padrão:	0,297
Variância:	0,088
Erro Tolerável:	0,264

Tabela 8 - Dados gerados das imagens analisadas com diâmetros no intervalo de 69 à 85 pixels.

Análise de dados com padrões gerados					
Intervalo: raios de 69 pixels à 85 pixels					
Raio do padrão do padrão circular determinado	Raio do padrão circular gerado para calibração	Erro Verdadeiro	Erro Aparente	Erro Relativo	Erro Porcentual
69,211	69,000	0,211	0,211	0,003	0,306
70,001	70,000	0,001	0,001	0,000	0,001
71,045	71,000	0,045	0,045	0,001	0,063
72,013	72,000	0,013	0,013	0,000	0,018
73,214	73,000	0,214	0,214	0,003	0,293
74,258	74,000	0,258	0,258	0,003	0,349
75,145	75,000	0,145	0,145	0,002	0,193
76,214	76,000	0,214	0,214	0,003	0,282
77,111	77,000	0,111	0,111	0,001	0,144
78,321	78,000	0,321	0,321	0,004	0,412
79,124	79,000	0,124	0,124	0,002	0,157
80,145	80,000	0,145	0,145	0,002	0,181
81,674	81,000	0,674	0,674	0,008	0,832
82,666	82,000	0,666	0,666	0,008	0,812
83,141	83,000	0,141	0,141	0,002	0,170
84,154	84,000	0,154	0,154	0,002	0,183
85,654	85,000	0,654	0,654	0,008	0,769

A Tabela 9 ilustra uma síntese da análise realizada e apresentada na Tabela 8.

Tabela 9 - Síntese da análise para padrões circulares com diâmetros na faixa de 69 pixels à 85 pixels.

Medidas	
Erro Médio Percentual %:	0,397
Desvio Médio:	0,315
Desvio Quadrático Médio:	0,212
Desvio Padrão:	0,218
Variância:	0,048
Erro Tolerável:	0,143

Os resultados apresentados nas Tabelas 3, 5, 7, 9 levaram a valores de erros médios percentuais de respectivamente 3,61%, 1,97%, 0,59%, 0,66% e 0,40%.

5.3 – Calibração para medida de padrões circulares em imagens bidimensional com correção de profundidade obtida por estereoscopia.

Para a calibração foram realizadas aquisições de um padrão circular conhecido com diâmetro de 49mm em diferentes posições em profundidade de 0,5m até 3m. A Figura 5.18 ilustra a imagens adquiridas nas diversas situações estudadas.




Figura 5.18 - Imagens Adquiridas para a calibração onde as imagens (a) e (b) foram adquiridas com profundidade 0,5m, foram adquiridas com profundidade (c) e (d) de 1m, foram adquiridas com profundidade (e) e (f) de 1,5m, foram adquiridas com profundidade (g) e (h) de 2m, foram adquiridas com profundidade (i) e (j) de 2,5m e foram adquiridas com profundidade (k) e (l) de 3m.

Sabendo que o tamanho real do padrão circular utilizado é conhecido, neste caso com diâmetro igual a 49 mm, o fator de escala foi definido da seguinte forma:

$$\text{medida real} = f(\text{ntr}, \text{FPX}, \text{FE}(Z)) \quad \text{Equação 5.1}$$

onde *ntr* é o diâmetro em número de pixel dada pela transformada de Hough, *FPX* é um fator que corrige a diferença entre a medida realizada manualmente e o *ntr*, *FE* é o fator de escala da dimensão do pixel nas imagens adquiridas em função da profundidade obtida pelo o imageamento estereoscópico.

A Tabela 10 apresenta os fatores de escala, para o ensaio de calibração, considerando a imagem 2D corrigida com profundidade variando de 0,5 a 3,0 metros.

Tabela 10 - Tabela com os resultados da calibração.

Distância (m)	Z obtido por estereoscopia	Fator de correção para pixel (FPX)	Fator de escala (FE)
0,5	0,0174	0,5128	1,1939
1	0,0217	0,5283	0,5408
1,5	0,0237	0,5882	0,3469
2	0,0252	0,6364	0,2245
2,5	0,0263	1,0000	0,1224
3	0,0271	1,0000	0,1020

5.4 – Estudo de caso com aplicação do método em imagens reais.

O sistema foi testado com diversas situações reais de posicionamento em cena de objetos circulares, o que permitiu a obtenção dos objetos com a integridade de suas características de formato e tamanho. Os teste foram realizados compondo cenas com bolas de isopor de diferentes tamanho com diâmetro conhecido conforme ilustra a Tabela 11 e seu posicionamento espacialmente diferenciado.

Tabela 11 - Lista dos padrões utilizados nos estudos de caso com seus respectivos tamanhos.

Padrão	Tamanho (mm)
1	49
2	74
3	97

Os estudos de caso seguiram da seguinte ordem:

- a) Primeiro estudo de caso: Foram utilizadas bolas de isopor com tamanhos diferentes posicionadas de forma aleatória com um anteparo escuro ao fundo e suspensas por fio de nylon. As bolas de isopor são apresentadas com os tamanhos diferentes na seqüência de cima para baixo da esquerda para direita são 97mm, 74mm, 49mm, 97mm, 49mm, 49mm, 97mm e 74mm. As aquisições foram realizadas com distância de 1,37 m das bolas de isopor. A Figura 5. 19 ilustra a imagem sob análise e o resultado

dessas imagens é ilustrada na Figura 5.20. Na Figura 5.21 é apresentado o gráfico com os padrões reconhecidos pela transformada de Hough.




Figura 5.19 - Primeiro padrão de teste, realizado com bolas de isopor com tamanhos diferentes posicionada de forma aleatória. ((a) Imagem com a câmera 1; (b) Imagem com a câmera 2)

A Tabela 12 ilustra os resultados obtidos no primeiro estudo de caso.




Figura 5. 20 - (a) e (b) ilustram o Filtro Laplaciano e a identificação da transformada de Hough na imagem do primeiro estudo de caso, respectivamente.





Figura 5. 21 – Histograma dos padrões circulares identificados pela transformada de Hough.


Tabela 12- Tabela comparativa do resultado obtido no primeiro estudo de caso e respectivo erro médio percentual.

Padrão Circular	Diâmetro Obtido com Medida Mecânica (mm)	Diâmetro Obtido com Medida em imagem 2D (nº de pixel)	Diâmetro Obtido com imagem corrigida por estereoscopia (FE= 0,5889 e FPX= 0,3469) (mm)
1	49	10	49
1	49	10	49
2	49	10	49
2	74	14	68,60
2	74	14	68,60
3	97	18	88,19
3	97	19	93,09
3	97	20	97,99
Erro Médio Percentual %			3,59%

- b) Segundo estudo de caso: Neste ensaio foram utilizadas oito bolas de isopor com tamanhos diferente posicionadas de forma aleatória, com uma sobreposição para aumentar a complexibilidade de reconhecimento pelo sistema e com distância de 1,37m Observando a Figura 5. 22 tem-se a seguinte composição de cima para baixo da direita para esquerda: bolas de isopor com diâmetro de 97mm, 74mm, 49mm, 97mm, 49mm, 49 mm, 97 mm e 74 mm respectivamente.



(a)



(b)

Figura 5. 22 - Segundo padrão de teste com oito bolas de isopor com tamanhos diferentes, posicionadas de forma aleatória com uma sobreposição. ((a) Imagem com a câmera 1; (b) Imagem com a câmera 2)

A repetição dos tamanhos das bolas de isopor foi proposital de forma a reconhecer objetos circulares de mesmo tamanho mas posicionados com variabilidade espacial. O resultado do ensaio é apresentado na Tabela 13.




Figura 5. 23 - (a) e (b) ilustram o Filtro Laplaciano e a identificação da transformada de Hough na imagem do segundo estudo de caso, respectivamente.




Figura 5. 24 - Histograma de padrões circulares identificados pela transformada de Hough

c) Terceiro estudo de caso: As bolas de isopor foram posicionadas em de forma aleatória com o corte de um padrão circular e com uma distância de 1,37m. Neste ensaio conforme ilustra a Figura 5. 25, a ordem das bolas de isopor foram respectivamente 49mm, 97mm, 74mm, 97mm, 49mm e 74mm.




Figura 5. 25 - Terceiro teste com oito bolas de tamanhos diferentes e desalinhadas. ((a) Imagem com a câmera 1; (b) Imagem com a câmera 2)

Tabela 13 - Tabela comparativa dos resultados obtido pelo sistema no segundo estudo de caso e respectivo erro médio percentual.

Padrão Circular	Diâmetro Obtido com Medida Mecânica (mm)	Diâmetro Obtido com Medida em imagem 2D (nº de pixel)	Diâmetro Obtido com imagem corrigida por estereoscopia (FE= 0,5889 e FPX= 0,3469) (mm)
1	49	10	49
1	49	10	49
1	49	10	49
2	74	14	68,60
2	74	14	68,60
3	97	19	93,09
3	97	19	93,09
3	97	20	97,99
Erro Médio Percentual %			2,96%




Figura 5. 26 - (a) e (b) ilustram o Filtro Laplaciano e a identificação da transformada de Hough na imagem do terceiro estudo de caso, respectivamente.




Figura 5. 27 - Histograma das circunferência identificadas pela transformada de Hough

Observou-se no ensaio a bola de isopor cortada teve seu tamanho reconhecido e houve a identificação de um padrão não existente de dimensão igual a dois, o qual provavelmente é decorrente do não estabelecimento de um limiar inferior no processo de limiarização utilizado no bloco para o processamento da transformada de Hough.

Os resultados deste ensaio são apresentados na Tabela 14.

Tabela 14 - Resultados obtidos no terceiro estudo de caso e respectivo erro médio percentual.

Padrão Circular	Diâmetro Obtido com Medida Mecânica (mm)	Diâmetro Obtido com Medida em imagem 2D	Diâmetro Obtido com imagem corrigida por estereoscopia (FE= 0,5889 e FPX= 0,3469) (mm)
1	—	2	—
1	49	10	49
1	49	10	49
2	74	14	68,60
2	74	16	78,39
3	97	19	93,09
3	97	19	93,09
Erro Médio Percentual %			3,55%

5.5 - Conclusões

O desenvolvimento do método de reconhecimento de padrões circulares com o uso da transformada rápida de Hough em conjunto com as técnicas de *Backmapping*, análise de vizinhança e correção estereoscópica encontra utilidade na análise de imagens de padrões circulares.

Os testes realizados para validação do método desenvolvido para reconhecimento de padrões circulares com correção de profundidade se mantiveram com erro médio percentual na faixa de 2,96 % a 3,59 %. Estes resultados qualificam o sistema para aplicação no auxílio á

tomada de decisão baseado em problemas que envolvem o reconhecimento de padrões circulares.

5.6 - Sugestões de trabalhos futuros.

- Implementar módulo para visualização estereoscópica nos moldes concebidos conforme diagrama esquemático (Figura 4.1).
- Estudar aplicações do sistema na agricultura e agroindústria.

Referência Bibliográfica

ABDELAZEEM, S. **Microaneurysm Detection using vessels removal and circular Hough transform**, Nineteenth National Radio Science conference, Alecandria, March, 2002.

AGRAWAL, R. C; SHEVGAONKAR, R. K.; Sahasrabudhe, S. C. **A fresh look at the Hough transform**. *PRL*, v. 17, n. 10, p. 1065-1068, 1996.

ATIQUZZAMAN, M. **Multiresolution Hough transform-an efficient method of detecting patterns in images**. *IEEE Transactions on Pattern Analysis and Machine Ingelligence*, New York, v. 14, n. 11, p. 1090-1095, 1992.

ATIQUZZAMAN, M.; AKHTAR, M. W. **A robust Hough transform technique for complete line segment description**. *RTI*, v. 1, p. 419-426, 1995.

BALLARD, D. H. **Generalizing the Hough transform to detect arbitrary shapes**. *Pattern Recognition*, Ezmsford, v. 13, n. 2, p. 111-122, 1981.

BEN-TZVI, D.; NAQVI, A.; SADLER, M. B. **Synchronous multiprocessor implementation of the Hough transform**. *Computer Vision, Graphics, and Image Processing*, San Diego, v. 52, p. 437-446, 1990.

BEN-TZVI, D.; SADLER, M. B. **A combinatorial Hough transform**. *Pattern Recognition Letters*, Amsterdam, v. 11, p. 167-174, 1990.

BESSALAH H., ALIM F., SEDDIKI S. **Implementation of the Hough transform by the on-line mode**, VIPromcom – IEEE Regional 8 International Symposium on video / image processing and multimedia communications, Zadar – Croatia, june 2002

BETELU, S.; SAPIRO, G.; TANNENBAUM, A.; GIBLIN, P. J. **On the computation of the affine skeletons of planar curves and the detection of skew symmetry**. *Pattern Recognition*, Ezmsford, v. 34, n. 5, p. 943-952, 2001.

CARBONI, G e DESAULNIERS, D. **Building a Setereoscopic Microscope**. 1997, http://www.funsci.com/fun3_en/uster/uster.htm, Acessado em: 5/01/2003.

CHAHL, J. S.; SRINIVASAN, M. V. **A complete panoramic vision system, incorporating imaging, ranging, and three dimensional navigation.** In: IEEE Workshop on Omnidirectional Vision (OMNIVIS'00), 2000.

CHATZIS, V.; PITAS, I. **Fuzzy Cell Hough Transform For Curve Detection,** *PR*, v. 30, p.2031-2042 , 1997.

CHU, H. T.; CHEN, C. C. **Domain indexing for fast fractal image compression.** IEEE Transactions on Image Processing, New York, 2001.

COSTA, L .F.; CONSULARO, L. A.; CESAR JÚNIOR, R. M. **Eynergos and its application to contour segmentation.** In: INTERNATIONAL SEMINAR ON BIOELECTRONIC INTERFACES; WORKSHOP ON CYBERNETIC VISION, 3., 1999, Campinas. Proceedings... São Carlos: WCV: ISBI: USP-IFSC, 1999. p. 77-83. Editado por L. da F. Costa e V. M. F. de Lima.

COSTA, L. F. **Small camera movements as a means of reducing the amount of broken and false detected lines in Hough transform.** Real-Time Imaging, London, v. 2, p. 181-185, 1996

COSTA, L. F. **Assessing concurrent hardware alternatives for the implementation of the binary Hough transform.** Applied Signal Processing, v. 1, p. 195-203, 1994b.

COSTA, L. F. **Image compression using Hough transform.** Applied Signal Processing, v. 1, p. 12-19, 1994a.

COSTA, L. F.; CESAR JR., R. M. **Shape analysis and classification: theory and practice.** New York: CRC Press, 2000. 659 p.

COSTA, L. F; SANDLER, M. B. **Effective detection of digital bar segments with Hough transform.** CVGIP. Graphical Models and Image Processing, Duluth, v. 55, n. 3, p. 180-191, 1993.

CRUVINEL, P. E.; VIEIRA, S. R.; CRESTANA, S.; MINATEL, E. R.; MUCHERONI, M. L.; TORRE-NETO, A. **Image processing in automated measurements of raindrop size and distribution.** *Computers and Electronics in Agriculture*, Amsterdam, p. 205-217, 1999.

DAVIES, E. R. **Machine vision: theory, algorithms, practicalities.** London: Academic Press, 1990.

DEMPSEY, G. L.; MCVERY, E. S. **A Hough transform system based on neural networks.** IEEE Transactions on Industrial Electronics, New York, v. 39, n. 6, p. 522-528, 1992.

DEVIJVE, P.; KITTLER J. **Pattern recognition theory and applications.** Berlim: Springer-Verlag, 1987.

DOOLEY, S. R.; STEWART, R. W.; DURRANI, T. S., SETAREHDAN, K. S.; SORAGHAN, J. J. **Fast implementation of accurate geometric transformations for 2-D and 3-D image processing.** IEEE Transactions on Image Processing, New York, 1999

DUDA, R. O.; HART, P. E. **Use of the Hough transformation to detect lines and curves in pictures.** Graphics and Image Processing, v. 12, n. 1, p. 11-15, 1972.

DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification.** 2. ed. New York : Wiley,. 2001.

DUDA, R. O.; MORE, I. D. **Pattern classification and scene analysis.** New York:: J. Wiley, 1973.

ENRIQUE J. TOMERO B., TORNERO J. **Hough Transform for Distance Computation and Collision Avoidance,** *IEEE Transactions On Robotics And Automation*, V. 18, Nº 3, June, 2002.

FAUGERAS, O. D. e MOURRAIN, B. **On the geometry and algebra of the point and line correspondence between n images.** Piscataway, NJ: IEEE - In 5 th Internacional Conference on Computer Vision - MIT, 1995. 951-956.

FISHER, B **Epipolar Gometry**, disponível em: Fisher, B. Epipolar Geometri.http://www.dai.ed.ac.uk/CVonline/LOCAL_COPIES/PSRC_SSAZ/node18.html Acessado em: 30/04/2003.

FONGA, H. **Pattern recognition in gray-level images by Fourier analysis.** *Pattern Recognition Letters*, Amsterdam, v. 17, n. 14, p. 1477-1489, 1996.

FRANCESCHI, F. **Stereograms Theory.**, Disponível em: FRANCESCHI, F. Stereograms Theory. <http://www.ffranceschi.com/midima/ffeng005.html>, acessado em: 16/01/2003.

FU, K. S., GONZALEZ, R. C., e LEE, C. S. G. **Robotics: Control, Sensing, Vision, and Intelligence.** McGraw-Hill: McGraw-Hill, 1987. Primeira Edição

FU, K. S.; KEIDEL, W. D.; WOLTER, H. . **Digital pattern recognition.** Berlim: Springer-Verlag, 1976.

FU, K. S.; MUI, J. K. **A survey on image segmentation.** *Pattern Recognition*, Ezmsford , v. 13, 3-16, 1981.

FUKUNAGA, K. **Introduction to statistical pattern recognition.** 2. ed. [S.l.]: Academic Press, 1990.

FUKUNAGA, K. **The estimation of the Bayes error by the k-nearest neighbor approach.** In: KANAL, L. N.; ROSENFELD, A. (Ed.) *Progress in pattern recognition.* Amsterdam: North-Holland, 1985. v. 2.

GERING, G.; KLEIN, F. **Fast contour identification through efficient Hough transform and simplified interpretation** In: INTERNATIONAL JOINT CONFERENCE ON PATTERN RECOGNITION, 8. 1986, Paris. p 498-500.

GIACINTO, G.; PAOLUCCI, R.; ROLI, F. **Application of neural networks and statistical pattern recognition algorithms to earthquake risk evaluation.** *Pattern Recognition Letters*, Amsterdam, v. 18, n. 11/13, p. 1353-1362, 1997.

GOLDBERG, N.; FEUER, A.; GOODWIN, G. C. **Super-resolution reconstruction using spatio-temporal filtering.** *IEEE Transactions on Image Processing*, New York, 2001.

GONZALEZ, R. C. e WOODS, R. E. **Digital Image Processing.** Addison-Wesley: Addison-Wesley, 1992.

GONZALEZ, R. C.; WOODS, R. E. **Digital image processing.** [S.l.]: Addison-Wesley, 1993.

GRIMSON, W. E. L.; HUTTENLOCHER, D. P. **On the sensitivity of the Hough transform for object recognition.** *IEEE Transactions on Pattern Analysis and Machine Intelligence*, New York, v. 12, n. 3, p. 255-274, Mar 1990.

HAIYUAN W. U., YOSHIKAWA, T., LAO S., KAWADE M. **Glasses Frame Detection with 3D Hough Transform,** *IEEE*, 2002.

HAN, J. H.; LÁSZLÓ, T.; POSTON, T. **Fuzzy Hough transform.** *Pattern Recognition Letters*, Amsterdam, v. 15, p. 649-658, 1994.

HERNANDES, A., BASSET, O., DAUTRAIX, I., MAGNIN, I., FAVRE, C., e GIMENEZ, G. **Stereoscopic Visualization of 3D Ultrasonic Data for the Diagnosis Improvement of Breast Tumors.** *IEEE ULTRASONICS SIMPOSIUM*, 1995. 1435-1438.

HOU, T. H.; LIN, L; SCOTT, P. D. **A neural network-based automated inspection system with an application to surface mount devices.** *International Journal of Production Research*, Basingstoke, v. 31, n. 5, p. 1171-1187, 1993.

HUECKEL, M. **A local visual operator which recognizes edges and lines.** *J. Ass. Comput.*, v. 20, p. 634-646, 1973.

ILLINGWORTH, H. K. J.; KITTLER, J. **Detecting partially occluded ellipses using the Hough transform.** Image and Vision Computing, Guildford, v. 7, n. 1, p. 31-37, Feb 1989.

ILLINGWORTH, J.; KITTLER, J. **The adaptive Hough transform.** IEEE Transactions on Pattern Analysis and Machine Intelligence, New York, v. 9, n. 5, p. 690-695, 1987.

JAIN, R.; KASTURI, R; SCHUNCK, B. G. **Machine Vision.** [S.1.]: McGraw-Hill, 1995.

JOLION, J. M.; ROSENFELD, A. **An $O(\log n)$ pyramid Hough transform.** Pattern Recognition Letters, Amsterdam, v.9, p. 343-349, Jun 1989.

KARTHIK, A., CHANDRA, S., RAMAMOORTHY, B., e DAS, S. **3D Tool Wear Mesurement and Visualisation Using Stereo Imaging.** Tools Manufact: Elsever Scinece Ltd, 19-3-1997. 1573-1581.

KIMME, C.; BALLARD, D.; SKLANSKY, J. **Finding circles by an array of accumulators.** Communications of the ACM, New York, v. 18, n. 2, p. 120-122, Feb. 1975.

KIMURA, A., WATANABE, T. **An Extension of the generalize Hough Transform to realize affine-invariant two-dimensional (2D) shape detection, IEEE, 2002.**

KIRYATI, N; ELDAR, Y; BRUCKSTEIN, A. M. **A probabilistic Hough transform.** Pattern Recognition, Ezsmsford, v. 24, n. 4, p. 303-316, 1991.

LEAVERS, V. F. **Which Hough transform?** CVGIP. Image Understanding, Duluth, v. 58, n. 2, p. 250-264, Sep 1993.

LI, H.; LAVIN, M. A.; MASTER, R. J. L. **Fast Hough transform: a hierarchical approach.** Computer Vision, Graphics And Image Processing, San Diego, v. 36, p. 139-161, 1985.

LIPTON, L. **Developers' HandBook - Background on Creating images for CrystalEyes® and SimulEyes®.** San Rafael, CA: Stereographics Corporation, 1997. 66.

LONGUET-HIGGINS, H. C. **A computer algorithm for reconstruction a scene from two projections.** Nature, 1981. 133-135.

LOW, A. **Introductory computer vision and image processing.** [S. 1.]: McGraw-Hill, 1991.

MARTINEZ, A. C. **Um novo método para medir gotas de chuva com técnicas do processamento digital de imagens**, USP – Universidade do Estado de São Paulo. São Carlos – SP, 2002

MARTINEZ, A. C., CRUVINEL, P. E. **Uso de transformada rápida de Hough na determinação do volume de gotas de chuva natural e artificial**, CONBEA – Congresso Brasileiro de Engenharia Agrícola, Salvador – BA, 2002.

NILCHOLSON, P. T. **Three-Dimensional imaging in archeology: its history and future**. Cardiff: School of the History & Archaeology. Cardiff University, 2001.

OLSON, C. F. **Improving the generalized Hough transform through imperfect grouping**. *IVC*, v 16, p. 627-634, 1998.

PAIVA, A. C., SEIXAS, R. B., e GATTASS, M. **Introdução à Visualização Volumétrica**. Rio de Janeiro: PUC - Inf. MCC03, 1999. 107.

PARKER, J. R. **Practical computer vision using C**. New York: J. Wiley, 1994.

PEREIRA, A. S., **Processamento de imagens medicas utilizando a transformada de hough**. 1995. Tese (Doutorado). Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos.

RIBEIRO JÚNIOR, E. **Análise de atributos visuais em imagens texturais utilizando técnicas espectrais**. 1995. Dissertação (Mestrado) – Universidade Federal de São Carlos, São Carlos.

RISSE, T. **Hough transform for line recognition: complexity of evidence accumulation and cluster detection and cluster detection**. [S. l.]: Academic Press, 1989.

ROSENFELD, A.; ORNELAS, J.; HUNG, Y. **HOUGH TRANSFORM ALGORITHM FOR MESH-CONNECTED SIMD PARALLEL PROCESSOR**. *COMPUTER VISION, GRAPHICS AND IMAGE PROCESSING*, SAN DIEGO, V.41, P.293-305, 1988.

SAHOO, P K.; SOLTANI, S.; WONG, A. K. C. **AN SURVEY OF THRESHOLDING TECHNIQUES**. *COMPUTER VISION, GRAPHICS AND IMAGE PROCESSING*, SAN DIEGO, V. 41, P. 233-260, 1988.

SAITO, J. H., ABIB S., FURUYA, N., e CRUVINEL, P. E. **Multi-DSP Parallel Image Processing for Vision Application**. San Deigo Convection Center, CA, USA: Proceeding of The International Conference on Signal Processing Applications & Techonology (ICSPAT), 14-9-1997. 1331-1335.

SCHALKOFF, R. J. **Digital image processing and computer vision.** [S.l.]: J. Wiley, 1989.

SCHUBERT, R. **Stereoscopic Scanner in Quality Control.** Quebec, Canada: Proc. Conf. "Quality Control by Artificial Vision", Trois-Rivières, 1999.

SHAPIRO, S. D. **Use of the Hough transform for image data compression.** Pattern Recognition Society, v. 12, p. 333-337, Jan. 1980.

SILVA, E. P. **Aplicação da Transformada de Hough em Inspeção Visual Automática.** 1996 Dissertação (Mestrado). Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

SILVA, E. P.; GONZAGA, A. **Inspeção visual automática aplicada ao controle de qualidade de objetos de média complexidade utilizando transformada de Hough.** In: ENCONTRO NACIONAL DE FÍSICA DA MATÉRIA CONDENSADA, 18., 1995, Caxambu. Anais... 1995. p. 99-102.

SONKA, M., HLAVAC, V., e BOYLE, R. **Image Processing and Machine Vision.** EUA: PWS PUBLISHING, 1998.

STOCKMAN, G. C.; AGRAWALA, A. K. **Equivalence of Hough curve detection to template matching.** v. 20, p. 820-822, 1985.

TRUCCO, E.; VERRI, A. **Introductory techniques for 3D computer vision.** [S.l.]: Prentice-Hall, 1998.

VRex Inc. **How to view a stereoscopic image?** Elmsford, NY: VRex Inc., 17-6-1997.

XU, L. ERKKI, O.; PEKKA, K. **A new curve detection method: randomized Hough transform (RHT).** Pattern Recognition Letters, Amsterdam, v. 11, n. 5, p. 331-338, May 1990.

XU, L.; ERKKI, O. **Randomized Hough transform (RHT): basic mechanisms, algorithms, and computational complexities.** CVGIP. Image Understanding, Duluth, v. 57, n. 2, p. 131-154, Mar 1993.

YUEN, H. K.; PRINCEN, J.; ILLINGWORTH, J.; KITTLER, J. **Comparative study of Hough transform methods for circle finding.** Image and Vision Computing, Guildford, V. 8, n. 1, p. 71-77, Feb. 1989.

ZHU Y., CARRAGHER B., POTTER C. S. **Fast detection of generic biological particles in cryo-em images through efficient Hough transform, IEEE, 2002.**

ZOU C., SHI G. **A Hough transform-based method for fast detection of fixed period sinusoidal curves in images**, *IEEE*, 2002.