

[Redacted]

PAULO CÉSAR CORTEZ

[Redacted]

RECONHECIMENTO DE OBJETOS BIDIMENSIONAIS  
USANDO MODELAGEM POLIGONAL

Dissertação apresentada ao Curso de MESTRADO  
EM ENGENHARIA ELÉTRICA da Universidade Fede-  
ral da Paraíba, em cumprimento às exigências  
para obtenção do Grau de Mestre.

ÁREA DE CONCENTRAÇÃO: PROCESSAMENTO DA INFORMAÇÃO

JOÃO MARQUES DE CARVALHO  
(Orientador)

CAMPINA GRANDE  
AGOSTO - 1992

[Redacted]

D16  
621.391(043)  
C828n

15

C



C828r      Cortez, Paulo Cesar  
Reconhecimento de objetos bidimensionais usando  
modelagem poligonal / Paulo Cesar Cortez. - Campina Grande,  
1992.  
89 f.

Dissertacao (Mestrado em Engenharia Eletrica) -  
Universidade Federal da Paraiba, Centro de Ciencias e  
Tecnologia.

1. Teoria dos Sinais - 2. Teoria da Informacao - 3.  
Algoritmo - 4. Modelos Poligonais dos Objetos 5.  
Dissertacao I. Carvalho, Joao Marques de, Dr. II.  
Universidade Federal da Paraiba - Campina Grande (PB) III.  
Titulo

CDU 621.391(043)

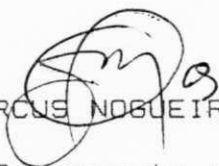
RECONHECIMENTO DE OBJETOS BIDIMENSIONAIS  
USANDO MODELAGEM POLIGONAL

PAULO CÉSAR CORTEZ

DISSERTAÇÃO APROVADA EM 21/08/92



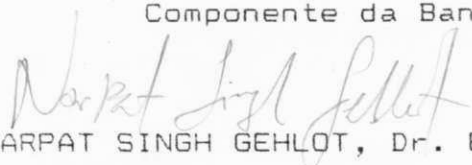
JOÃO MARQUES DE CARVALHO, Ph. D., UFPB  
Orientador



ANTÔNIO MARCUS NOBUEIRA LIMA, Dr., UFPB  
Componente da Banca



MISAEL ELIAS DE MORAIS, Dr.-Ing., UFPB  
Componente da Banca



NARPAT SINGH GEHLOT, Dr. Engg., UFPB  
Componente da Banca

CAMPINA GRANDE

AGOSTO - 1992

## O ANALFABETO POLÍTICO

"O pior analfabeto é o analfabeto político.

Ele não ouve, não fala, nem participa  
dos acontecimentos políticos.

Ele não sabe que o custo de vida, o preço do feijão,  
do peixe, da farinha, do aluguel,  
do sapato e remédio dependem das decisões políticas.

O analfabeto político é tão burro  
que se orgulha e estufa o peito dizendo que odeia  
a política.

Não sabe o imbecil que de sua ignorância  
política nasce a prostituição, o menor abandonado,  
o assaltante e o pior de todos os  
bandidos, que é o político vigarista,  
pilantra, corrupto e lacaio das empresas  
nacionais e internacionais."

Bertolt Brecht

Aos meus pais, Miguel e Iolanda,  
a minha companheira Sueli, aos  
meus filhos Aresqui e Bartira.

## AGRADECIMENTOS

Agradeço, em primeiro lugar, ao meu orientador Prof. João Marques de Carvalho pela orientação, dedicação e acompanhamento tão necessários ao desenvolvimento e conclusão deste trabalho.

Não poderia esquecer de agradecer aos colegas professores do Departamento de Engenharia Elétrica da Universidade Federal do Ceará que assumiram direta ou indiretamente a minha carga de trabalho naquela instituição, com destaque para os professores Antônio Mauro Barbosa, João César Mota, Fátima Nacizeuma S. de Medeiros, Helano de Sousa Castro, Mário Fialhos e Roberto Oscar Brasil pelo incentivo e estímulo a mim prestados. Agradeço também ao colega e amigo professor do Departamento de Física Giovanni Cordeiro Barroso que nos momentos mais difíceis soube prestar a sua ajuda irrestrita, ouvindo e discutindo todos os detalhes na reta final deste trabalho.

Também não poderia deixar de agradecer a ajuda, direta ou indiretamente, prestada pelos funcionários da Universidade Federal da Paraíba, em especial, ao engenheiro José Wallington P. Leal e ao mestre Rinaldo Santos Júnior, durante todo o desenvolvimento deste trabalho.

Agradeço também a todos os colegas e amigos do LAPS, em particular ao colega Adriano Fábio Q. de Brito pela sua contribuição dada na implementação do referido trabalho.

## ABSTRACT

This dissertation presents a system that recognizes and localizes 2D objects, isolated or superimposed. Global and local attributes extracted of polygonal models of objects are used. The modelling of the objects defines the strategy used for this system. An new algorithm for polygonal modelling of two-dimensional objects is proposed. This algorithm possesses some relevant features, such as variable number of sides for the model produced (depending on the desired accuracy), allows the extraction of geometric measurements during the modelling process, integrates in a single step the operations of segmentation, modelling and feature extraction. The operation of the algorithm is described in details in this dissertation, experimental results are presented and conclusions are drawn about the advantages and future applications of the method.

## RESUMO

Esta dissertação apresenta um sistema capaz de reconhecer e localizar objetos em bidimensionais, isolados ou sobrepostos, que utiliza os atributos globais e locais extraídos dos modelos poligonais dos objetos. As estratégias usadas, pelo sistema aqui desenvolvido, estão intimamente ligadas à forma de modelamento dos objetos. Um novo algoritmo para modelamento poligonal de objetos bidimensionais foi proposto. Este algoritmo aqui proposto possui algumas características relevantes tais como: produz número de segmentos (lados do polígono) variável, dependendo apenas da precisão desejada; permite extração de medidas geométricas do modelo do objeto durante o processo de modelamento; integra em uma única etapa os processos de segmentação, de modelamento e de extração de características. A operação do algoritmo é descrita em detalhes nesta dissertação, resultados experimentais são apresentados e conclusões são tiradas a respeito das vantagens do método e possíveis aplicações futuras.



## LISTA DE FIGURAS

	PAG.
Figura 1.1 - Estrutura Geral de um Sistema de Reconhecimento...	17
Figura 1.2 - Situação Típica de um Ambiente Industrial.....	20
Figura 2.1 - Sistema Genérico de Reconhecimento.....	24
Figura 2.2 - Diagrama de Blocos do Sistema Proposto.....	31
Figura 3.1 - Diagrama de Blocos do Pré-Processamento.....	36
Figura 3.2 - Código Direcional de Borda.....	37
Figura 3.3 - Vizinhança do Ponto $P_i$ para o Rastreamento.....	38
Figura 3.4 - Distância entre o Ponto $P_i$ e o Segmento de Reta $\overline{P_{i-2}P_{i-1}}$ .....	40
Figura 3.5 - Fluxograma do Algoritmo.....	42
Figura 3.6 - Medidas Geométricas Extraídas dos Modelos.....	44
Figura 3.7a - Imagem Original em 4 Tons de Cinza do Objeto 1....	46
Figura 3.7b - Imagem Pré-Processada.....	46
Figura 3.7c - Imagem Segmentada.....	46
Figura 3.7d - Modelo Poligonal.....	46
Figura 3.8a - Imagem Original em 4 Tons de Cinza do Objeto 2....	47
Figura 3.7b - Imagem Pré-Processada.....	47
Figura 3.7c - Imagem Segmentada.....	47
Figura 3.7d - Modelo Poligonal.....	47

PAG.

Figura 4.1 - Hierarquia do Classificador.....	55
Figura 4.2 - Posição Inicial dos Lados antes da Transformação..	60
Figura 5.1 - Cena 1 em 4 Tons de Cinza.....	65
Figura 5.2 - Cena 2 em 4 Tons de Cinza.....	66
Figura 5.3 - Cena 3 em 4 Tons de Cinza.....	67
Figura 5.4 - Cena 4 em 4 Tons de Cinza.....	74

## LISTA DE TABELAS

### Tabelas de Classificação dos Objetos Isolados

	PAG.
Tabela 1.1 - Resultados Obtidos da Cena 1.....	66
Tabela 1.2 - Resultados Obtidos da Cena 2.....	67
Tabela 1.3 - Resultados Obtidos da Cena 3.....	67

### Tabelas de Classificação dos Objetos Parcialmente Oclusos

#### Para o Atributo Composto por Três Lados e Dois Ângulos

Tabela 2.1 - Resultados Obtidos da Cena 2 para $L_c = 0.3$ e $L_a = 30^\circ$ .....	70
Tabela 2.2 - Resultados Obtidos da Cena 2 para $L_c = 0.2$ e $L_a = 20^\circ$ .....	71
Tabela 2.3 - Resultados Obtidos da Cena 3 para $L_c = 0.3$ e $L_a = 30^\circ$ .....	72
Tabela 2.4 - Resultados Obtidos da Cena 3 para $L_c = 0.2$ e $L_a = 20^\circ$ .....	73
Tabela 2.5 - Resultados Obtidos da Cena 4 para $L_c = 0.3$ e $L_a = 30^\circ$ .....	74

Tabela 2.6 - Resultados Obtidos da Cena 4 para $L_c = 0.2$ e $L_a = 20^\circ$ .....	75
--	----

Para o Atributo Composto por Dois Lados e Um Ângulo

Tabela 3.1 - Resultados Obtidos da Cena 2 para $L_c = 0.3$ e $L_a = 30^\circ$ .....	77
Tabela 3.2 - Resultados Obtidos da Cena 2 para $L_c = 0.2$ e $L_a = 20^\circ$ .....	78
Tabela 3.3 - Resultados Obtidos da Cena 3 para $L_c = 0.3$ e $L_a = 30^\circ$ .....	79
Tabela 3.4 - Resultados Obtidos da Cena 3 para $L_c = 0.2$ e $L_a = 20^\circ$ .....	80
Tabela 3.5 - Resultados Obtidos da Cena 4 para $L_c = 0.3$ e $L_a = 30^\circ$ .....	81
Tabela 3.6 - Resultados Obtidos da Cena 4 para $L_c = 0.2$ e $L_a = 20^\circ$ .....	82

## Í NDECE

	PAG.
CAPITULO 1 - INTRODUÇÃO.....	15
CAPITULO 2 - REVISÃO DOS MÉTODOS	
1 - Introdução.....	22
2 - Sistemas Baseados em Modelos.....	23
a) Métodos dos Atributos Globais.....	24
b) Métodos dos Atributos Estruturais.....	25
c) Métodos dos Grafos Relacionais.....	27
3 - Proposta de Trabalho.....	29
CAPITULO 3 - MODELAMENTO DOS OBJETOS E DAS CENAS EM 2D	
1 - Introdução.....	32
2 - Escolha do Modelo.....	33
3 - Pré-Processamento e Segmentação.....	35
4 - Descrição do Algoritmo de Modelamento.....	39
5 - Discussão do Algoritmo.....	42
6 - Resultados Experimentais.....	44
7 - Conclusão.....	48

CAPITULO 4 - RECONHECIMENTO DE MODELOS BIDIMENSIONAIS

1 - Introdução.....	50
2 - Modelagem da Cena.....	51
3 - Reconhecimento dos Modelos de Objetos Isolados.....	54
4 - Localização dos Modelos de Objetos Isolados.....	56
5 - Localização e Reconhecimento dos Modelos de Objetos Parcialmente Oclusos.....	57

CAPITULO 5 - RESULTADOS EXPERIMENTAIS

1 - Introdução.....	64
2 - Resultados Obtidos com Objetos Isolados.....	65
3 - Resultados Obtidos com Objetos Parcialmente Oclusos.....	68
3.1 - Atributo Composto por Três Lados e Dois Ângulos.....	70
3.2 - Atributo Composto por Dois Lados e Um Ângulo.....	76
4 - Conclusão.....	82

CAPITULO 6 - CONCLUSÃO.....84

BIBLIOGRAFIA.....87

## CAPITULO 1

### INTRODUÇÃO

O desenvolvimento das tecnologias de computadores digitais particularmente a de integração de circuitos e dos transdutores (sensores) nas últimas duas décadas, permitiu aumentar enormemente o campo de suas aplicações. Simultaneamente progressos importantes foram obtidos na área de inteligência artificial, tornando possível construir máquinas com capacidade cada vez maior de se comunicar com o meio externo, e processar inteligentemente as informações recebidas através de sensores para realizar determinadas tarefas [1].

Inicialmente essas tarefas eram simples como por exemplo, leitura de fitas magnéticas, cartões e etc.. Depois surgiram tarefas mais complexas como por exemplo, ler caracteres manuscritos, reconhecer a voz de um locutor, detectar objetos numa fotografia, guiar veículos e mísseis, interpretar imagens médicas, analisar imagens aéreas e sísmicas, etc.[2].

Muitas dessas tarefas são realizadas através da visão computacional ou visão artificial que consiste em extrair informações sobre uma cena, analisando imagens dessa cena. As imagens consideradas são formadas por luz visível, assume-se que a cena é ilumi-

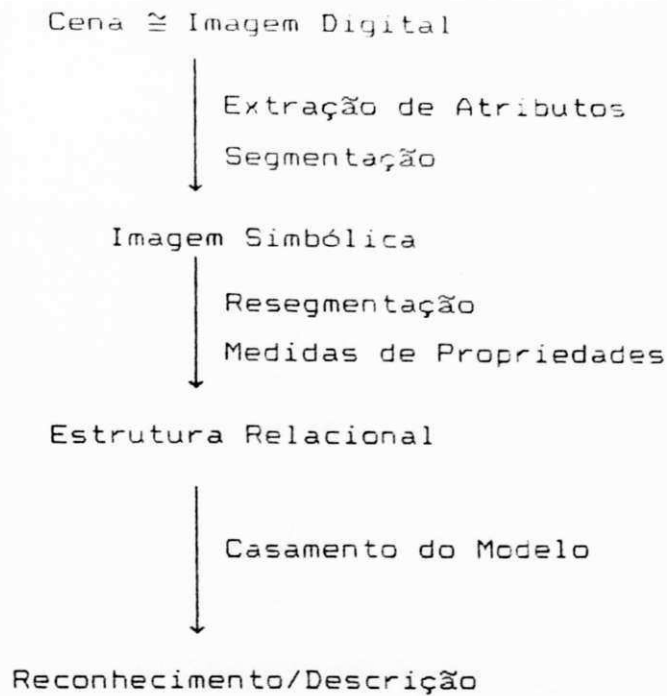
nada por uma fonte de luz, natural ou artificial é que o sensor óptico incorporado ao sistema transforma qualquer imagem da cena em uma imagem plana, perpendicular ao campo de visão do sensor óptico. São ignorados os objetos transparentes [3].

Para processar uma imagem analógica por um computador digital, primeiro é necessário converter a imagem analógica em uma imagem digital, ou seja, em uma matriz discreta de pontos, representando os níveis de cinza ou os valores da cor da grade discreta de pontos da imagem plana. Os elementos da matriz discreta de pontos são usualmente conhecidos como pixels (picture elements). Em muitas aplicações, um único valor é medido em cada ponto amostrado, representando o valor do brilho daquele ponto na imagem, em outras aplicações que requerem informações sobre as cores, vários valores são medidos para cada ponto amostrado, representando a medida do brilho do ponto num conjunto de  $K$  bandas espectrais, assim, cada pixel será representado por uma  $K$ -upla desses valores [3].

Em visão computacional, a entrada é uma imagem (ou várias imagens) e a saída consiste de informações sobre a cena que se obteve da imagem ou das imagens da cena. Por exemplo, a saída pode ser algum tipo de descrição da cena. O processo derivado da descrição da cena é algumas vezes chamado de análise da imagem. Em geral, a função principal de um sistema de visão artificial é reconhecer objetos de vários tipos que possam estar presentes em uma determinada cena [3].

A estrutura geral de um sistema de reconhecimento de objetos em cenas bidimensionais, dada uma imagem digital da cena, é mostrada na figura 1.1 [3].





*Figura 1.1: Estrutura Geral de um Sistema de Reconhecimento*

Um objeto é definido como uma disposição de partes cujas propriedades (níveis de cinza, texturas, formas, comprimentos, etc) e relações (posições relativas, comprimentos relativos, etc) satisfazem determinadas condições. Desta forma, para reconhecer um objeto na imagem verifica-se uma coleção de partes da imagem que correspondem às partes do objeto e que satisfazem condições apropriadas [3].

Os processos usados para detectar partes na imagem são conhecidos como técnicas de segmentação ou detecção de atributos. Detecção de atributos identifica os tipos especiais de padrões locais na imagem, por exemplo linhas ou curvas, manchas, cantos, etc.. Tais padrões podem ser detectados pela comparação da imagem com modelos (em cada posição e orientação) ou pela comparação de várias combinações das primeiras e segundas derivadas em cada ponto da imagem. A segmentação identifica distintas regiões da imagem

(subpopulações de pixels) ou particiona a imagem em regiões conectadas, cada uma delas é "homogênea" com base em algum critério [3].

Os processos de segmentação e detecção de atributos podem ser considerados como designadores de rótulos aos pixels da imagem, indicando que esses pixels pertencem à classes especiais. Assim, o resultado do processo de segmentação produz como saída uma "imagem simbólica", na qual o "valor" de cada pixel é um rótulo antes que nível de cinza [3].

Os conjuntos de pixels já rotulados podem tornar a serem agrupados em novos conjuntos, baseado em vários critérios; esse processo é chamado de resegmentação. Por exemplo, pode-se dividir um conjunto de pixels em regiões conectadas e se pode distinguir várias partes de uma região (convexa/côncava, alongada, etc.). Curvas ou arcos conectados podem também ser resegmentados com base em vários critérios geométricos [3].

Dada uma coleção de partes obtidas por (re)segmentação de uma imagem, pode-se agora medir várias propriedades e as relações entre as partes. Propriedades geométricas dependem unicamente do conjunto de pixels contidos nas partes (área, alongamento, etc.), enquanto que outras propriedades dependem dos níveis de cinza desses pixels (média, textura, etc.), e semelhantemente para as relações [3].

Os objetos são comumente descritos como sendo constituídos de partes que possuem certas propriedades e relações entre elas. Essa informação pode, em princípio, ser representada por um grafo rotulado (o "grafo objeto") no qual os nós representam as partes e os arcos as relações entre as partes. Os nós são "rotulados" com valores ideais de propriedades ou conjunto de constantes desses va-

lores. Assim, a primeira aproximação para o reconhecimento de objetos em uma imagem pode ser pela extração de partes apropriadas da imagem (usando detecção de atributos ou técnicas de segmentação), computando suas propriedades e relações, e representando essa informação em um grafo rotulado (o "grafo cena"), onde os rótulos são agora os valores de propriedades e relações observados. Neste caso, o reconhecimento pode então ser feito encontrando subgrafos do grafo cena que se aproximem dos grafos objetos, ou que satisfazem as condições definidas pelo grafo objeto. A aproximação descrita está restrita a cenas bidimensionais, isto é, aplica-se ao reconhecimento de objetos cuja orientação espacial, relativa a direção vista, é conhecida [3].

Diversas aplicações de visão computacional envolvem cenas essencialmente bidimensionais, destacando-se aquelas que utilizam superfícies planas na manufatura. Embora, algumas técnicas usadas para análise de imagens bidimensionais (2D) são também utilizadas nos primeiros estágios na análise de imagens tridimensionais [3].

As principais aplicações de visão artificial na indústria se concentrou na inspeção automática e na manipulação robótica de partes. Dotar os robôs de visão, significa torná-los flexíveis o suficiente para realização de tarefas mais complexas e adaptarem seu comportamento em função das tarefas, ou seja, transformá-los em polivalentes [2].

As aplicações ligadas à inspeção e à manipulação automática, requerem, como primeira tarefa, reconhecer e localizar precisamente os objetos presentes na cena, isto é, realizar uma classificação de padrões ("pattern classification"). Segundo Aya-che [2], a complexidade desta tarefa depende da disposição espaci-

al dos objetos na cena.

A situação típica de um ambiente industrial é aquela de uma linha de montagem em que os objetos se encontram num plano horizontal fixo, ou em uma esteira rolante, com condições de iluminação que, em geral, podem ser controladas. Esta situação está mostrada na figura 1.2. A solução, do ponto de vista de visão, para uma situação desse tipo é na maior parte das vezes relativamente simples e consiste em fixar uma ou mais câmeras numa posição, de modo que a cena de interesse se encontre dentro do campo de visão. Nestas condições, o reconhecimento e a localização dos objetos podem ser feitos através de uma análise e classificação da cena em 2D apenas.




Figura 1.2: Situação Típica de um Ambiente Industrial.

O trabalho apresentado nesta dissertação, tem como objetivo propor uma solução algorítmica para o problema descrito acima. O que significa dizer que o sistema desenvolvido deverá ser capaz de reconhecer e localizar modelos de objetos em 2D nas cenas onde os objetos aparecem, isolados ou parcialmente oclusos, utilizando-se de estratégias diferentes daquelas já conhecidas, que são revistas no próximo capítulo. A inclusão no problema de cenas nas quais os objetos se encontram em contato ou com oclusão parcial, envolve estabelecer um sério compromisso entre a flexibilidade, relativa a capacidade de reconhecer objetos com oclusão parcial, sistema de um lado e a sua complexidade por outro lado.

Este trabalho está organizado da seguinte forma: o próximo capítulo faz uma revisão geral e sucinta dos métodos que utilizam modelos para solucionar o problema apresentado e trata também das estratégias, normalmente, usadas na solução do mesmo; o terceiro capítulo trata do pré-processamento e da modelagem poligonal dos objetos bidimensionais, propondo um novo algoritmo para tal; o quarto capítulo aborda a metodologia utilizada na solução do problema de reconhecimento e localização; o capítulo 5 faz uma avaliação dos resultados experimentais obtidos e finalmente o sexto capítulo apresenta as conclusões, contribuições do trabalho e aponta algumas linhas de investigação que dele podem advir.

## CAPITULO 2

### REVISÃO DOS MÉTODOS

#### 1 - INTRODUÇÃO

O desenvolvimento das pesquisas e da tecnologia em visão artificial aumentou consideravelmente o potencial desta área nas últimas décadas. As áreas de aplicação são as mais diversas, com destaque para sensoriamento remoto e automação industrial. Dependendo da aplicação específica, um sistema de visão sofisticado pode ser necessário, como os que trabalham em três dimensões (3D). Entretanto, muitos dos problemas podem ser resolvidos com o uso de sistemas de visão bidimensionais, inclusive aqueles que trabalham com imagens binárias. Uma grande parte deles são sistemas baseados em modelos ("model-based") que tentam casar uma cena (imagem de entrada) com algum elemento pertencente a um conjunto de modelos definidos a priori.

Neste capítulo é feita uma revisão dos mais conhecidos sistemas de reconhecimento que utilizam métodos baseados em modelos.

Inicialmente é feito uma caracterização dos modelos bidimensionais usados no reconhecimento de peças industriais. Em seguida é feita uma descrição dos sistemas baseados em modelos, fazendo

uma caracterização geral de cada um deles e mostrando suas principais vantagens e desvantagens. Finalmente a proposta desta dissertação é apresentada.

## 2 - SISTEMAS BASEADOS EM MODELOS

Boa parte dos sistemas de visão desenvolvidos até o momento, usam modelos 2D para a descrição e reconhecimento de peças industriais em cenas complexas. Entretanto, alguns têm como base as propriedades radiométricas ( como por exemplo, os níveis de cinza, cor, textura) para a descrição e o reconhecimento das cenas, como por exemplo, os sistemas propostos por Asano, Mochizuki e Hata [4] e por Mital, Leng e Khwang [5]. Outros sistemas utilizam propriedades geométricas que são muito importantes em aplicações industriais conforme Chin e Dyer [6]. Dentre esses sistemas podem ser citados os sistemas desenvolvidos por Rillo [7], por Turney, Mudge e Volz [8], por Bhanu e Faugeras [9], por Ayache e Faugeras [10] e por Fukuda et al. [11]. De acordo com Chin e Dyer [6], os métodos utilizados podem ser divididos em três classes: métodos dos atributos globais, métodos dos atributos estruturais e métodos dos grafos relacionais. A decisão na escolha dos atributos é subjetiva e depende do modelo e da aplicação específica.

O procedimento em cada uma das classes acima é formada por três partes básicas: extração de atributos, modelagem das cenas e o casamento. A figura 2.1 mostra, em diagrama de blocos, de um sistema genérico de reconhecimento de objetos baseado em modelos bidimensionais.

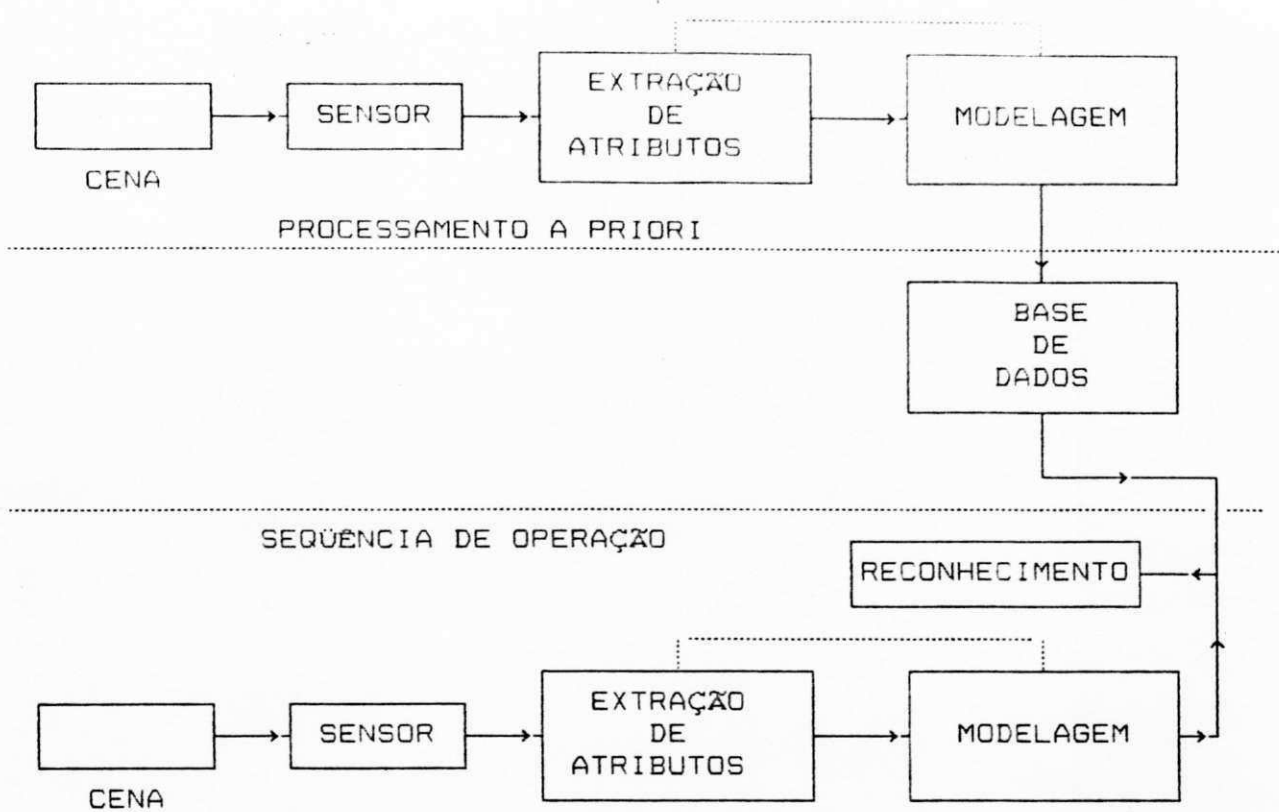


Figura 2.1: Sistema Genérico de Reconhecimento.

A descrição das classes de métodos que se segue é baseada no trabalho de Chin e Dyer, onde maiores detalhes podem ser encontrados [6].

#### a) Métodos dos Atributos Globais

Esta classe usa, como o próprio nome sugere, atributos globais dos modelos tais como, perímetro, área, momentos de inércia, centro de gravidade. Cada um desses métodos associa um vetor de atributos  $n$ -dimensional ao modelo do objeto, onde  $n$  é o número de atributos utilizados. Normalmente, métodos estatísticos de reconhecimento de padrões são empregados, em que os vetores de atributos extraídos da cena, são comparados com cada um dos vetores de atri-



butos dos modelos contidos em uma base de dados. Os modelos da base de dados são formados a partir de imagens de protótipos representativas de cada um dos objetos possíveis de serem reconhecidos. São, em geral, utilizadas a regra de Bayes e a decisão hierárquica seqüencial para a classificação, sendo que esta pode vir a reduzir o tempo computacional.

Em geral, estes métodos são rápidos por serem limitados o número de atributos globais. Sua principal desvantagem está em não permitir o reconhecimento de objetos em contato ou parcialmente oclusos. Outra desvantagem é também não reconhecer modelos com atributos globais semelhantes. Uma forma de melhorar a classificação é usar a decisão hierárquica associada ao classificador de vizinho mais próximo. Deste modo, se  $n$  atributos são usados na descrição de todos os modelos, então, cada modelo é representado por um ponto no espaço  $n$ -dimensional de atributos. Por conseguinte, uma dada lista de atributos de uma imagem de entrada será reconhecida como sendo aquela que se encontra mais próxima no espaço  $n$ -dimensional de atributos.

#### b) Métodos de Atributos Estruturais

Da mesma forma que os atributos globais, os atributos locais podem ser utilizados por diversos métodos. Os atributos locais caracterizam partes do contorno do objeto, ou seja, descrevem propriedades locais dos contornos dos objetos que, em geral, são mais complexas do que as propriedades caracterizadas pelos atributos globais.

Os métodos de atributos estruturais, em geral, usam atributos

locais para a construção dos modelos e descrevem propriedades mais complexas dos objetos em termos de segmentos retos, arcos de curvaturas constantes e curvas, definindo as partes das bordas dos modelos dos objetos. Nesta classe, os atributos são representados abstratamente e organizados de forma estruturada em listas ou em uma seqüência de equações. O ordenamento dos atributos é feito de tal forma que seguir a lista de atributos seqüencialmente é equivalente a percorrer a borda do objeto.

Os modelos baseados em atributos locais, em geral, estão associados aos métodos de casamento sintático, no qual os atributos locais são transformados em primitivas que são organizadas em sentenças por regras gramaticais bem estruturadas. O reconhecimento usa os procedimentos de verificação de hipóteses. A estruturação dos atributos locais nos modelos é usada para prever a localização dos objetos na cena. Desta forma, atributos de objetos hipotéticos são medidos, na base da predição hipotética do modelo, para a verificação ordenada e finaliza com o casamento.

Os métodos de atributos estruturais representam um avanço, em relação aos métodos de atributos globais, em termos de capacidade e de flexibilidade por permitir reconhecer objetos parcialmente oclusos. Entretanto, requerem mais complexos e sofisticados processos de treinamento e de reconhecimento. Por isso, necessitam de maior esforço computacional. Embora essa classe utilize muitos atributos locais para modelar os objetos, no processo de pesquisa e casamento dos atributos de uma imagem, pode, em geral, ser evitado o teste de todos os atributos, trabalhando-se apenas com os mais significativos para o problema em questão.

Uma das desvantagens desses métodos é que os atributos de bor-

das (locais) não são, em geral, invariantes às translações e às rotações. Por conseguinte, o reconhecimento consiste de uma seqüência de tentativas de casamento de alguns atributos locais e de uma rigorosa análise gramatical das sentenças. O resultado de cada tentativa é usado para restringir a pesquisa de outros atributos, visando reduzir o tempo consumido neste processo. Os procedimentos para a verificação de hipóteses consomem muito tempo se o modelo não encontrar uma aproximação desejada, podendo chegar a 150 segundos. O sistema proposto por Ayache [2] tenta diminuir essas desvantagens fazendo uso dos maiores lados (privilegiados) do modelo poligonal, os quais são mais invariantes às translações e às rotações e utilizando um algoritmo paralelo associado a um hardware para a geração e verificação de hipóteses.

#### c) Métodos dos Grafos Relacionais

Os métodos dos grafos relacionais utilizam uma combinação de atributos locais e de suas relações. Neste, as relações geométricas entre os atributos locais (retas e curvas) têm um particular interesse.

A estrutura relacional é representada por um grafo no qual cada nó está associado com um atributo local e são rotulados pela lista de propriedades de cada atributo. Os arcos representam as relações entre os atributos dos pares de nós que se encontram ligados e são rotulados com uma lista de valores relacionais (distâncias e adjacências).

O reconhecimento do modelo do objeto, em geral, é feito através do casamento dos grafos, um da imagem de entrada e o outro de

um dos modelos extraídos durante o processo de treinamento. Portanto, em geral, utilizam as técnicas de casamento de grafos.

Esses métodos podem ser usados para manipular cenas em que os objetos se encontram em contato ou parcialmente oclusos, onde as partes visíveis dos objetos correspondem aos subgrafos. O reconhecimento neste caso se reduz ao casamento dos subgrafos.

Essa classe de métodos apresenta como vantagens:

- o os atributos locais consomem pouco tempo porque são simples e podem ser extraídos seqüencialmente;
- o os modelos são pouco sensíveis às pequenas variações para um dado tipo de objeto;
- o se alguns atributos locais estão ausentes (por causa de ruídos ou oclusão), ainda pode ser reconhecido um dado objeto com base nos atributos restantes associados ao modelo.

Os métodos de grafos relacionais diminuem os requisitos com relação a ordem com que os objetos foram apresentados ao sistema para que o reconhecimento seja bem sucedido. Desde que, o modelo possua os atributos locais e suas relações, na forma de grafo, o casamento não depende unicamente da presença exata dos atributos da borda, mas também de outros atributos e propriedades de suas interconexões (distâncias, adjacências). Para o reconhecimento ter sucesso, o único requisito é que um conjunto chave de atributos locais se encontre visível e corretamente posicionado. Isto pode constituir uma restrição, pois, um conjunto de objetos que possua regiões muito semelhantes (silhuetas) pode produzir um conjunto chave de atributos locais que apresentem suas propriedades nos grafos muito próximas, portanto, comprometendo o reconhecimento para tal conjunto de objetos.

A principal desvantagem desses métodos é o fato de que um grande número de atributos são extraídos e agrupados para o reconhecimento de um objeto. Portanto, os algoritmos de casamento usados por esses modelos devem ser mais complexos e por isso podem ser mais de 10 vezes mais lentos do que os algoritmos utilizados pelas classes anteriores.

Outra desvantagem destes métodos é que o reconhecimento pode ser lento se o modelo-grafo for complexo, resultando em uma grande complexidade no problema de detecção de clique [10]. Uma tentativa de melhorar o desempenho nestes casos é o uso de técnicas de relaxação relatado por Bins, Velasco e Monteiro [12] e Ayache e Faugeras [13].

Comparando com as classes anteriores, esta classe apresenta uma forma de modelagem e casamento mais complexos. O procedimento de casamento envolve técnicas de pesquisas e casamento de grafos que são, em geral, computacionalmente mais lentas e ainda sem uma proposta de hardware especial que possibilite aplicações industriais.

As técnicas de pesquisas hierárquicas em grafos usadas por Barrow e Tenenbaum [14] pode reduzir o tempo computacional no processo de casamento pela decomposição do modelo em componentes independentes, introduzindo um certo grau de paralelismo.

### 3 - PROPOSTA DE TRABALHO

A proposta deste trabalho consiste no desenvolvimento de um sistema simples baseado em modelos poligonais para reconhecimento de modelos bidimensionais de objetos isolados e com algum grau de

oclusão. A solução proposta utiliza simultaneamente características das três classes descritas anteriormente, aproveitando a rapidez e simplicidade da primeira classe e a capacidade de reconhecer objetos em oclusão das outras duas classes.

Para realizar a classificação foram adotadas duas estratégias, uma para os modelos isolados e outra para as cenas em que aparecem objetos em contato ou com oclusão parcial. A estratégia usada para a classificação dos modelos isolados está baseada nos atributos globais, na decisão hierárquica sequencial e na minimização de erros desses atributos. A outra estratégia, isto é, usada na classificação de cenas nas quais os objetos apresentam-se em contato ou em oclusão parcial, está baseada nos atributos locais (lados do polígono) e nas suas relações geométricas, os ângulos internos entre eles. Essa estratégia utiliza, para o casamento dos atributos, funções discriminantes lógica ou analítica.

O trabalho que será descrito nos capítulos subseqüentes, apresenta algumas características que o diferencia dos demais sistemas propostos citados neste capítulo. Dentre estas características estão: os blocos de modelagem e extração de atributos se comunicam com a base de dados e as informações adquiridas através desta comunicação serão utilizadas no reconhecimento de cenas onde os objetos se encontram em contato ou parcialmente oclusos. Adicionalmente, possui características em comum com as três classes descritas no item anterior. Por exemplo, como a primeira classe utiliza os atributos globais e a decisão hierárquica sequencial para casar modelos de objetos isolados; como a segunda classe usa os atributos locais para casar modelos das cenas com objetos em oclusão ou que se encontram em contato, e a forma sequencial de

ordenamento dos atributos; e como a terceira classe utiliza os atributos locais (lados do polígono) e suas relações (ângulos internos entre eles) para as cenas com objetos em oclusão ou que se encontram em contato.

O sistema proposto está representado em forma de diagrama de blocos na figura 2.2.

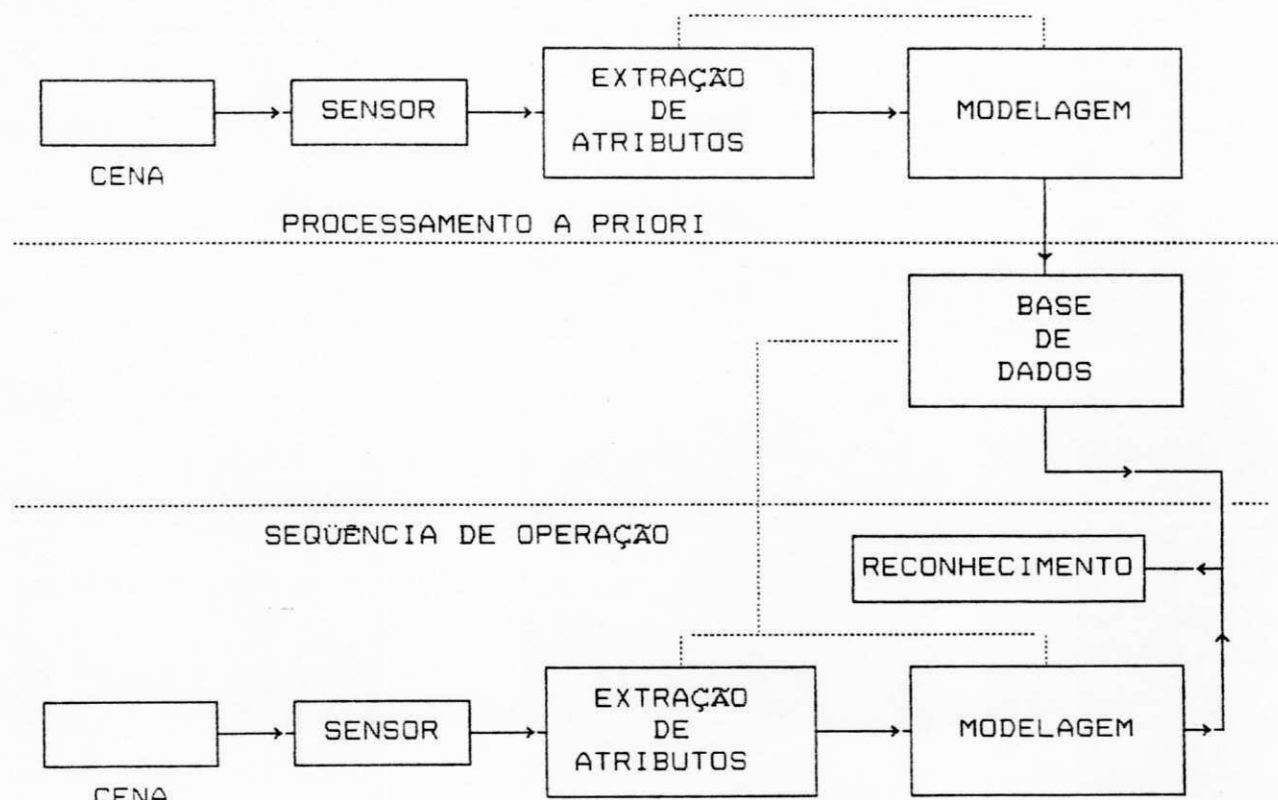


Figura 2.2: Diagrama de Blocos do Sistema Proposto.

Durante sua elaboração foi desenvolvido um novo algoritmo para construir os modelos poligonais, o qual resultou no trabalho [15] e que é descrito no capítulo 3.

## CAPITULO 3

### MODELAMENTO DOS OBJETOS E CENAS BIDIMENSIONAIS

#### 1 - INTRODUÇÃO

Este capítulo trata do modelamento dos objetos e das cenas em 2D, bem como dos diversos aspectos envolvidos neste processo, destacando-se o algoritmo utilizado na implementação do mesmo.

Inicialmente são abordadas as razões que justificam a escolha do uso de modelos poligonais para os objetos e as cenas. Logo após é descrita a etapa de pré-processamento, que é responsável pela preparação da imagem original para aplicar o algoritmo que fará o modelamento dos objetos e das cenas, bem como a segmentação da imagem gradiente (resultante do pré-processamento). Em seguida será descrito o processo de modelagem propriamente dito, o qual é realizado simultaneamente com a segmentação. Finalmente far-se-á uma discussão do algoritmo e dos resultados obtidos, mostrando suas principais características, vantagens, desvantagens em relação aos outros algoritmos usados para a mesma finalidade, estudados por Junior e Linhares [17] e são tiradas algumas conclusões sobre o método proposto e suas possíveis aplicações.



## 2 - ESCOLHA DO MODELO

Define-se o modelo de um objeto ou de uma cena como uma forma aproximada de representação do objeto ou da cena. Portanto, a escolha de um determinado modelo define a forma de se resolver um dado problema.

Existe uma grande variedade de aplicações em processamento digital de imagens nas quais os modelos poligonais de objetos em 2D estão sendo usados, com especial destaque, no reconhecimento de padrões e visão robótica [16]. Muitos algoritmos que já foram propostos para este fim e são usados com bastante frequência nas mais diversas áreas, três dos quais foram estudados e comparados por Junior e Linhares [17].

Os modelos poligonais de objetos em 2D apresentam muitas vantagens, com relação a outras formas de modelagem bidimensional, algumas das quais são enumeradas por Ayache e Faugeras [10], tais como:

- o por serem locais, permitem descrever diferentes partes do objeto ou cena de forma independente;
- o são compactos, pois, a maioria dos objetos podem ser formados com menos de 100 segmentos;
- o são gerais, podendo, portanto, serem aplicados a qualquer forma geométrica bidimensional;
- o são sensíveis às variações de posição e de orientação;
- o podem ser representados facilmente por um conjunto de retas, sendo, assim, bastante simples de serem manipulados.

Além dessas vantagens pode-se acrescentar aos modelos poligonais de objetos em 2D a rapidez no processamento e a facilidade na

manipulação desses modelos.

O novo algoritmo proposto neste capítulo possui algumas características relevantes tais como:

- o produz número de segmentos (lados do polígono) variável, dependendo apenas da precisão desejada;
- o permite a extração de medidas geométricas durante o processo de modelamento;
- o integra em uma única etapa os processos de segmentação, de modelamento e extração de características.

Em geral, os algoritmos usados para modelamento poligonal de objetos bidimensionais, dividem-se em duas classes: os iterativos e os seqüenciais.

Os algoritmos iterativos necessitam de uma dada solução inicial, usa os dados de forma global e algum critério de aproximação. São menos sujeitos a problemas comuns decorrentes da digitalização da imagem e do pré-processamento destas, como por exemplo, a posição do objeto em relação ao foco da câmera. Em geral, requerem um tempo de processamento maior e alguns dependem de uma boa solução inicial [17].

Já os algoritmos seqüenciais procuram construir o modelo ao longo da curva de contorno do objeto. Estes algoritmos são, em geral, mais simples, mais rápidos, mas as regras heurísticas utilizadas são muitas vezes de difícil compreensão e para ajustar a aproximação é necessário, em geral, ajustar também as regras, o que os tornam menos flexíveis. Podem estar sujeitos a problemas de digitalização da imagem como aquele que foi citado antes ou ao seu pré-processamento [17].

O algoritmo aqui descrito apresenta algumas características

dos algoritmos seqüenciais, tais como: a maneira como os dados são tratados e a existência de regras para a escolha dos pontos que poderão compor a lista de vértices do polígono. Entretanto, difere por possuir regras bastante simples, de fácil entendimento, e que são aplicadas durante a segmentação, resultando numa maior eficiência e também por ser pouco sensível às variações no contorno dos objetos decorrentes da digitalização e do pré-processamento. Isto se deve ao fato deste método utilizar um critério de determinação dos vértices independentes das regras. Além disso, reúne características muito particulares (como o controle da precisão do modelo através de parâmetros independentes dos critérios para eleição dos possíveis vértices) que o torna mais flexível na definição da precisão do modelo.

### 3 - PRÉ-PROCESSAMENTO E SEGMENTAÇÃO

Para que o algoritmo proposto seja utilizado eficientemente, faz-se necessário que a imagem original passe por uma etapa de pré-processamento, cujo objetivo é garantir que as bordas do objeto, a ser modelado, sejam contínuas e bem definidas.

Para obter os resultados apresentados neste trabalho a imagem original foi submetida sucessivamente aos processos de binarização, filtragem passa-baixa e a detecção das bordas.


Na binarização das imagens foi empregada a técnica de limiar, já que as imagens originais apresentam um histograma bimodal, o que facilita sobremaneira esta etapa. Durante esta etapa podem ser perdidas informações sobre a imagem original, embora não o suficiente para prejudicar o desempenho dos algoritmos usados.

A filtragem passa-baixa foi realizada da seguinte maneira: cada pixel na posição  $(x,y)$  teve seu nível de cinza substituído pela média aritmética dos níveis de cinza dos pontos com coordenadas  $(x,y+1)$ ,  $(x+1,y)$  e  $(x+1,y+1)$  além do próprio ponto. Dentre os filtros passa-baixas testados (da média 3X3, da ordem, etc.) este foi o que apresentou melhores resultados para a finalidade específica desta etapa. O objetivo desta etapa é tão somente espalhar as bordas do objeto e com isso facilitar a utilização do algoritmo de rastreamento.

Em seguida, a imagem resultante do processo anterior foi submetida a um filtro passa-alta, implementando o gradiente discreto de Roberts descrito por Mascarenhas e Velasco [18], para fazer a detecção das bordas do objeto.

O processo de filtragem pode eventualmente vir a ser substituído por máscaras que realizam a extração dos contornos do objeto de forma adequada a partir da imagem binária como descrito por Rillo [6].

Toda esta etapa está representada na forma de diagrama de blocos na figura 3.1.



*Figura 3.1: Diagrama de Blocos do Pre-Processamento.*

A forma mais compacta de armazenar informações sobre a imagem

segmentada é através do código em cadeia que consiste das coordenadas do ponto inicial seguida por uma seqüência do código direcional de bordas. Cada número desta lista representa a direção associada ao caminho percorrido entre os pontos que compõem a borda da imagem de acordo com Gonzalez [16] e Castleman [19]. As direções assumidas por cada ponto em relação ao ponto central P estão representadas na figura 3.2.

3	2	1
4	P	0
5	6	7

*Figura 3.2: Código Direcional de Borda.*

Uma vez obtida a imagem gradiente, a mesma é submetida ao passo seguinte, ou seja, a segmentação.

Para a segmentação da imagem gradiente usou-se o método de rastreamento de bordas (**boundary tracking**), o qual permite que as bordas do objeto sejam percorridas de forma contínua e seqüenciada conforme Gonzalez [16]. Algumas mudanças foram introduzidas neste método para melhorar o seu desempenho quando da sua utilização. A primeira foi em relação à obtenção dos dois pontos iniciais necessários à inicialização do algoritmo que realiza o modelamento dos objetos. O primeiro é obtido pela varredura da imagem gradiente no sentido das linhas, do topo até encontrar o primeiro ponto da borda do objeto e o segundo é o seu vizinho, na direção 0 do código direcional de borda. Assim, é formado o segmento de reta inicial composto pelos dois pontos iniciais. A partir desse momento é usado o procedimento do algoritmo de rastreamento, com as

modificações descritas abaixo.

De posse do ponto atual  $P_1$  e do ponto anterior  $P_0$ , centrado no ponto atual  $P_1$ , examina-se cada um dos três vizinhos ( $P_{p1}$ ,  $P_{p2}$  e  $P_{p3}$ ), opostos a  $P_0$ . Adotando-se o ponto  $P_{p1}$  como o ponto central, tem-se os pontos  $F_1$ ,  $F_2$  e  $F_3$  opostos a  $P_1$ . Centrado no ponto  $P_{p2}$ , tem-se  $F_3$ ,  $F_4$  e  $F_5$  os pontos opostos a  $P_1$  e para  $P_{p3}$  os pontos  $F_5$ ,  $F_6$  e  $F_7$ . Calcula-se a soma dos níveis de cinza dos três pontos  $F_i$  associados a cada  $P_{pj}$ , onde  $i=1,2,3,4,5,6$  e  $7$  e  $j=1,2$  e  $3$ , ou seja, para  $P_{p1}$  a soma ( $S_1$ ) dos níveis de cinza de  $F_1$ ,  $F_2$  e  $F_3$ , para  $P_{p2}$  a soma ( $S_2$ ) dos níveis de cinza de  $F_3$ ,  $F_4$  e  $F_5$  e finalmente para  $P_{p3}$  a soma ( $S_3$ ) dos níveis de cinza de  $F_5$ ,  $F_6$  e  $F_7$ . Seja  $S_m$  a maior das três somas  $S_j$ . O ponto  $P_{pj}$  escolhido para pertencer a borda do objeto ou da cena será aquele que possuir maior nível de cinza e cuja soma  $S_j$  dos pontos  $F_i$  associados a ele for maior que  $60\%S_m$ . Caso contrário é escolhido aquele que possuir o maior nível de cinza dos dois pontos  $P_{pj}$  restantes se a respectiva soma  $S_j$  for maior que  $60\%S_m$ , senão, será escolhido o ponto  $P_{pj}$  de menor nível de cinza, mas que apresenta a maior soma  $S_j = S_m$ . Na hipótese de dois pontos  $P_{pj}$  com níveis de cinza iguais também será escolhido aquele cuja soma  $S_j$  for maior que  $60\%S_m$ , com prioridade para a direção anterior. A figura 3.3 ilustra a vizinhança do ponto  $P_1$ .




Figura 3.3: Vizinhança do Ponto  $P_1$  para o Rastreamento.

#### 4 - DESCRIÇÃO DO ALGORITMO DE MODELAMENTO

Inicialmente é necessário escolher alguns parâmetros para uso do algoritmo que são:

- a) A distância máxima permitida  $d$  que irá determinar os vértices do modelo, em função da precisão desejada. Para este trabalho foi considerado  $d = 2.0$  pixels;
- b) Algum critério para eleger os pontos que serão os possíveis vértices do modelo poligonal, como por exemplo a variação no código direcional de borda entre pixels consecutivos, o qual foi utilizado para se obter os resultados experimentais aqui mostrados;
- c) O número  $N$  de pixels que deverá ser obtido por vez no processo de segmentação da imagem gradiente para permitir a aplicação do critério do item b). Este parâmetro influi na precisão do modelo. Neste trabalho assumiu-se  $N = 2$  pixels;
- d) Um critério para eliminar vértices comuns a dois segmentos quase alinhados, que, embora, facultativo, também influi na precisão do modelo e que pode ser definido em função da forma geral dos objetos utilizados. Um exemplo é a variação angular mínima permitida entre dois segmentos consecutivos, a qual pode ser determinada por um dado limiar. Para os resultados aqui mostrados foi considerado um valor de 10 graus para este limiar.

Considerando uma imagem digital qualquer  $I(x,y)$ , chamaremos de  $P_0$  o pixel inicial  $P(x_0, y_0)$  e  $P_1$  o segundo pixel  $P(x_1, y_1)$ , localizados durante a segmentação, onde  $x_0, y_0$  e  $x_1, y_1$  são suas respectivas coordenadas. Considerando o processo em andamento,  $P_i$  é definido como o último ponto selecionado ou o ponto atual. Considere

os pontos, que formam o último segmento de reta, como sendo  $P_{i-1}$  e  $P_{i-2}$ . O ponto  $P_{i-2}$  é pelo menos um vértice temporário no caso de ser o primeiro ponto localizado no início da segmentação. Isto se deve ao fato de que para iniciar o processo de rastreamento e a aplicação do algoritmo descrito, são necessários dois pontos iniciais (comentado no item anterior) para formar o segmento de reta inicial e desta forma o ponto inicial coincide com o ponto  $P_{i-2}$ . Quando é encontrado o vértice inicial, durante esse procedimento, este passa a ser considerado o ponto inicial para que o processo de rastreamento seja concluído.

O algoritmo utilizado se baseia na distância entre  $P_i$ , o ponto atual, e o segmento de reta formado pelos pontos  $\overline{P_{i-2}P_{i-1}}$ , como ilustrado na figura 3.4.




Figura 3.4: Distância entre  $P_i$  e o Segmento de Reta  $\overline{P_{i-2}P_{i-1}}$ .

Descrição do algoritmo:

Início: considera-se temporariamente o ponto  $P_0$  como o vértice inicial e que junto com o ponto  $P_1$ , obtidos no início da seg-



mentação, comporão o segmento de reta inicial a partir do qual se inicia o processo de rastreamento e modelamento.

1) A partir do ponto atual, rastrea-se  $N$  ou mais pixels, de acordo com o critério definido no item b), até eleger o próximo ponto  $P_i$ ;

2) Calcula-se  $d_1$  (distância entre o segmento de reta  $\overline{P_{i-1}P_{i-2}}$  ao ponto atual  $P_i$ ).

Se  $d_1$  for maior do que  $d$ , então,

o  $P_{i-1}$  será um vértice;

o atualiza o segmento para  $\overline{P_{i-1}P_i}$ ;

o retorna a 1);

senão,

o retorna a 1).

3) A partir de três vértices formados, pode-se tentar otimizar o modelo, eliminando-se o vértice comum aos dois segmentos, dependendo de algum critério fixado no item d). Este passo é opcional;

Fim: o processo de segmentação da imagem gradiente e o modelamento termina quando for encontrado o vértice inicial.

O fluxograma da figura 3.5 explica mais detalhadamente o algoritmo. Considere:  $V_j$  o  $j$ -ésimo vértice do modelo poligonal,  $S_j$  o  $j$ -ésimo segmento de reta,  $P_k$  o  $k$ -ésimo ponto rastreado, Controle=C para o processo em andamento e Controle=F para o final do processo.




Figura 3.5: Fluxograma do Algoritmo.

### 5 - DISCUSSÃO DO ALGORITMO

O algoritmo proposto apresenta significativas vantagens em

relação ao algoritmo descrito por Pavlidis [20], tais como:

- o Acopla etapas indispensáveis em qualquer modelamento poligonal de objetos bidimensionais, ou seja, as etapas de segmentação e modelagem;
- o Para se construir o modelo de um objeto em 2D não é necessário obter antes a lista de pontos da borda do objeto, como nos algoritmos mais usados;
- o Possibilita obter determinadas características geométricas do modelo durante o processo de modelagem.

Durante o processo de modelagem de cada um dos objetos, as medidas geométricas extraídas foram: o comprimento de cada um dos lados do polígono e os ângulos internos. Obtido o modelo poligonal, calculou-se o centróide, o perímetro total, os ângulos entre cada lado e o segmento de reta formado pelo centróide e por cada vértice e a distância do centróide a cada um dos vértices. Durante a segmentação de furos existentes em alguns objetos, extrai-se o perímetro de cada furo. Para melhor entendimento destas medidas pode-se observar a figura 3.6, que ilustra três vértices do modelo  $V_{j-1}(x_{j-1}, y_{j-1})$ ,  $V_j(x_j, y_j)$  e  $V_{j+1}(x_{j+1}, y_{j+1})$ , onde  $x_j$  e  $y_j$  são suas coordenadas, e o centróide  $C(x_c, y_c)$  com coordenadas  $x_c$  e  $y_c$ . Assim, define-se:

- a)  $L_j$  (comprimento do lado  $j$  em pixels) como sendo a distância euclidiana entre os vértices  $V_j$  e  $V_{j+1}$ ;
- b)  $\alpha_{j-1}$  (ângulo entre os lados  $L_{j-1}$  e  $L_j$  em graus);
- c)  $\beta$  (ângulo entre o lado  $L$  e o segmento de reta  $\overline{V_{j+1}C}$  em graus);
- d)  $\rho_j$  (a distância euclidiana entre o vértice  $V_{j+1}$  e  $C$  em pixels);
- e)  $x_c$  e  $y_c$  (coordenadas do centróide) são calculadas pelo momento de primeira ordem das respectivas coordenadas dos vértices do

modelo.

São essas medidas que, juntas, compõem os atributos para serem usados no reconhecimento dos modelos de objetos em 2D porque são invariantes à translação e à rotação desses modelos.





Figura 3.6: Medidas Geométricas Extraídas dos Modelos.

## 6 - RESULTADOS EXPERIMENTAIS

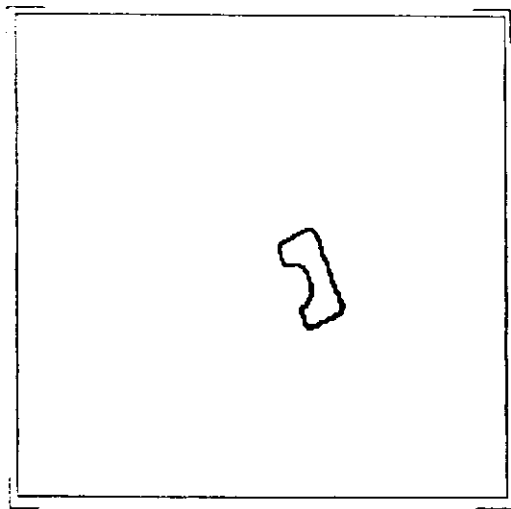
As imagens utilizadas neste trabalho foram digitalizadas no Laboratório de Sub-Sistemas Integráveis da EPUSP (Escola Politécnica da Universidade de S. Paulo). Suas dimensões são 256X252 (linhas por colunas) com 256 níveis de cinza.

A etapa de binarização foi realizada com um limiar 96, ou seja, os níveis de cinza com valores inferiores a 96 foram substituídos por 0 (zero), caso contrário por 1, resultando numa imagem com apenas dois níveis de cinza, um caracterizando o objeto e o outro o fundo. Os resultados obtidos são mostrados nas figuras 3.7 e 3.8, onde se pode observar seqüencialmente as imagens original, pré-processada, segmentada e seus respectivos modelos polígo-


nais. Para o objeto da figura 3.7 foi obtido um modelo com 15 lados e para o da figura 3.8 um modelo com 12 lados. Estes valores são função dos parâmetros utilizados na implementação do algoritmo, podendo, portanto, serem facilmente alterados de modo a produzir uma maior ou menor precisão na construção do modelo.




a)



b)




c)




d)


Figura 3.7: a) Imagem Original em 4 Tons de Cinza do Objeto I,  
b) Imagem Pré-Processada, c) Imagem Segmentada e  
d) Modelo Poligonal.




a)



b)



c)



d)

*Figura 3.8: a) Imagem Original em 4 Tons de Cinza do Objeto 2.  
b) Imagem Pré-Processada, c) Imagem Segmentada e  
d) Modelo Poligonal.*

No caso de reconhecimento de padrões, usando modelos poligonais, em geral, é preferível sacrificar a precisão de modo a obter segmentos maiores, em menor número e conseqüentemente mais discriminantes. Outra característica muito importante para as mais diversas aplicações é que os segmentos maiores são mais invariantes às

translações e as rotações [2].

## 7 - CONCLUSÃO

Pelos resultados obtidos e pela discussão anterior pode ser concluído que o algoritmo apresentado neste trabalho representa uma nova forma eficiente de modelar objetos em 2D que se espera ser possível que sua aplicação reduza o tempo de processamento nas diversas áreas onde são usados os modelos poligonais. Isto decorre do fato de unir em uma única etapa diversos passos normalmente executados para realizar o modelamento de objetos bidimensionais.

O método proposto pode ser adaptado para fazer o modelamento poligonal de curvas diversas.

As condições requeridas para uso do algoritmo são típicas de ambientes onde é possível obter imagens com alto contraste entre o objeto e o fundo. Mas poderá ser utilizado em outras situações desde que o pré-processamento da imagem original produza as condições necessárias à aplicação do algoritmo "boundary tracking".

Espera-se que a aplicação deste algoritmo em reconhecimento de padrões venha trazer alguma contribuição nesta área, pois, mesmo os trabalhos mais recentes, que usam modelos poligonais, como o descrito por Ayache e Faugeras [10], ainda trabalham com modelos tradicionais e com as etapas de obtenção da lista de borda, modelagem e extração de características de forma isolada.

Da forma como o algoritmo proposto executa a modelagem dos objetos e das cenas em 2D, é possível propor um sistema de visão que poderá realizar o reconhecimento de objetos durante o processo de modelagem de uma determinada cena. Este sistema proposto possui



características bastante distintas dos sistemas apresentados na literatura atual.

## CAPITULO 4

### RECONHECIMENTO DE MODELOS BIDIMENSIONAIS

#### 1 - INTRODUÇÃO

Este capítulo trata da metodologia usada no processo de reconhecimento de modelos em 2D de objetos. No início é abordada a etapa de segmentação e modelagem da cena, entendida esta como sendo a imagem gradiente objeto do estudo (imagem de entrada), podendo conter um ou mais objetos, isolados ou sobrepostos. Em seguida é descrito o método usado no reconhecimento dos modelos de objetos isolados bem como a localização dos mesmos. Logo após é feita a descrição do método de reconhecimento dos modelos de objetos que se encontram parcialmente oclusos, utilizando-se duas funções discriminantes diferentes, uma lógica e outra analítica bem como as posições dos modelos reconhecidos. O método aqui desenvolvido está diretamente ligado ao processo de modelagem da cena e dos objetos antes treinados. É importante destacar que o procedimento descrito neste capítulo é original, pelo menos em relação aos métodos descritos na literatura especializada ao nosso alcance.

## 2 - MODELAGEM DA CENA

Nesta etapa é realizada uma varredura, da imagem de entrada contendo os objetos na cena, no sentido das linhas, do topo até o final da imagem. Durante este processo, cada contorno fechado será modelado. Se no interior de um dado contorno existirem outros contornos fechados, representando furos na cena modelada, estes serão contados e extraídos os seus respectivos perímetros. Após terminar este procedimento, cada um dos contornos fechados será submetido ao processo de reconhecimento que será descrito na próxima seção.

Para realizar a modelagem de cada contorno fechado da cena é utilizado o mesmo algoritmo usado para modelar os protótipos de cada objeto durante a fase de construção da base de dados. Este procedimento já foi descrito com detalhes no capítulo anterior.

O processo de segmentação e modelagem de cada contorno fechado em um polígono, possui características peculiares e que serão descritas em seguida.

Considere em curso o processo de segmentação e modelagem de um contorno poligonal fechado. Como atributo a ser extraído deste modelo, será considerado o conjunto formado pela sequência de três lados consecutivos e os ângulos internos entre eles, ou, alternativamente, o conjunto de dois lados e o ângulo interno entre eles. A partir da formação do primeiro atributo, é feita uma comparação com a base de dados, visando casar os atributos do modelo em formação, com algum atributo dos modelos de protótipos armazenados. Este processo continua a cada novo vértice formado. Assim, ao final da segmentação e modelagem deste contorno, tem-se um vetor de

atributos casados onde está armazenada toda a informação relativa a casamentos ocorridos entre atributos do contorno e os atributos dos modelos dos protótipos guardados na base de dados. Também são armazenados neste vetor as posições dos atributos no contorno e nos protótipos onde estes atributos foram identificados, sempre que ocorrer casamento.

O vetor de atributos casados, gerado durante esta etapa, será usado no processo de reconhecimento e localização dos objetos parcialmente oclusos.

É importante salientar que, durante a modelagem da cena são extraídos os mesmos atributos que foram extraídos na modelagem dos protótipos dos objetos isolados durante a fase de treinamento, acrescidos das medidas de orientação de cada lado do modelo poligonal e das coordenadas de seus vértices.

O casamento dos atributos do modelo do contorno é feito comparando cada novo atributo formado com aqueles existentes na base de dados. Considere o atributo formado por três lados consecutivos do modelo poligonal e seus dois ângulos internos. Seja  $c_j$  o  $j$ -ésimo lado do contorno poligonal fechado e  $L_{c_j}$  o seu comprimento (em pixels),  $p_i$  o  $i$ -ésimo lado do protótipo e  $L_{p_i}$  seu comprimento (em pixels), onde  $j=2, \dots, N_{vc}$ , sendo  $N_{vc}$  o número de vértices do contorno poligonal (ainda não conhecido durante esta etapa) e  $i=2, \dots, N_{vp}$ , sendo  $N_{vp}$  o número de vértices do protótipo;  $\alpha_{c_{j-1}}$  ângulo (em graus) entre os lados  $c_{j-1}$  e  $c_j$  do contorno; e  $\alpha_{p_{i-1}}$  o ângulo (em graus) entre os lados  $p_{i-1}$  e  $p_i$  do protótipo. Desta forma, podem-se definir os erros para os comprimentos dos lados e para os ângulos internos entre eles:

$$El_{j-1} = \frac{|L_{c_{j-1}} - L_{p_{i-1}}|}{L_{c_{j-1}}} \quad (4.1a)$$

$$El_j = \frac{|L_{c_j} - L_{p_i}|}{L_{c_j}} \quad (4.1b)$$

$$El_{j+1} = \frac{|L_{c_{j+1}} - L_{p_{i+1}}|}{L_{c_{j+1}}} \quad (4.1c)$$

$$Ea_{j-1} = |\alpha_{c_{j-1}} - \alpha_{p_{i-1}}| \quad (4.2a)$$

$$Ea_j = |\alpha_{c_j} - \alpha_{p_i}| \quad (4.2b)$$

No caso em que os atributos são formados por apenas dois lados do polígono e o ângulo interno entre eles, os valores iniciais para  $i$  e para  $j$  são ambos iguais a 1.

Para um dado valor de  $j$ , os erros acima definidos são calculados para todos os lados e ângulos internos de cada um dos modelos dos protótipos contidos na base de dados. Os valores encontrados são armazenados para uso quando do reconhecimento e localização de modelos de cenas contendo objetos oclusos.

Em seguida à modelagem da borda do contorno fechado, será iniciada a etapa de busca do(s) furo(s) para que seja medido o perímetro de cada um, se existirem. O perímetro dos furos é calculado, durante o rastreamento do mesmo, usando o código direcional de borda, descrito no capítulo anterior. Portanto, a cada novo pixel rastreado, um pixel é adicionado ao perímetro parcial se o código direcional for par e  $\sqrt{2}$  pixels se for ímpar [16], [19]. Finalizado o processo de rastreamento de cada furo, o perímetro

total do furo está calculado e os dados, utilizados para o reconhecimento do contorno fechado, estão completos.

### 3 - RECONHECIMENTO DOS MODELOS DE OBJETOS ISOLADOS

Após a modelagem e geração do vetor de atributos casados de cada contorno fechado da cena, o próximo passo é a etapa de reconhecimento do(s) objeto(s) contido(s) nesta região da cena já modelada. Esta etapa consiste em casar a parte da imagem que já foi modelada com um dos modelos armazenados na base de dados. No caso de não haver contato ou sobreposição entre os objetos da cena, detectados no nível 1 do classificador, são utilizados os atributos globais (perímetro total, número de furos, perímetros dos furos e o número de vértices) para classificar a porção modelada da imagem.

O classificador está organizado de forma hierárquica com relação aos atributos globais da seguinte forma: perímetro total, número de furo(s) e número de vértices no primeiro nível e perímetros do(s) furo(s) no segundo nível como mostra a figura 4.1. Para cada um desses atributos são considerados os erros  $E_{P_t}$  (para o perímetro total),  $E_{n_f}$  (para o número de furos),  $E_{P_f}$  (para o perímetro do(s) furo(s)) e  $E_{n_v}$  (para o número de vértices), definidos a seguir:

$$E_{P_t} = \frac{|P_{tc} - P_{tp}|}{P_{tc}} \quad (4.3a)$$

$$E_{n_f} = |N_{fc} - N_{fp}| \quad (4.3b)$$

$$E_{n_v} = |N_{vc} - N_{vp}| \quad (4.3c)$$

$$E_{P_f} = \frac{|P_{fc} - P_{fp}|}{P_{fc}} \quad (4.3d)$$

Onde  $P_{tc}$  e  $P_{tp}$  são os perímetros totais do contorno fechado e do protótipo,  $N_{fc}$  e  $N_{fp}$  são os números de furos contidos no contorno fechado e no protótipo,  $N_{vc}$  e  $N_{vp}$  são os números de vértices do contorno e do protótipo,  $P_{fc}$  e  $P_{fp}$  são os perímetros dos furos do contorno e do protótipo, respectivamente. Para o trabalho aqui apresentado os valores de limiar utilizados para os erros, abaixo dos quais considera-se que houve casamento, são 10%, 0, 6 e 25% respectivamente. O maior limiar para o erro do perímetro dos furos é justificado pelo pequeno perímetro (às vezes, menor do que que 10 pixels) destes nos objetos estudados, mas poderá ser diminuído se, no conjunto dos protótipos modelados, os perímetros dos furos forem da ordem de meia centena ou mais de pixels.




Figura 4.1: Hierarquia do Classificador.

No nível 1, o classificador opera pela busca do menor valor de erro  $E_{p_t}$ , para classificar modelos de objetos cujos protótipos possuem muita semelhança. Isto significa dizer que, se um modelo apresenta valor do erro  $E_{p_t}$  abaixo do limiar para mais de um protótipo, será reconhecido aquele protótipo com menor  $E_{p_t}$ . Isto porque os atributos globais (como por exemplo, o perímetro total) são mais invariantes às translações e às rotações [4] e, portanto, mais confiáveis. No caso do modelo possuir um ou mais furos esta decisão é tomada usando-se o perímetro destes furo(s) (nível 2 do classificador).

Com este classificador, embora simples, foi reconhecido e localizado todos os objetos isolados nas imagens que foram apresentadas ao sistema.

#### 4 - LOCALIZAÇÃO DOS MODELOS DE OBJETOS ISOLADOS

Um dos problemas de visão artificial que ocupa uma posição de destaque é a localização dos objetos em uma determinada cena. Nesta seção será descrito a forma usada aqui para localizar os modelos dos objetos, sendo esta localização dada pelas coordenadas do centróide.

Ao finalizar a segmentação e a modelagem do objeto, dispõe-se dos vértices do modelo poligonal, ou seja, as coordenadas de todos os vértices.

As coordenadas do centróide do modelo do objeto dado são obtidas pelo cálculo do momento de primeira ordem nas abscissas e das ordenadas dos vértices do modelo de acordo com Mascarenhas e



Velasco [18]. Assim, considerando  $x_j$  e  $y_j$  as coordenadas do vértice  $V_j$ ,  $j=1, \dots, N_{VC}$ , as coordenadas  $x_c$  e  $y_c$  do centróide são dadas por:

$$x_c = \frac{\sum_{j=1}^{N_{VC}} x_j}{N_{VC}} \quad (4.4a)$$

$$y_c = \frac{\sum_{j=1}^{N_{VC}} y_j}{N_{VC}} \quad (4.4b)$$

Obtém-se, portanto, a posição do modelo dada pelas coordenadas do centróide.

O procedimento de localização descrito nesta seção apresentou resultados satisfatório, permitindo a localização do centróide de todos os objetos do conjunto estudado.

## 5 - LOCALIZAÇÃO E RECONHECIMENTO DOS MODELOS DE OBJETOS PARCIALMENTE OCLUSOS

O problema da identificação e localização dos modelos em cenas nas quais os objetos estão em contato ou sobrepostos é, em geral, de difícil solução e é considerado de grande importância para qualquer sistema de visão dedicado à automação industrial, por permitir maior flexibilidade conforme descrito por Turney, Mudge e Volz [8]. A dificuldade na solução desse problema se caracteriza pela perda de informação das partes em oclusão dos objetos modela-

dos e que às vezes são de fundamental importância para o reconhecimento dos modelos e para as suas localizações. Os diversos sistemas desenvolvidos resolveram o problema de várias maneiras e os sistemas mais atuais chegam a obter resultados considerados satisfatórios, embora, produzidos por métodos muito complexos. Este trabalho apresenta uma nova forma de resolver esta questão, que é muito simples em relação aos procedimentos usados até agora. Este método está intimamente agregado ao modelamento poligonal e ao conjunto de atributos usados, atributos estes que ainda não foram utilizados por nenhum outro sistema que se conhece até o momento.

O reconhecimento dos modelos de objetos parcialmente oclusos é baseado no vetor de atributos casados gerado durante o processo de modelagem conforme descrito na seção 3. Com os dados contidos neste vetor é possível identificar os casamentos ocorridos entre atributos do contorno modelado e dos protótipos na base de dados.

Nesta seção serão investigadas basicamente duas formas para resolver o problema do reconhecimento dos modelos de objetos que se encontram parcialmente oclusos na cena. A primeira é considerando a geração do vetor de atributos casados como sendo feita por uma função discriminante lógica, pela qual todos os comprimentos dos lados e ângulos de um dado atributo devem ter seus erros abaixo dos respectivos limiares simultaneamente para que ocorra casamento. Todos os erros são considerados com mesmo peso nesta decisão. Na segunda forma é usada uma função discriminante analítica, para gerar o vetor de atributos casados, pela qual os erros correspondentes aos comprimentos dos lados e aos ângulos internos são ponderados com pesos distintos.

A função discriminante analítica ponderada usada na geração do

vetor de atributos casados é dada por:

$$f = p_1 \cdot \frac{(El_{i-1} + El_i + El_{i+1})}{\Delta L_{max}} + p_2 \cdot \frac{(Ea_{i-1} + Ea_i)}{A_{max}} \quad (4.5)$$

$$f = p_1 \cdot \frac{(El_{i-1} + El_i)}{\Delta L_{max}} + p_2 \cdot \frac{Ea_{i-1}}{A_{max}} \quad (4.6)$$

onde  $p_1$  e  $p_2$  são os pesos. A equação (4.5) define a função discriminante para os atributos compostos por três lados consecutivos e os ângulos internos entre eles e a equação (4.6) para os atributos formados apenas por dois lados e o ângulo entre eles. No trabalho aqui apresentado foi considerado 0.6 e 0.4 para os pesos e para  $\Delta L_{max}$  e  $A_{max}$  0.3 e 30 graus respectivamente. Os dois últimos valores e esta função são uma adaptação da função usada por Ayache e Faugeras [10]. Ela tem a propriedade de medir a precisão do casamento dos atributos do contorno fechado da cena com os modelos dos protótipos da base de dados, através de uma ponderação dos erros dos lados e dos erros dos ângulos. Os atributos do modelo somente se casam com atributos dos protótipos para valores das funções menores do que 1. Quanto menor for o seu valor mais preciso é o casamento. O peso menor para  $p_2$  é explicado pela maior variação dos ângulos internos em relação aos lados quando ocorrem pequenas variações no modelo poligonal com pequenos lados.

Usando uma das funções discriminantes, pode-se iniciar o processo de localização dos objetos e de sua classificação.

As duas maneiras usadas para a geração do vetor de atributos casados, descritas antes, usarão o mesmo método para localizar os modelos.

A localização é feita tomando o (j-1)-ésimo lado do contorno

fechado como referência e o  $j$ -ésimo vértice como origem de um novo sistema de coordenadas para a transformação responsável pela localização e reconhecimento do modelo do objeto. A transformação tem início fazendo coincidir o lado  $c_{j-1}$  do contorno fechado modelado com o lado  $p_{i-1}$  para cada um dos protótipos, que se encontram no vetor de atributos casados. Esta sobreposição dos lados ocorre de tal forma que o vértice  $V_j$  coincida exatamente com o vértice  $V_i$  do dado protótipo. A figura 4.2 mostra como é feita a justaposição dos lados do protótipo e da cena. É importante salientar que o índice do lado de cada protótipo é, em geral, diferente para cada um deles. A origem do novo sistema de coordenadas será o vértice  $V_j$ .




Figura 4.2: Posição Inicial dos Lados antes da Transformação.

Onde os valores de  $\tau$  e de  $\Delta l$  são dados por:

$$\tau = \alpha_{c_{j-1}} - \alpha_{p_{i-1}} \quad (4.7)$$

$$\Delta l = L_{p_1} - L_{c_j} \quad (4.8)$$

Para  $\tau > 0$  a rotação ocorre no sentido horário e para  $\tau < 0$  no sentido anti-horário.

Considerando o vértice  $V_j$  como origem do sistema  $x'y'$ , as novas coordenadas do vértice  $V'_{j+1}$  são  $x_{j+1} - x_j$  e  $y_{j+1} - y_j$ . A transformação ocorrerá com o vértice  $V'_{j+1}$  para que este se posicione em  $V''_{j+1}$ . A transformação consiste de uma translação (T1) seguida de uma rotação (T2) em torno da origem como descrito abaixo:

$$T1(\text{translação}) \begin{cases} x' = x_{j+1} + \Delta l \cdot \cos(\alpha_{c_j}) \\ y' = y_{j+1} + \Delta l \cdot \text{sen}(\alpha_{c_j}) \end{cases}$$

onde  $x'$  e  $y'$  são as coordenadas do vértice intermediário VI. Em seguida  $x'$  e  $y'$  serão submetidos a rotação,

$$T2(\text{rotação}) \begin{cases} x''_{j+1} = x' \cdot \cos(\tau) - y' \cdot \text{sen}(\tau) \\ y''_{j+1} = x' \cdot \text{sen}(\tau) + y' \cdot \cos(\tau) \end{cases}$$

onde  $x''_{j+1}$  e  $y''_{j+1}$  são as coordenadas do vértice  $V''_{j+1}$ .

A finalidade das transformações T1 e T2 é fazer com que os vértices  $V_j$  e  $V_{j+1}$  do modelo do contorno fechado, coincidam com os seus correspondentes vértices no modelo do protótipo, através da sobreposição dos lados  $c_{j-1}$  e  $c_j$  do contorno com seus correspondentes  $p_{i-1}$  e  $p_i$ .

De posse do vértice  $V''_{j+1}$ , dos ângulos  $\beta_{j-1}$  e  $\beta_j$  (cap3, seção 5, figura 3.5) e do ângulo  $\tau$ , podem ser criadas as equações das retas: uma passando pela origem, coincidindo com o segmento  $p_{j-1}$  e outra passando pelo vértice  $V''_{j+1}$ , sobreposta ao segmento  $p_j$ . É importante dizer que a inclinação da reta que passa pelo vértice

$V_{j+1}'$  depende também do ângulo  $\tau$ . A interseção dessas duas retas fornecem as coordenadas do centróide do objeto  $C(x_c, y_c)$ , no sistema de coordenadas  $x'y'$ .

Para encontrar o centróide no sistema de coordenadas da cena é necessário que aquele sofra as transformações inversas  $T_1^{-1}$  e  $T_2^{-2}$ , seguida da translação do sistema de coordenadas para o sistema  $xy$  da cena, ou seja, adicionar as coordenadas do vértice  $V_j$  (referência) na cena às respectivas coordenadas do centróide no sistema  $x'y'$ .

Com as coordenadas do centróide no plano  $x'y'$  são calculada as distâncias (em pixels) deste aos vértices  $V_j$  e  $V_{j+1}$ , representadas por  $\rho_{j-1}'$  e  $\rho_j'$  respectivamente. Os erros absolutos  $\epsilon_1 = |\rho_{j-1} - \rho_{j-1}'|$  e  $\epsilon_2 = |\rho_j - \rho_j'|$  são calculados e a soma deles não deve ultrapassar um determinado limiar ( $L_\epsilon$ ), ou seja,  $S_\epsilon = \epsilon_1 + \epsilon_2 < L_\epsilon$  que será controlado.

Podem-se encontrar diversas situações causadas pela geração do vetor de atributos, tais como, encontrar um determinado atributo da cena em mais de um objeto ou mesmo mais de uma vez no próprio protótipo. Estas situações são decorrentes das propriedades estatísticas dos atributos, conforme afirma Frias e Guigoitia [1]. Para tanto, deve-se estabelecer um critério para classificar os objetos. Este critério tem como base a soma dos erros descritos antes ( $S_\epsilon$ ). Assim, o vetor de atributos casados é alterado de tal forma que, para cada atributo casado, verifica-se o menor valor de  $S_\epsilon$  para todos os protótipos que possuírem aquele atributo. Se o casamento ocorrer apenas em um único protótipo basta somente que  $S_\epsilon$  seja inferior a  $L_\epsilon$ . No final, o vetor de atributos casados contém apenas os atributos casados com os atributos dos protótipos

com maior chance de serem reconhecidos. Vale salientar que um certo protótipo pode ter mais de um atributo selecionado.

Neste momento o processo de classificação já foi concluído, faltando apenas a localização dos modelos dos protótipos reconhecidos. A localização é feita pelo exame do vetor de atributos casados na sua forma final, onde já estão disponíveis as coordenadas dos centróides relativas a cada um dos atributos casados. Considerando apenas o protótipo já identificado, seja  $N_0$  o número de casamentos de atributos entre este protótipo e o modelo. Para  $N_0=1$ , as coordenadas deste casamento serão identificadas com as coordenadas do protótipo. Para  $N_0>1$ , indicando a existência de mais de um casamento, examina-se o valor de  $S_e$ . Se apenas um dos casamentos produzir  $S_e=0$ , o centróide determinado por este casamento será o centróide do modelo. Se ocorrerem mais de um casamento com  $S_e=0$ , as coordenadas do centróide serão dadas pela média aritmética das respectivas coordenadas. Se nenhum casamento produzir  $S_e=0$ , as coordenadas do centróide serão dadas pela média ponderada das respectivas coordenadas cujos pesos são dados por  $(L_e - S_e)/L_e$ .

No próximo capítulo são apresentados e analisados os resultados para as diversas cenas e também são comparadas as duas funções discriminantes definidas neste capítulo.

## CAPITULO 5

### RESULTADOS EXPERIMENTAIS

#### 1 - INTRODUÇÃO

Em qualquer trabalho, a análise dos resultados obtidos, constitui uma das partes mais importantes, pois, é baseado nestes que se pode avaliar adequadamente o trabalho, com relação a outros desenvolvidos para a mesma finalidade.

Este capítulo trata de fazer uma análise de todos os resultados obtidos com as cenas usadas na fase de reconhecimento do sistema.

As cenas serão divididas em três grupos: o primeiro reúne as cenas nas quais os objetos aparecem isolados, o segundo aquelas que contém objetos isolados e sobrepostos e o terceiro grupo aquelas cenas que possuem apenas objetos oclusos.

A análise dos resultados obtidos será dividida em partes correspondentes a cada uma das estratégias adotadas.

No início é feita a análise dos resultados obtidos com os objetos isolados. Em seguida serão estudados os resultados do reconhecimento dos modelos em cenas nas quais eles aparecem sobrepostos. Finalmente algumas conclusões são tiradas a respeito de cada uma das estratégias usadas.



## 2 - RESULTADOS OBTIDOS COM OBJETOS ISOLADOS

Considere a cena mostrada na figura 5.1, pertencente ao primeiro grupo. Como todos os objetos se encontram isolados a estratégia usada na classificação é aquela descrita na seção 3 do cap. 4.




Figura 5.1: Cena 1 em 4 Tons de Cinza.

Os resultados estão sumarizados na tabela 1.1. A coluna *objeto* da tabela corresponde a ordem usada durante a modelagem da cena, isto é, o objeto número 1 é o primeiro a ser classificado, conforme seção 2 do cap. 4, a segunda coluna indica a ordem do protótipo, reconhecido como sendo correspondente aquele objeto, decidida durante a fase de formação dos protótipos para a base de dados.

Tabela 1.1: Resultados Obtidos da Cena 1.

Objeto	Protótipo	$E_{n_f}$	$E_{n_v}$	$E_{P_t} (%)$	$E_{P_f} (%)$
1	1	0	1	$\cong 1$	$\cong 1$
2	9	0	1	$\cong 9$	$\cong 18$
3	7	0	1	$\cong 7$	*
4	5	0	2	$\cong 1$	*
5	10	0	1	$\cong 9$	$\cong 17$
6	6	0	3	$\cong 9$	*
7	3	0	4	$\cong 5$	*

\* objeto sem furo

As demais colunas indicam, para cada objeto, os valores dos erros definidos na seção 3, cap. 4.

Considere agora a cena 2 da figura 5.2, que pertence ao segundo grupo, ou seja, contem objetos isolados e sobrepostos. Considerando apenas os contornos fechados correspondentes a objetos isolados, obteve-se a tabela 1.2.




Figura 5.2: Cena 2 em 4 Tons de Cinza.

Tabela 1.2: Resultados Obtidos da Cena 2.

Objeto	Protótipo	$E_{n_f}$	$E_{n_v}$	$E_{p_t}(\%)$	$E_{p_f}(\%)$
2	10	0	1	$\cong$	$\cong 4$
3	3	0	4	$\cong$	*

\* Objeto sem furo

A figura 5.3 também mostra uma cena pertencente ao segundo grupo. Similarmente, obteve-se a tabela 1.3.




Figura 5.3: Cena 3 em 4 Tons de Cinza.

Tabela 1.3: Resultados Obtidos da Cena 3.

Objeto	Protótipo	$E_{n_f}$	$E_{n_v}$	$E_{p_t}(\%)$	$E_{p_f}(\%)$
2	5	0	2	$\cong$	*
3	2	0	2	$\cong$	*

\* Objeto sem furo

Para as cenas nas quais os objetos se encontram isolados, obteve-se 100% de sucesso no procedimento de classificação, indicando-

do que a estratégia usada no reconhecimento de modelos de objetos isolados pode ser considerada como acertada.

### 3 - RESULTADOS OBTIDOS COM OBJETOS PARCIALMENTE OCLUSOS

A tarefa de analisar resultados nas cenas contendo objetos oclusos é difícil pela sua própria natureza, principalmente, se não existe outro sistema para ser usado como referência. Para se ter uma comparação válida, seria necessário submeter as mesmas imagens (nas mesmas condições de iluminação, ruídos, etc.), a diversos sistemas e comparar os resultados da classificação dos mesmos.

Um parâmetro que poderia ser utilizado para uma avaliação objetiva do desempenho do sistema proposto seria o tempo gasto no reconhecimento e localização dos modelos dos objetos nas cenas consideradas. Porém, dois fatores impedem de utilizar o parâmetro tempo para esta análise que são:

- a) o sistema desenvolvido realiza simultaneamente diversas etapas indispensáveis a qualquer sistema e que nos demais sistemas conhecidos são realizadas seqüencialmente;
- b) os sistemas conhecidos não fornecem o tempo envolvido em cada uma dessas etapas, apenas o tempo total de análise das cenas.

Portanto, na análise aqui apresentada, o desempenho do sistema foi avaliado apenas com relação a sua capacidade de reconhecer ou não os objetos parcialmente oclusos presentes na cena.

A análise dos resultados será dividida em duas partes, uma para cada um dos atributos usados: três lados e dois ângulos ou dois lados e um ângulo. Cada uma das partes apresentará os resul-

tados obtidos com cada um dos dois tipos de função discriminante usada, como descrito no capítulo 4.

As tabelas que se seguem sumarizam o comportamento do sistema para os limiares que produziram variações de resultados na classificação de cada cena.

A primeira coluna das tabelas (protótipos), corresponde aos números dos protótipos armazenados na base de dados, onde aqueles que se encontram presentes no contorno fechado sendo analisado, estão marcados por um asterisco. A coluna (N) indica o número de ocorrências de casamentos entre os atributos extraídos do modelo do contorno fechado e os atributos dos protótipos. Finalmente, a coluna (C), indica o reconhecimento ou não dos protótipos para os quais N não é nulo, baseado no erro de localização dos centróides, descrito na seção 5 do capítulo 4.

Nas tabelas, encontram-se divididos os resultados obtidos pelo uso das funções discriminantes lógica e analítica.

Cada tabela está associada a um conjunto de limiares correspondendo a cada um dos erros usados pelas funções discriminantes e pelo limiar  $L_e$  utilizado na localização, descrito no capítulo 4. Os valores de  $L_c$  e  $L_a$  correspondem aos limiares de tolerância permitidos para os erros no comprimento dos lados e nos ângulos dos atributos, respectivamente.

É importante frisar que para resultar numa classificação correta, não necessariamente consiste no casamento de muitos atributos de um dos protótipos com os atributos do modelo e sim no quanto esses atributos são discriminantes em relação aos demais protótipos.

### 3.1 - Atributo Composto por Três Lados e Dois Ângulos

Os resultados produzidos pelas funções discriminantes lógica e analítica são apresentados nas tabelas para dois valores de  $L_e$ , 10 e 12 pixels. Para a função lógica são considerados valores para  $L_c$  0.3 e 0.2 e para  $L_a$  de 30 e 20 graus.

Considere o primeiro contorno fechado da figura 5.2, pertencendo ao segundo grupo, cujos resultados estão sumarizados nas tabelas 2.1 e 2.2.

Tabela 2.1: Resultados Obtidos da Cena 2 para  $L_c=0.3$  e  $L_a=30^\circ$ .

Protótipo	$L_e = 10$ pixels				$L_e = 12$ pixels			
	$L_c = 0.3$ $L_a = 30^\circ$				$L_c = 0.3$ $L_a = 30^\circ$			
	Lógica		Analítica		Lógica		Analítica	
	N	C	N	C	N	C	N	C
1*								
2	1	Não			2	Sim		
3								
4								
5*	2	Sim			2	Sim		
6								
7*								
8*	3	Sim	1	Sim	8	Sim	1	Sim
9	2	Sim			2	Sim		
10	3	Sim	1	Não	3	Sim	1	Não
11*	1	Não			1	Sim		

Observando os dados da tabela 2.1, nota-se que a função discriminante lógica gera um maior número de casamentos errados e conseqüentemente a classificação dos correspondentes protótipos. A função discriminante analítica é mais consistente na classificação, pois, apenas o protótipo de número 10 teve um atributo casado e mesmo assim não foi classificado.

Tabela 2.2: Resultados Obtidos da Cena 2 para  $L_c=0.2$  e  $L_a=20^\circ$ .

Protótipo	$L_c = 10$ pixels				$L_c = 12$ pixels			
	$L_c = 0.2$ $L_a = 20^\circ$				$L_c = 0.2$ $L_a = 20^\circ$			
	Lógica		Analítica		Lógica		Analítica	
	N	C	N	C	N	C	N	C
1*								
2								
3								
4								
5*								
6								
7*								
8*			1	Sim			1	Sim
9								
10	1	Não	1	Não	1	Não	1	Não
11*								

Os dados da tabela 2.2 indicam que a função discriminante lógica não mais consegue classificar nenhum protótipo porque foi muito reduzido o número de atributos casados em relação a tabela

2.1.

Para a figura 5.3 que também pertence ao segundo grupo, são apresentados os resultados nas tabelas 2.3 e 2.4.

Tabela 2.3: Resultados Obtidos da Cena 3 para  $L_c=0.3$  e  $L_a=30^\circ$ .

Protótipo	$L_\epsilon = 10$ pixels				$L_\epsilon = 12$ pixels			
	$L_c = 0.3$ $L_a = 30^\circ$				$L_c = 0.3$ $L_a = 30^\circ$			
	Lógica		Analítica		Lógica		Analítica	
	N	C	N	C	N	C	N	C
1*	2	Sim			2	Sim		
2	3	Sim	1	Sim	3	Sim	1	Sim
3	2	Sim	1	Sim	2	Sim	1	Sim
4								
5								
6								
7								
8*	2	Sim	1	Não	2	Sim	1	Sim
9*	2	Sim	1	Sim	2	Sim	1	Sim
10*	9	Sim	4	Sim	9	Sim	4	Sim
11*								

Na tabela 2.3, a função discriminante lógica apresenta-se melhor do que a função discriminante analítica no que se refere à classificação dos protótipos presentes no contorno fechado.



Tabela 2.4: Resultados Obtidos da Cena 3 para  $L_c=0.2$  e  $L_a=20^\circ$ .

Protótipo	$L_\epsilon = 10$ pixels				$L_\epsilon = 12$ pixels			
	$L_c = 0.2$ $L_a = 20^\circ$				$L_c = 0.2$ $L_a = 20^\circ$			
	Lógica		Analítica		Lógica		Analítica	
	N	C	N	C	N	C	N	C
1*								
2			1	Sim			1	Sim
3	1	Sim	1	Sim	1	Sim	1	Sim
4								
5								
6								
7								
8*			1	Não			1	Sim
9*	1	Não	1	Sim	1	Não	1	Sim
10*	2	Sim	4	Sim	2	Sim	4	Sim
11*								

Os resultados da tabela 2.4 indicam que a função discriminante lógica diminuiu significativamente o número de atributos casados, em relação a tabela 2.3, e conseguiu apresentar uma classificação abaixo da função discriminante analítica.

Considerando o terceiro grupo, representado pela figura 5.4, onde aparece apenas um contorno fechado e todos os objetos se encontram em oclusão parcial, obtêm-se as tabelas 2.5 e 2.6.




Figura 5.4: Cena 4 em 4 Tons de Cinza.

Tabela 2.5: Resultados Obtidos da Cena 4 para  $L_c=0.3$  e  $L_a=30^\circ$ .

Protótipo	$L_e = 10$ pixels				$L_e = 12$ pixels			
	$L_c = 0.3$ $L_a = 30^\circ$				$L_c = 0.3$ $L_a = 30^\circ$			
	Lógica		Analítica		Lógica		Analítica	
	N	C	N	C	N	C	N	C
1								
2*	3	Sim			3	Sim		
3*								
4								
5*								
6								
7								
8*	3	Sim	2	Sim	3	Sim	2	Sim
9								
10	3	Sim	1	Não	3	Sim	1	Não
11								

As duas funções apresentam comportamentos semelhantes, pois, a função discriminante lógica acerta na classificação do protótipo 2 e erra no protótipo 10, enquanto que a função discriminante analítica não classifica o protótipo 2 e desclassifica o 10. Uma comparação das tabelas 2.5 e 2.6 mostra a consistência na classificação dos atributos, realizada pela função discriminante analítica.

Tabela 2.6: Resultados Obtidos da Cena 4 para  $L_c=0.2$  e  $L_a=20^\circ$ .

Protótipo	$L_s = 10$ pixels				$L_s = 12$ pixels			
	$L_c = 0.2$ $L_a = 20^\circ$				$L_c = 0.2$ $L_a = 20^\circ$			
	Lógica		Analítica		Lógica		Analítica	
	N	C	N	C	N	C	N	C
1								
2*								
3*								
4								
5*								
6								
7								
8*	2	Sim	2	Sim	2	Sim	2	Sim
9								
10			1	Não			1	Não
11								

Os resultados encontrados para o atributo utilizado indicam que a função discriminante analítica classifica mais corretamente

os protótipos pela eficiência na separação dos atributos dos diversos modelos.

### 3.2 - Atributo Composto de Dois Lados e um Ângulo

Esse tipo de atributo permite aumentar as dimensões do vetor de atributos casados que, conseqüentemente, contribui para dificultar a classificação dos protótipos, indicando que esse atributo é menos discriminante do que o atributo considerado antes. Para melhor comparação entre as duas funções usadas na geração do vetor de atributos casados, os valores assumidos pelos parâmetros  $\Delta_{max}$  e  $A_{max}$  são 0.2 e 20 graus, respectivamente.

Os resultados para a figura 5.2, pertencendo ao segundo grupo são mostrados nas tabelas 3.1 e 3.2.

Tabela 3.1: Resultados Obtidos da Cena 2 para  $L_c=0.3$  e  $L_a=30^\circ$ .

Protótipo	$L_e = 10$ pixels				$L_e = 12$ pixels			
	$L_c = 0.3$ $L_a = 30^\circ$				$L_c = 0.3$ $L_a = 30^\circ$			
	Lógica		Analítica		Lógica		Analítica	
	N	C	N	C	N	C	N	C
1*	8	Sim	4	Sim	8	Sim	4	Sim
2	9	Sim	5	Sim	9	Sim	5	Sim
3	7	Sim	3	Sim	7	Sim	3	Sim
4								
5*	5	Sim	1	Sim	5	Sim	1	Sim
6								
7*	3	Sim	1	Sim	3	Sim	1	Sim
8*	12	Sim	3	Sim	12	Sim	3	Sim
9	8	Sim	4	Sim	8	Sim	4	Sim
10	9	Sim	8	Sim	9	Sim	8	Sim
11*	8	Sim	4	Sim	8	Não	4	Sim

Nas tabelas 3.1 e 3.2, observa-se que as duas funções discriminantes se comportam de forma igual, classificando vários protótipos que não se encontram no contorno fechado que está sendo analisado. Isto se deve a maior dimensão do vetor de atributos casados comentado no início desta subseção. No que se refere ao número de atributos casados, a função discriminante analítica, é muito menor para a tabela 3.1 e em alguns casos maior para a tabela 3.2.

Tabela 3.2: Resultados Obtidos da Cena 2 para  $L_c=0.2$  e  $L_a=20^\circ$ .

Protótipo	$L_c = 10$ pixels				$L_c = 12$ pixels			
	$L_c = 0.2$ $L_a = 20^\circ$				$L_c = 0.2$ $L_a = 20^\circ$			
	Lógica		Analítica		Lógica		Analítica	
	N	C	N	C	N	C	N	C
1*	4	Sim	4	Sim	4	Sim	4	Sim
2	4	Sim	5	Sim	4	Sim	5	Sim
3	3	Sim	3	Sim	3	Sim	3	Sim
4								
5*	1	Sim	1	Sim	1	Sim	1	Sim
6								
7*	1	Não	1	Não	1	Não	1	Não
8*	2	Sim	3	Sim	2	Sim	3	Sim
9	2	Sim	4	Sim	2	Sim	4	Sim
10	4	Sim	8	Sim	4	Sim	8	Sim
11*	4	Sim	4	Sim	4	Sim	4	Sim

Para a figura 5.3 também pertencendo ao segundo grupo, obtêm-se os resultados que são apresentados nas tabelas 3.3 e 3.4.

As tabelas 3.3 e 3.4 continuam apresentando o mesmo comportamento que as tabelas 3.1 e 3.2. Em geral, a função discriminante analítica apresenta um menor número de atributos casados na tabela 3.3 e na tabela 3.4 o resultado se inverte, sendo a função lógica a que apresenta um maior número de casamentos.

Tabela 3.3: Resultados Obtidos da Cena 3 para  $L_c=0.3$  e  $L_a=30^\circ$ .

Protótipo	$L_e = 10$ pixels				$L_e = 12$ pixels			
	$L_c = 0.3$ $L_a = 30^\circ$				$L_c = 0.3$ $L_a = 30^\circ$			
	Lógica		Analítica		Lógica		Analítica	
	N	C	N	C	N	C	N	C
1*	14	Sim	8	Sim	14	Sim	8	Sim
2	13	Sim	6	Sim	13	Sim	6	Sim
3	5	Sim	2	Sim	5	Sim	2	Sim
4								
5								
6								
7								
8*	20	Sim	10	Sim	20	Sim	10	Sim
9*	12	Sim	7	Sim	12	Sim	7	Sim
10*	21	Sim	11	Sim	21	Sim	11	Sim
11*	12	Sim	5	Sim	12	Sim	5	Sim

Tabela 3.4: Resultados Obtidos da Cena 3 para  $L_c=0.2$  e  $L_a=20^\circ$ .

Protótipo	$L_c = 10$ pixels				$L_c = 12$ pixels			
	$L_c = 0.2$ $L_a = 20^\circ$				$L_c = 0.2$ $L_a = 20^\circ$			
	Lógica		Analítica		Lógica		Analítica	
	N	C	N	C	N	C	N	C
1*	7	Sim	8	Sim	7	Sim	8	Sim
2	5	Sim	6	Sim	5	Sim	6	Sim
3	2	Sim	2	Sim	2	Sim	2	Sim
4								
5								
6								
7								
8*	6	Sim	10	Sim	6	Sim	10	Sim
9*	9	Sim	7	Sim	9	Sim	7	Sim
10*	9	Sim	11	Sim	9	Sim	11	Sim
11*	3	Sim	5	Sim	3	Sim	5	Sim

Finalmente, para a figura 5.4 contida no terceiro grupo, os resultados se encontram resumidos nas tabelas, 3.5 e 3.6, onde a função discriminante analítica apresenta, em geral, um menor número de atributos casados.



Tabela 3.5: Resultados Obtidos da Cena 4 para  $L_c=0.3$  e  $L_a=30^\circ$ .

Protótipo	$L_e = 10$ pixels				$L_e = 12$ pixels			
	$L_c = 0.3$ $L_a = 30^\circ$				$L_c = 0.3$ $L_a = 30^\circ$			
	Lógica		Analítica		Lógica		Analítica	
	N	C	N	C	N	C	N	C
1	2	Sim	1	Sim	2	Sim	1	Sim
2*	5	Sim	3	Sim	5	Sim	3	Sim
3*	4	Sim	2	Sim	4	Sim	2	Sim
4								
5*	1	Não			1	Sim		
6								
7	1	Sim			1	Sim		
8*	10	Sim	6	Sim	10	Sim	6	Sim
9	6	Sim	1	Não	6	Sim	1	Não
10	7	Sim	5	Não	7	Sim	5	Sim
11	4	Sim	3	Sim	4	Sim	3	Sim

Na tabela 3.5, as duas funções usadas apresentam, praticamente, o mesmo resultado na classificação do contorno em análise e este comportamento se repete para a tabela 3.6.

Tabela 3.6: Resultados Obtidos da Cena 4 para  $L_c=0.2$  e  $L_a=20^\circ$ .

Protótipo	$L_\epsilon = 10$ pixels				$L_\epsilon = 12$ pixels			
	$L_c = 0.2$ $L_a = 20^\circ$				$L_c = 0.2$ $L_a = 20^\circ$			
	Lógica		Analítica		Lógica		Analítica	
	N	C	N	C	N	C	N	C
1	1	Sim	1	Sim	1	Sim	1	Sim
2*	1	Sim	3	Sim	1	Sim	3	Sim
3*	1	Sim	2	Sim	1	Sim	2	Sim
4								
5*								
6								
7								
8*	6	Sim	6	Sim	6	Sim	6	Sim
9			1	Não			1	Não
10	1	Sim	5	Sim	1	Sim	5	Sim
11	2	Sim	3	Sim	2	Sim	3	Sim

#### 4 - CONCLUSÃO

Pelos resultados antes apresentados e considerando o grau de oclusão dos objetos nas cenas, mostradas na seção anterior, as seguintes conclusões podem ser tiradas a respeito dos atributos usados e das funções utilizadas para gerar o vetor de atributos casados:

o dos atributos usados, o que apresentou melhores resultados foi aquele composto de três lados do polígono e seus dois ângulos

internos; e

o a função que conseguiu classificar com maior eficiência os atributos foi a função discriminante analítica associada ao atributo mencionado antes.

O método utilizado para a localização dos modelos nas cenas dos grupos 2 e 3 pode ser considerado como satisfatório, embora não se tenha uma medida objetiva para se chegar a uma conclusão definitiva. Para reduzir o grau de subjetividade desta conclusão foi feito um mapeamento de cada uma das cenas desses grupos e um centróide aproximado foi encontrado para se chegar a esta conclusão.

Uma conclusão a respeito do sistema será assunto do próximo capítulo e que algumas podem ser úteis nos trabalhos futuros.

## CAPITULO 6

### CONCLUSÃO

Esta dissertação trata do problema de reconhecimento automático de objetos bidimensionais, através do uso de modelos poligonais.

A solução do problema, apresentado no primeiro capítulo, envolve dois aspectos básicos. O primeiro deles é a modelagem dos objetos em 2D e o segundo é o reconhecimento dos protótipos através de um determinado método. Estes dois aspectos, normalmente, estão intimamente ligados, como está demonstrado ao longo deste trabalho. A modelagem dos objetos foi detalhada no capítulo 3, no qual é proposto um novo algoritmo para modelagem de objetos em 2D. Os resultados produzidos por este algoritmo foram examinados e algumas conclusões sobre suas propriedades foram tiradas, dentre as quais se destacam a integração de diversas etapas necessárias à modelagem e que em geral são realizadas independentemente. Também pode ser considerado muito simples em relação aos outros algoritmos citados no mesmo capítulo e portanto computacionalmente eficiente.

Infelizmente, não houve condições de realizar uma efetiva comparação de desempenho entre o algoritmo proposto e os demais exis-

tentes, o que esperamos seja realizado no futuro.

O método proposto para o reconhecimento dos protótipos deve ser encarado sob dois ângulos, correspondentes às duas estratégias utilizadas. A primeira delas é usada para reconhecer os protótipos de objetos isolados e a segunda é usada para reconhecer objetos que se tocam ou se encontram sobrepostos na imagem, de modo que os atributos globais não são suficientemente discriminantes nestas condições. A primeira estratégia apresentou um excelente resultado, embora as formas dos objetos modelados tenham sido as mais diversas, desde formas geométricas poligonais propriamente ditas, como triângulos e retângulos, até formas circulares. Esta diversidade normalmente não se encontra nos sistemas para o mesmo fim citados neste trabalho.

A segunda estratégia, a mais crítica das duas, também apresentou resultados satisfatórios, mostrados no capítulo 5, mesmo para cenas onde o grau de oclusão dos objetos é bastante alto como na figura 5.4 do capítulo 5. O desempenho desta estratégia depende de vários fatores, como a função discriminante utilizada e a forma de casar os atributos dos protótipos com os atributos da cena, bem como dos próprios atributos utilizados. Os resultados obtidos que levaram a estas conclusões são apresentados na seção 3 do capítulo 5.

No geral foi possível concluir que o método desenvolvido possui maior flexibilidade que os métodos que utilizam apenas atributos globais, pois, possibilita reconhecer objetos parcialmente oclusos, bem como representa uma solução mais simples e eficiente para o problema abordado que os outros métodos também citados no capítulo 2.

Podem ser destacadas três contribuições importantes para a área trazidas por este trabalho que são:

- 1 - O algoritmo desenvolvido para modelagem dos objetos em 2D;
- 2 - A definição de novos tipos de atributos usados para casar os protótipos dos objetos com os modelos das cenas; e
- 3 - As estratégias adotadas para resolver o problema do reconhecimento e da localização dos objetos nas cenas.

Este trabalho pode servir como base para outros trabalhos futuros, os quais poderão abordar:

- a) Uma comparação de desempenho entre o algoritmo de modelagem proposto no capítulo 3 e os demais algoritmos mais usados para modelagem poligonal;
- b) Investigação do comportamento do algoritmo proposto no capítulo 3 no que diz respeito a sua robustez às translações e às rotações, bem como à disposição espacial dos objetos, a serem modelados, na imagem, visando otimizar o mesmo;
- c) A criação de outras técnicas de casamento de atributos, partindo da que foi desenvolvida no capítulo 4;
- d) A determinação de limiares ótimos dos erros que são usados pelas funções discriminantes; e
- e) A investigação de outras funções discriminantes.

## BIBLIOGRAFIA

- [1] Frias, B. C. e Guigoitia, C. F. B. (1987). "Visión para Computadoras", Facultad de Ingeniería - Universidad de Buenos Aires.
- [2] Ayache, N. (1983). "Un Système de Vision Bidimensionnelle en Robotique Industrielle" Thèse de Docteur-Ingénieur, L'Université de Paris-Sud Centre D'Orsay.
- [3] Rosenfeld, A. (1988). "Computer Vision: Basic Principles", Proceedings IEEE, Vol. 76, n° 8, August.
- [4] Asano, T., Kenwood, G., Mochizuki, J. and Hata, S. (1986). "Color Image Recognition Using Chrominance Signals", Proc. 8th International Conference Pattern Recognition.
- [5] Mital, D. P., Leng, G. W. and Khwang, T. E. (1989). "Colour Vision for Industrial Applications", 10th International Conference TECON, Bombaim - India, November.
- [6] Chin, R. T. and Dyer, C. R. (1986). "Model-Based Recognition in Robot Vision", Computing Surveys, Vol. 18, n° 1, March.
- [7] Rillo, A.H.R.C. (1989). "Um Sistema de Visão Binária para Reconhecimento de Peças Isoladas e Parcialmente Oclusas", Laboratório de Sub-Sistemas Integráveis - DEE - EPUSP - São Paulo.
- [8] Turney, J. L., Mudge, T. N. and Volz, R. A. (1985). "Recognizing Partially Occluded Parts", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. PAMI-7,

July.

- [9] Bhanu, B. and Faugeras, O. D. (1984). "Shape Matching of Two-Dimensional Objects", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. PAMI-6, March.
- [10] Ayache, N. e Faugeras O.D. (1986). "A New Approach for the Recognition and Positioning of Two-Dimensional Objects", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. PAMI-8, January.
- [11] Fukuda, T., Ishizuka, M., Hasegawa, O., Asama, H., Nagamune, T. and Endo, I. (1990). "Vision System for Animal Cell Recognition in a Bio-Engineering Process", 10th International Conference TECON, Bombaim - India, November.
- [12] Bins, L. S. A., Velasco, F. R. D. e Monteiro, A. M. V. (1989). "Object Detection Using Structural Matching" pelo projeto ESTRA-SID informática no Instituto de Pesquisas Espaciais.
- [13] Ayache, N. J. and Faugeras, O. D. (1982). "Recognition of Partially Visible Planar Shapes" in Proc. 6th Conference Pattern Recognition, Setembro, Munich.
- [14] Barrow, H. G., and Tenenbaum, J. M. (1981). "Computational Vision", Proc. IEEE vol. 69, n.º 5, May.
- [15] Cortez, P. C. e Carvalho, J. M. (1992). "Algoritmo para Modelamento Poligonal de Objetos em 2D", aceito para o 9.º Congresso Brasileiro de Automática, Vitória, Setembro.
- [16] Gonzalez, R. C., (1987). "Digital Image Processing", 2<sup>a</sup> Edição, Addison-Wesley Publishing Company.
- [17] Junior, R.M.C. e Linhares, O.D. (1990). "Métodos Numéricos de Aproximação Poligonal: uma Análise Comparativa de 3 Métodos",



Jornada EPUSP/IEEE em Computação Visual.

- [18] Mascarenhas, N.D.A. e Velasco, F.R.D., (1989). "Processamento Digital de Imagens", 2<sup>a</sup> Edição, Ministério da Ciência e Tecnologia e Instituto Nacional de Pesquisas Espaciais.
- [19] Castleman, K. R. (1979). "Digital Image Processing", Prentice-Hall, New Jersey.
- [20] Pavlidis, T. e Horowitz, S. L. (1974). "Segmentation of Plane Curves", IEEE Transactions on Computers, Vol. C-23, n.º 8, August.