

UNIVERSIDADE FEDERAL DE SANTA CATARINA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**SEGMENTAÇÃO BINÍVEL DE IMAGENS
USANDO ENTROPIA DIFUSA BIDIMENSIONAL
E DISTRIBUIÇÃO DA ORIENTAÇÃO
DE GRADIENTE DOS PIXELS**

DISSERTAÇÃO SUBMETIDA À
UNIVERSIDADE FEDERAL DE SANTA CATARINA
PARA OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA ELÉTRICA

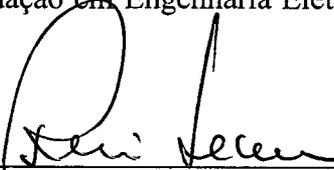
Luiz Hermano Costa de Oliveira

FLORIANÓPOLIS, MARÇO DE 1999.

SEGMENTAÇÃO BINÍVEL DE IMAGEM USANDO ENTROPIA DIFUSA BIDIMENSIONAL E DISTRIBUIÇÃO DA ORIENTAÇÃO DE GRADIENTE DOS PIXELS

Autor: LUIZ HERMANO COSTA DE OLIVEIRA

Esta dissertação foi julgada adequada para obtenção do título de Mestre em Engenharia Elétrica, Área de Concentração Circuitos e Instrumentação Eletrônica, e aprovada em sua forma final pelo Curso de Pós-graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina.

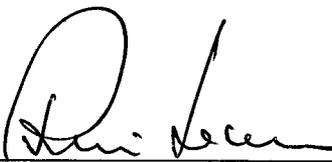


Prof. RUI SEARA, Dr.
ORIENTADOR

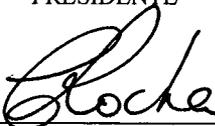


Prof. ILDEMAR CASSANA DECKER, D.Sc.
COORDENADOR DO CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

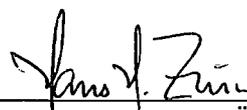
BANCA EXAMINADORA:



Prof. RUI SEARA, Dr.
PRESIDENTE



Prof. CARLOS AURÉLIO FARIA DA ROCHA, Dr.



Prof. HANS HELMUT ZÜRN, Ph.D.



Prof. SIDNEI NOCETI FILHO, Dr.

“Quem, de três milênios,
Não é capaz de se dar conta,
Vive na ignorância, na sombra,
À mercê dos dias, do tempo”.

Johann Wolfgang von Goethe

“O homem é a medida de todas as coisas”.

“Dos Deuses nada posso dizer de concreto,
pois nesse particular são muitas as coisas que ocultam o saber:
a obscuridade do assunto e a brevidade da vida humana”.

Protágoras (487-420 a.C.)

“ Mas a vida é triste e solene.

Somos deixados em um mundo maravilhoso,
encontramo-nos aqui com outras pessoas,
somos apresentados uns aos outros
e caminhamos juntos durante algum tempo.

Depois nos separamos e desaparecemos,
tão rápida e inexplicavelmente quanto surgimos”.

Jostein Gaarder

Aos meus pais,
Reinaldo e Yolanda

Eu ainda crescia no ventre de minha mãe e nessa época
você não sonhavam ainda em me ver formado,
mas enchiam seus corações de humildade
e pediam a Deus que fosse perfeito
e que tivesse saúde.

É difícil lembrar onde vocês não estiveram, assim como é difícil expressar
a minha gratidão por tudo que fizeram em meu benefício.

Todo sacrifício e trabalho para que pudesse concluir os estudos.
A vocês, o verdadeiro e justo momento de vitória.

À minha esposa Elaine

Eu tenho tanto para lhe falar,
mas com palavras não sei dizer.
Como é grande o meu amor por você ...

AGRADECIMENTOS

Aos meus pais, Reinaldo Moitinho de Oliveira e Yolanda Costa de Oliveira, pelo incentivo, apoio, carinho e amor.

À minha esposa, Elaine Cristina Rodrigues dos Santos, pelo companheirismo, amizade e amor.

Ao meu orientador Prof. Rui Seara, pela persistente e preciosa orientação, dedicação e apoio.

Aos professores, Carlos Aurélio F. da Rocha e Sidnei Noceti Filho, que em momentos difíceis deste trabalho, me deram um valioso incentivo.

Ao professor Hans Helmut Zürn, pelas sutis e relevantes contribuições para a redação desta dissertação.

Ao CNPQ pelo apoio financeiro, fundamental na realização deste trabalho.

A todos os amigos e companheiros de pesquisa do LINSE, pela conversa informal e pelas preciosas informações técnicas que também contribuíram para a elaboração deste trabalho.

Aos professores e funcionários da Escola de Engenharia de Lins, em especial a Wail M. Pastorelo Filho, Edgar Paulo Pastorelo, Alberto Eduardo Fregosi e Bianor C. F. Colchesqui, pela amizade sincera e por todo apoio e incentivo.

E a todos aqueles que de alguma forma colaboraram para a realização deste trabalho, o meu *muito obrigado*.

ÍNDICE

LISTA DE GRÁFICOS -----	x
RESUMO -----	xii
ABSTRACT -----	xiii
CAPÍTULO 1 – INTRODUÇÃO -----	1
CAPÍTULO 2 – CONCEITOS FUNDAMENTAIS -----	4
2.1 Introdução -----	4
2.2 Histograma 1D -----	4
2.3 Binarização 1D -----	5
2.4 Histograma 2D -----	5
2.5 Binarização 2D -----	7
2.6 Breve Introdução à Teoria de Lógica Difusa -----	8
2.6.1 Função “S” -----	8
2.6.2 Função “Z” -----	9
2.6.3 Medidas de Difusão -----	10
2.7 Separação Difusa -----	11
2.7.1 Separação Difusa sobre o Histograma 2D -----	12
2.8 Entropia -----	16
CAPÍTULO 3 – MÉTODOS DE REFERÊNCIA -----	18
3.1 Introdução -----	18

3.2 Método 1D -----	18
3.2.1 Descrição do Algoritmo -----	18
3.3 Método 2D -----	19
3.3.1 Descrição do Algoritmo -----	20
3.4 Método 1D Difuso -----	21
3.4.1 Descrição do Algoritmo -----	21
3.5 Método 2D Difuso -----	23
3.5.1 Descrição do Algoritmo -----	24
3.5.2 Cálculo da Entropia -----	24
CAPÍTULO 4 – MÉTODO PROPOSTO -----	27
4.1 Introdução -----	27
4.2 Breve Introdução à Detecção de Bordas -----	28
4.3 Teste Visual para JND -----	29
4.4 Descrição do Algoritmo de Detecção de Bordas -----	31
4.5 Binarização através do Método Proposto -----	34
CAPÍTULO 5 – RESULTADOS EXPERIMENTAIS -----	35
5.1 Introdução -----	35
5.2 Binarização da Imagem “TIFFANY” -----	35
5.3 Comentários sobre os Resultados Obtidos da Imagem Tiffany -----	40
5.4 Binarização da Imagem “LENNA” -----	42
5.5 Comentários sobre os Resultados Obtidos da Imagem Lenna -----	46

5.6 Limitações da Técnica Proposta -----	48
5.6.1 Pseudo Limiar 2D -----	48
5.6.1.1 Alteração de Histograma -----	48
5.6.2 Pseudo Borda -----	53
CAPÍTULO 6 – CONCLUSÕES -----	56
REFERÊNCIAS BIBLIOGRÁFICAS -----	58

LISTA DE FIGURAS

Fig. 2.1 - Histograma bimodal e multimodal dos níveis de cinza de uma imagem -	5
Fig. 2.2 - Histogramas bidimensionais -----	6
Fig. 2.3 - Histograma 2D segmentado pelo vetor limiar (t, s) -----	7
Fig. 2.4 - Função “S” e Função “Z” -----	9
Fig. 2.5 - Separação difusa -----	11
Fig. 2.6 - Separação difusa 2D -----	13
Fig. 2.7 - Função de pertinência 2D -----	15
Fig. 3.1 - Variação dos índices de difusão -----	23
Fig. 4.1 - “Just noticeable difference” (JND) -----	30
Fig. 4.2 - Fluxograma do algoritmo de detecção de bordas -----	33
Fig. 5.1 - Imagem Tiffany em níveis de cinza -----	36
Fig. 5.2 - Histograma da distribuição dos níveis de cinza da imagem Tiffany -----	36
Fig. 5.3 - Histograma 2D da imagem Tiffany -----	37
Fig. 5.4 - Imagem binária obtida do método 1D [5] -----	37
Fig. 5.5 - Imagem binária obtida do método 1D utilizando lógica difusa [15] -----	38
Fig. 5.6 - Imagem binária obtida do método 2D [8] -----	38
Fig. 5.7 - Imagem binária obtida pelo método 2D utilizando lógica difusa [20] ----	39
Fig. 5.8 - Imagem binária obtida pelo método proposto -----	39
Fig. 5.9 - Imagem Lenna em níveis de cinza -----	42
Fig. 5.10 - Histograma da distribuição dos níveis de cinza da imagem Lenna -----	43
Fig. 5.11 - Histograma 2D da imagem Lenna -----	43

Fig. 5.12 - Imagem binária obtida pelo método 1D [5] -----	44
Fig. 5.13 - Imagem binária obtida pelo método 1D utilizando lógica difusa [15] --	44
Fig. 5.14 - Imagem binária obtida pelo método 2D [8] -----	45
Fig. 5.15 - Imagem binária obtida pelo método 2D utilizando lógica difusa [20] --	45
Fig. 5.16 - Imagem binária obtida pelo método proposto -----	46
Fig. 5.17 - Transformação típica de um histograma de imagem -----	49
Fig. 5.18 - Imagem “Couple” original -----	50
Fig. 5.19 - Histograma da distribuição dos níveis de cinza da imagem original ----	51
Fig. 5.20 - Imagem binária resultante da binarização da imagem original -----	51
Fig. 5.21 - Histograma alterado -----	52
Fig. 5.22 - Imagem modificada resultante do alargamento do histograma -----	52
Fig. 5.23 - Imagem binária resultante da binarização da imagem modificada -----	53
Fig. 5.24 - Imagem “baboon” original -----	54
Fig. 5.25 - Imagem binária resultante com limiar único para a detecção de borda -	55
Fig. 5.26 - Imagem binária resultante com limiares diferentes para a detecção de borda -----	55

RESUMO**Segmentação binível de imagens usando Entropia Difusa Bidimensional e Distribuição da Orientação de Gradiente dos Pixels**

Binarização de imagem é uma importante etapa em muitos sistemas de análise de imagem, onde se deseja reconhecer ou selecionar um determinado padrão. Nós propomos um método de binarização de imagem baseado na associação de informações relevantes da imagem, tais como, distribuição dos níveis de cinza, média local dos níveis de cinza, e orientação do gradiente dos pontos da imagem. Para isso, em uma primeira etapa, é determinado o limiar do par (nível de cinza, média local) através da máxima entropia difusa no histograma 2D; em seguida, um algoritmo de detecção de bordas é utilizado para encontrar as bordas da imagem original; então, finalmente é realizada uma completa binarização da imagem associando todas essas informações. Em nossas simulações constatamos que o algoritmo proposto permite obter uma imagem binária de melhor qualidade quando comparado às mais recentes técnicas encontradas na literatura, no entanto, com um custo de uma maior complexidade computacional.

Palavras chaves:

Segmentação de imagem;

Imagem binária;

Reconhecimento de padrões;

Entropia difusa.

ABSTRACT**Bilevel Segmentation of Images using Two-Dimensional Fuzzy Entropy and Orientation Distribution of Gradient Pixels**

Thresholding is an important step in most image analysis systems when we desire to recognize or extract a selected pattern. We propose a threshold technique based on an association of pertinent information of the image, such as gray level distribution, local average gray level and orientation distribution of gradient pixels. For this end, initially, a threshold is obtained based on the two-dimensional (2D) histogram (gray level, local average gray level) using the maximal fuzzy entropy criterion; next, an edge detection algorithm is applied for finding the edges of the original image; finally, a whole image thresholding is achieved, associating the above information. By simulation, we confirm that the proposed algorithm leads to a binary image with better quality, as compared to most recent techniques found in the literature, but paying a price of a larger computational complexity.

Keywords:

Image thresholding;

Binary image;

Pattern recognition;

Fuzzy entropy.

INTRODUÇÃO

Binarização é uma técnica largamente utilizada em segmentação de imagem quando há interesse em identificar os diferentes componentes homogêneos de uma imagem [1,2,3]. Isto é útil, por exemplo, na discriminação entre objeto e fundo, em aplicações em que se busca reconhecer algum padrão procurado (como exemplo, nós poderíamos citar análises de imagens: biomédicas, aonde deseja-se reconhecer algum tipo de bactéria, célula, etc; geológicas, buscando separar algum tipo de rocha, mineral, etc; industriais, fazendo controle de qualidade com base no reconhecimento de uma falha; e militares, tendo como objetivo identificar um alvo militar) [12]. As bordas podem ser detectadas como o limite dos diferentes segmentos homogêneos. Porém, isto tem valor limitado para imagens texturizadas, isto é, aquelas que apresentam componentes não-homogêneos.

Há dois tipos de separação dos componentes homogêneos de uma imagem: binível e multinível. No primeiro, assume-se que a imagem é composta por dois componentes (ou classes, ou grupos, ou ainda, segmentos), objeto e fundo, que têm distintamente diferentes distribuições de níveis de cinza. Tenta-se então achar o valor limiar entre os dois grupos. Cada pixel com nível de cinza acima de um determinado limiar é assumido como objeto (ou fundo) e aquele abaixo é assumido como fundo (ou objeto). No multinível, assume-se que a imagem é composta de várias classes, cada uma com valores homogêneos de nível de cinza. Tenta-se então localizar os valores dos

limiares que podem separar essas classes. Obviamente, a situação multinível é uma extensão do caso binível. Em nosso trabalho, vamos abordar a separação binível, a qual denominaremos de um processo de binarização, já que, a imagem resultante será representada com apenas dois valores.

Na separação binível, a distribuição dos níveis de cinza (histograma) tem normalmente um vale entre dois picos (histograma bimodal); cada um representa a concentração de níveis de cinza da classe objeto ou fundo. O objetivo é localizar, eficientemente, o valor do vale, o qual separa as duas classes. Nestes casos, soluções simples e de baixo custo computacional, de acordo com algum critério como variância dentro das classes, variância entre classes, variância total, ou entropia, podem ser utilizadas, com resultados satisfatórios [4,5,6,7]. No entanto, para histogramas multimodais (com vários vales e picos), é necessário a utilização de métodos mais complexos [8,9,10], e portanto de maior esforço computacional para se obter uma boa separação entre as duas classes.

Recentemente, têm sido apresentados na literatura, métodos que utilizam lógica difusa e entropia difusa para a determinação do limiar. Devido à natureza difusa da região próxima ao limiar ótimo, esses métodos, utilizando pouco esforço computacional, apresentam bons resultados em imagens cujo histograma é multimodal [11,12,13,14,15].

As técnicas de separação que são baseadas somente no nível de cinza, contudo, não utilizam todas as informações disponíveis na imagem. O efeito da informação não incluída se torna aparente quando a razão sinal/ruído (SNR) decresce. Assim, espera-se uma melhora do desempenho se a informação espacial sobre a interação entre os pontos é explorada. Isso foi apresentado em [16, 23, 24]. Nesses trabalhos tem sido usada a

chamada matriz de co-ocorrência para determinar o limiar ótimo; essa matriz representa a probabilidade de ocorrência entre dois valores de níveis de cinza quando os pontos correspondentes são separados por uma determinada distância.

Na abordagem proposta, vamos utilizar a informação espacial (através da média local) associada ao nível de cinza do ponto e às bordas da imagem. Ambos, o nível de cinza em cada ponto e a média local em sua vizinhança, são usados para gerar um histograma bidimensional, que representa o número de ocorrências do par (nível de cinza, média local). O ponto de máxima entropia no histograma 2D (bidimensional) determina os limiares para o nível de cinza e para a média local da imagem. Simultaneamente um outro algoritmo determina as bordas da imagem através do gradiente local. Assim, um ponto pertence a uma classe se satisfizer a uma das três condições: limiar do nível de cinza, limiar da média local ou ponto borda; não somente uma, como nos métodos convencionais, nem duas, como nos métodos que utilizam o histograma 2D.

No Capítulo 2 são apresentados os conceitos fundamentais que serão utilizados neste trabalho. No Capítulo 3 são discutidos os métodos que serão utilizados como referência. No Capítulo 4 é apresentado o algoritmo proposto. No Capítulo 5 têm-se os resultados experimentais, que mostram o ganho de qualidade que se obtém com a associação das informações, como também as dificuldades e limitações encontradas e as propostas para solucioná-las. E finalmente, no Capítulo 6 são apresentadas as conclusões e discussões deste trabalho.

CONCEITOS FUNDAMENTAIS**2.1 Introdução**

Neste capítulo são apresentados os conceitos básicos sobre binarização de imagem, que são relevantes para o entendimento deste trabalho. Primeiro, vamos apresentar o conceito de histograma, que é o fundamento básico das técnicas que serão aqui discutidas. Em seguida apresentaremos, os conceitos de binarização 1D (unidimensional), histograma 2D (bidimensional), binarização 2D, entropia, lógica difusa e separação difusa.

2.2 Histograma 1D

Considere que f_1, f_2, \dots, f_L representa a frequência do nível de cinza observado (histograma 1D). A expressão para a probabilidade (percentual de ocorrência de um específico nível de cinza), p_i , será :

$$p_i = f_i / N^2, \quad \sum_{i=1}^L f_i = N^2, \quad i = 1, 2, \dots, L, \quad (2.1)$$

onde N^2 é o número total de pontos na imagem e L é o número de níveis de cinza no histograma. A Fig. 2.1 mostra dois tipos de histograma comumente encontrados, o primeiro é o histograma bimodal e o segundo é o histograma multimodal.

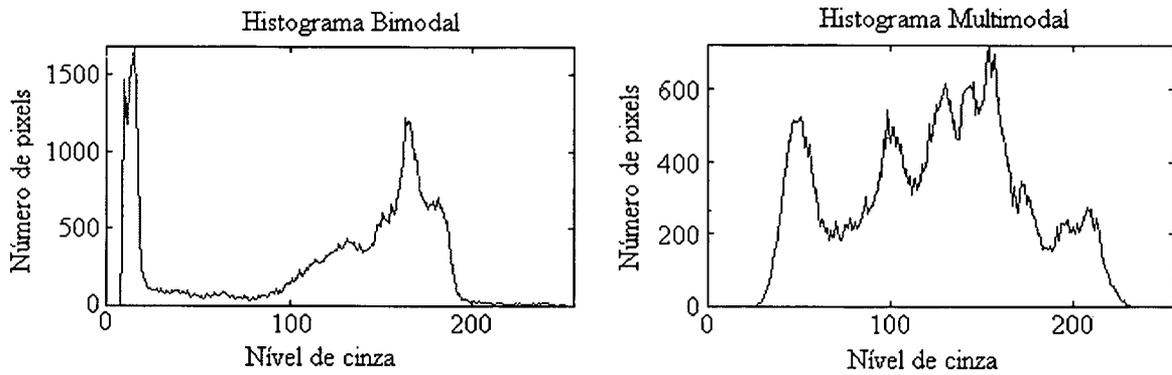


Fig. 2.1 - Histograma bimodal e multimodal dos níveis de cinza de uma imagem.

2.3 Binarização 1D

Uma vez que o valor do limiar t é obtido da aproximação proposta, nós podemos encontrar a imagem binária através da seguinte expressão:

$$f_i(x, y) = \begin{cases} 0, & f(x, y) < t \\ 1, & f(x, y) \geq t \end{cases} \quad (2.2)$$

onde $f(x, y)$ corresponde à intensidade do nível de cinza da imagem no ponto (x, y) .

2.4 Histograma 2D

O histograma 2D (histograma bidimensional) é definido como a distribuição do par (nível de cinza, média local) de todos os pontos da imagem. Para encontrá-lo é preciso definir a média local dos pontos da imagem. Supondo uma imagem digital com $N \times N$ pontos e L níveis de cinza $(0, 1, 2, \dots, L - 1)$ sendo representada como função da intensidade 2D $f(x, y)$; define-se a média local $g(x, y)$ de $f(x, y)$ como a média da intensidade dos seus pontos vizinhos, Eq. (2.3). Esse valor deve ser arredondado, pois a escala de níveis de cinza possui apenas valores inteiros.

$$g(x, y) = \frac{1}{n^2} \sum_{k=-n/2}^{n/2} \sum_{l=-n/2}^{n/2} f(x+k, y+l) \quad (2.3)$$

onde n representa o tamanho da janela utilizada para calcular a média local.

A operação de média funciona como um filtro espacial passa-baixas $n \times n$, que tem como característica atenuar as altas frequências, reduzindo com isso o ruído e algumas distorções, pois esses se caracterizam por ter intensidades muito diferentes dos seus pontos vizinhos. Os pontos fora da diagonal principal no histograma 2D, representam os pontos da imagem que têm igual intensidade de nível de cinza mas têm diferentes características espaciais. A ordem de um histograma 2D é (L, L) , cujos valores pontuais representam o número de ocorrências do par $(f(x, y), g(x, y))$. O número de ocorrências desse par dividido pelo número total de pontos, define a probabilidade p_{ij} :

$$p_{ij} = f_{ij} / N^2, \quad (i, j) = 1, 2, \dots, L. \quad (2.4)$$

Assim, podemos notar que os componentes afastados da diagonal principal serão próximos ou iguais a zero. A Fig. 2.2 mostra alguns exemplos de histogramas 2D.

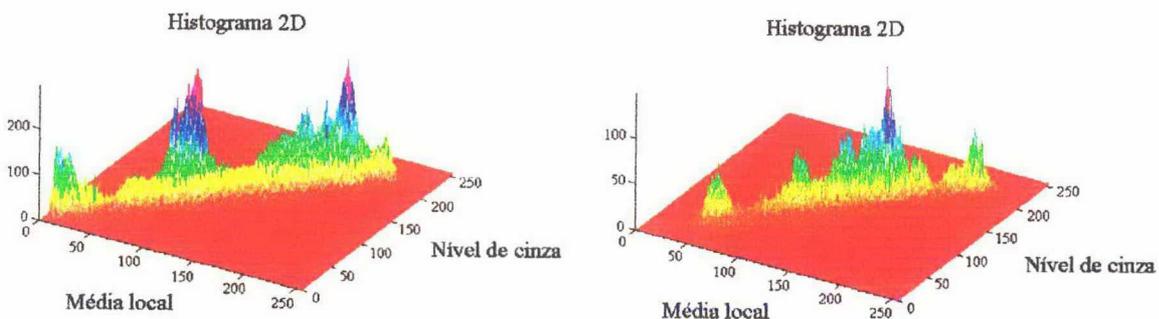


Fig. 2.2 - Histogramas bidimensionais.

2.5 Binarização 2D

No processo de binarização 2D, é determinado um vetor limiar (t, s) que divide o histograma 2D em quatro blocos, Fig. 2.3; i.e., um bloco de níveis escuros, um bloco de níveis claros, e dois blocos de ruídos (ou bordas, ou limites, pois esses blocos possuem pontos que se caracterizam por terem níveis de cinza escuro (ou claro) para uma média local clara (ou escura)). A binarização separa então o bloco de níveis escuros (classe objeto ou fundo), deixando os blocos de ruídos junto com o bloco de níveis claros (classe fundo ou objeto). Isso pode ser expresso por:

$$f_{ts}(x, y, \text{escuro}) = \begin{cases} 1, & f(x, y) \geq t \cup g(x, y) \geq s \\ 0, & \text{outros} \end{cases} \quad (2.5)$$

onde $g(x, y)$ é a média local de $f(x, y)$ definida pela Eq. (2.3). Inversamente, se é desejado extrair a classe de níveis claros, a Eq. (2.5) pode ser alterada para:

$$f_{ts}(x, y, \text{claro}) = \begin{cases} 0, & f(x, y) < t \cup g(x, y) < s \\ 1, & \text{outros} \end{cases} \quad (2.6)$$

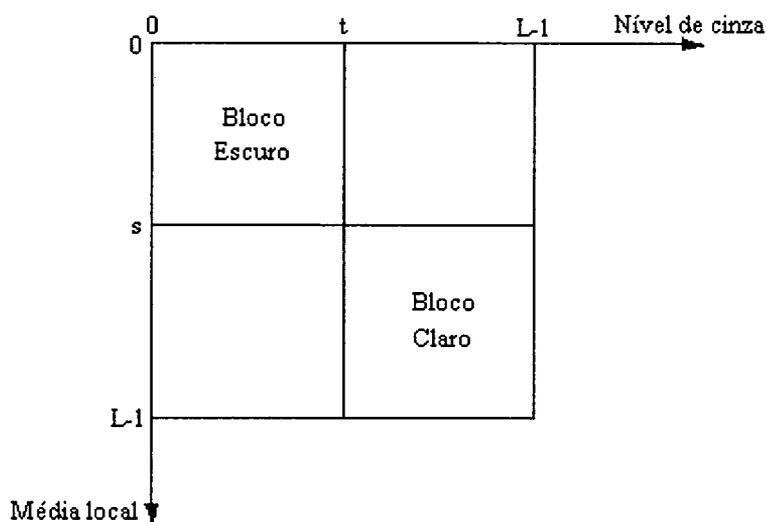


Fig. 2.3 - Histograma 2D segmentado pelo vetor limiar (t, s) .

2.6 Breve Introdução à Teoria de Lógica Difusa

A teoria dos conjuntos difusos está baseada na idéia de representar elementos e conjuntos tendo como fundamento uma relação de pertinência vaga, incerta, ambígua ou indefinida [17].

Um conjunto difuso A , no espaço observado X , é caracterizado por uma função de pertinência $\mu_A(x_i)$, que associa cada elemento x_i de X com um número real, $\mu_A(x_i)$, no intervalo $[0, 1]$. O valor de $\mu_A(x_i)$ indica com que grau o elemento x_i pertence a A . Generalizando, um conjunto difuso A é definido como uma coleção de pares ordenados e pode ser expresso pela seguinte notação:

$$A = \{(x_i, \mu_A(x_i)) | i = 1, 2, \dots, L\}$$
$$A = \sum_{i=1}^L \frac{\mu_A(x_i)}{x_i} \quad (2.7)$$

onde o somatório indica a união de todos os elementos x_i .

2.6.1 Função “S”

A seleção da função de pertinência depende da aplicação. Neste trabalho, vamos introduzir as duas funções que são utilizadas em nossos experimentos. Uma é a Função-S e a outra é a Função-Z. Outros tipos de funções podem ser encontradas em [17].

A Função-S é definida por:

$$\mu_A(x_i) = S(x_i; a, b, c) = \begin{cases} 0 & x_i \leq a \\ \frac{(x_i - a)^2}{(b - a)(c - a)} & a \leq x_i \leq b \\ 1 - \frac{(x_i - c)^2}{(c - b)(c - a)} & b \leq x_i \leq c \\ 1 & c \leq x_i \end{cases} \quad (2.8)$$

onde x_i é a variável observada. Aqui, x_i é o nível de cinza que varia entre 0 a 255. Os parâmetros a , b , e c determinam a forma da Função-S. O intervalo $[a, c]$ é a região difusa; b é usualmente o ponto médio desse intervalo, mas não necessariamente.

2.6.2 - Função “Z”

A Função-Z pode ser obtida da Função-S pela seguinte relação:

$$Z(x_i; a, b, c) = 1 - S(x_i; a, b, c) \quad (2.9)$$

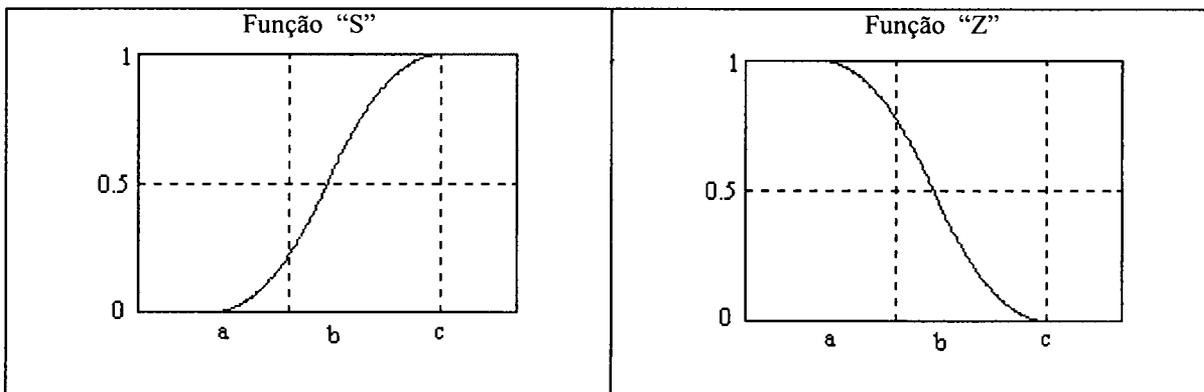


Fig. 2.4 - Função “S” e Função “Z”.

2.6.3 Medidas de Difusão

Usando o índice de difusão (ID) introduzido por Kaufmann [17], nós podemos determinar com que grau os elementos do conjunto difuso A pertencem ao conjunto ordinário \underline{A} . Na definição de Kaufmann, este índice é obtido medindo a distância entre A e \underline{A} , definida por:

$$\Psi_k(\mathbf{A}) = \frac{2}{n^k} d_k(A, \underline{A}) \quad (2.10)$$

onde $d(A, \underline{A})$ é a distância e n é o número de elementos de A . Para $k = 1$ e 2 , nós temos o índice linear e o quadrado, respectivamente. Estas medidas são representadas pela seguintes expressões:

para $k = 1$, índice de difusão linear:

$$\Psi_1(\mathbf{A}) = \frac{2}{n} \sum_{i=1}^n |\mu_A(x_i) - \mu_{\underline{A}}(x_i)| \quad (2.11)$$

para $k = 2$, índice de difusão quadrático:

$$\Psi_2(\mathbf{A}) = \frac{2}{\sqrt{n}} \sqrt{\sum_{i=1}^n (\mu_A(x_i) - \mu_{\underline{A}}(x_i))^2} \quad (2.12)$$

e $\mu_{\underline{A}}(x_i)$ é a função de pertinência de \underline{A} , que é definida por:

$$\mu_{\underline{A}}(x_i) = \begin{cases} 0 & \text{if } \mu_A(x_i) < 0.5 \\ 1 & \text{if } \mu_A(x_i) \geq 0.5 \end{cases} \quad (2.13)$$

2.7 Separação Difusa

Como a pertinência de um elemento em um conjunto difuso pode ser qualquer valor real entre $[0, 1]$, um elemento pode pertencer parcialmente a cada subconjunto da separação difusa. Nós usaremos um exemplo para demonstrar isso.

Consideramos $X = 0,1,2,\dots,7$ ser a escala de intensidade de uma imagem, onde 0 significa a intensidade mais escura e 7 a mais clara. Uma separação difusa binível pode ser obtida de X por dois subconjuntos difusos A_1 e A_2 , ou seja :

$$A_1 = \sum_{i=0}^7 \frac{\mu_{A_1}(x_i)}{x_i} = \frac{1}{0} + \frac{1}{1} + \frac{1}{2} + \frac{1}{3} + \frac{0.78}{4} + \frac{0.22}{5} + \frac{0}{6} + \frac{0}{7}$$

$$A_2 = \sum_{i=0}^7 \frac{\mu_{A_2}(x_i)}{x_i} = \frac{0}{0} + \frac{0}{1} + \frac{0}{2} + \frac{0}{3} + \frac{0.22}{4} + \frac{0.78}{5} + \frac{1}{6} + \frac{1}{7}$$

onde $\mu_{A_1}(x_i)$ é uma Função-Z e $\mu_{A_2}(x_i)$ é sua correspondente Função-S. A separação é mostrada na Fig. 2.5.

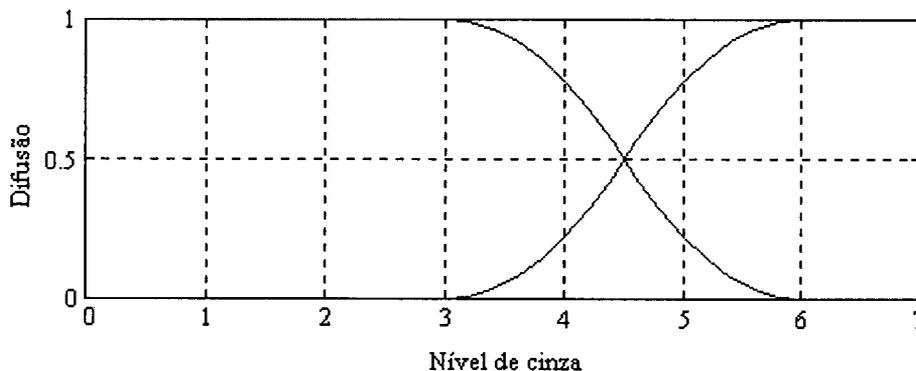


Fig. 2.5 - Separação difusa.

Basicamente, há duas tarefas para executar em uma separação difusa.

- i) determinação da região difusa. A região difusa é determinada pelo intervalo $[a, c]$. No exemplo acima, usando a Função-S (Função-Z) como uma função de pertinência, a região difusa é o intervalo $[a, c] = [3, 6]$.

ii) designação de pertinência. Os elementos na região difusa têm a incerteza de pertencer ao conjunto A_1 ou A_2 . A posição do ponto b pode influenciar a determinação das pertinências $\mu_{A_1}(x_i)$ e $\mu_{A_2}(x_i)$.

Conseqüentemente, uma separação difusa pode ser completamente caracterizada por uma combinação de a , b , e c . O ponto de cruzamento da Função-S com a Função-Z, ponto b , determina o ponto de separação entre os dois conjuntos A_1 e A_2 .

2.7.1 Separação Difusa sobre o Histograma 2D

Como descrito anteriormente, uma separação difusa pode ter uma região de incerteza entre os subconjuntos difusos. Aplicando esta consideração para o histograma 2D da imagem, deve haver um bloco difuso entre o bloco de níveis escuros (Bloco_A) e o bloco de níveis claros (Bloco_B). Baseado nos parâmetros a , b e c da Função-S (Função-Z), o Bloco_A é definido como o bloco que contém os pontos com coordenadas $(0,0)$ até (c,c) , o Bloco_B é o bloco que contém os pontos de coordenadas (a,a) até $(L-1, L-1)$. O bloco de incertezas é chamado bloco difuso (Bloco_D), que inicia no ponto (a,a) e termina no ponto (c,c) . A separação difusa é ilustrada na Fig. 2.6.

Depois de determinar a região difusa no histograma 2D da imagem, o próximo passo é determinar a pertinência para cada ponto do histograma 2D. Como os pontos do histograma 2D são classificados em dois subconjuntos difusos, devemos definir duas funções de pertinências para cada par (nível de cinza, média local). Uma é para o conjunto difuso claro, que descreve quão claro é o ponto, e o outro é para o conjunto difuso escuro, que descreve quão escuro é o ponto.

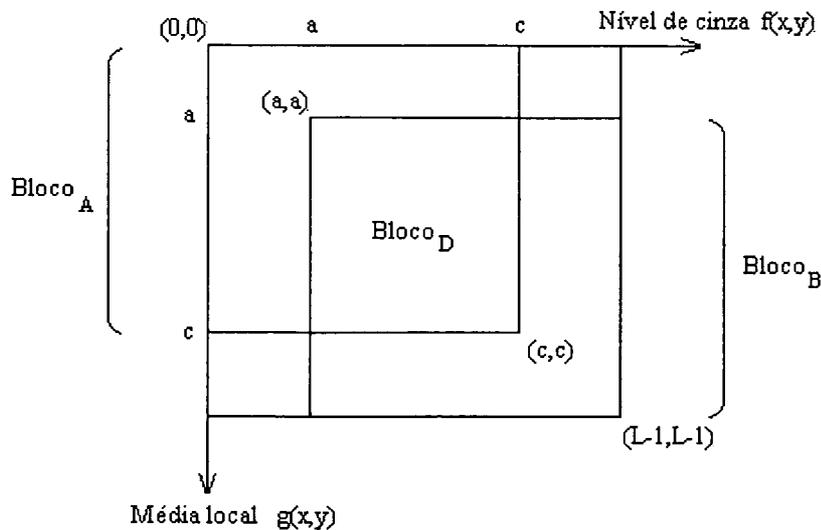


Fig. 2.6 - Separação difusa 2D.

Um histograma 2D consiste de todas os possíveis pares de (média local de nível de cinza, nível de cinza). Definindo dois conjuntos X e Y , que representam a média local e o nível de cinza, respectivamente, para definir os dois conjuntos difusos claro e escuro sobre o histograma 2D, vamos antes definir quatro conjuntos difusos, baseados na Função-S e a sua correspondente Função-Z, com parâmetros (a,b,c) . Eles são $Claro_x$, $Escuro_x$, $Claro_y$, $Escuro_y$; onde $Claro_x$ e $Escuro_x$ são os conjuntos difusos definidos para os elementos de X e $Claro_y$ e $Escuro_y$ são os conjuntos difusos definidos para os elementos de Y . Eles são descritos como segue:

- 1 - $Claro_x$ é um conjunto difuso que descreve o quanto é clara a variável observada $x \in X$. A função de pertinência μ_{Claro_x} é definida por uma Função-S. Assim:

$$Claro_x = \sum_{x \in X} \frac{\mu_{Claro_x}(x)}{x} = \sum_{x \in X} \frac{S(x; a, b, c)}{x}$$

2 - $Escuro_x$ é um conjunto difuso que descreve o quanto é escura a variável observada $x \in X$. A função de pertinência μ_{Escuro_x} é definida por uma Função-Z. Assim:

$$Escuro_x = \sum_{x \in X} \frac{\mu_{Escuro_x}(x)}{x} = \sum_{x \in X} \frac{Z(x; a, b, c)}{x}$$

3 - $Claro_y$ é um conjunto difuso que descreve o quanto é clara a variável observada $y \in Y$. A função de pertinência μ_{Claro_y} é definida por uma Função-S. Assim:

$$Claro_y = \sum_{y \in Y} \frac{\mu_{Claro_y}(y)}{y} = \sum_{y \in Y} \frac{S(y; a, b, c)}{y}$$

4 - $Escuro_y$ é um conjunto difuso que descreve o quanto é escura a variável observada $y \in Y$. A função de pertinência μ_{Escuro_y} é definida por uma Função-Z. Assim:

$$Escuro_y = \sum_{y \in Y} \frac{\mu_{Escuro_y}(y)}{y} = \sum_{y \in Y} \frac{Z(y; a, b, c)}{y}$$

O conjunto difuso Claro pode ser obtido pelo produto cartesiano entre os conjuntos $Claro_x$ e $Claro_y$, i.e.,

$$Claro = Claro_x \times Claro_y \subset X \times Y$$

A pertinência do conjunto difuso Claro pode ser obtida pela expressão :

$$\mu_{Claro}(x, y) = \mu_{Claro_x \times Claro_y}(x, y) = \min\{\mu_{Claro_x}(x), \mu_{Claro_y}(y)\} \quad (2.14)$$

Similarmente, o conjunto difuso Escuro pode ser obtido pelo produto cartesiano dos conjuntos difuso $Escuro_x$ e $Escuro_y$:

$$Escuro = Escuro_x \times Escuro_y \subset X \times Y$$

onde o conjunto difuso escuro tem a função de pertinência :

$$\mu_{Escuro}(x,y) = \mu_{Escuro_x \times Escuro_y}(x,y) = \min\{\mu_{Escuro_x}(x), \mu_{Escuro_y}(y)\} \quad (2.15)$$

As pertinências dos conjuntos difusos Claro e Escuro são mostradas na Fig. 2.7.

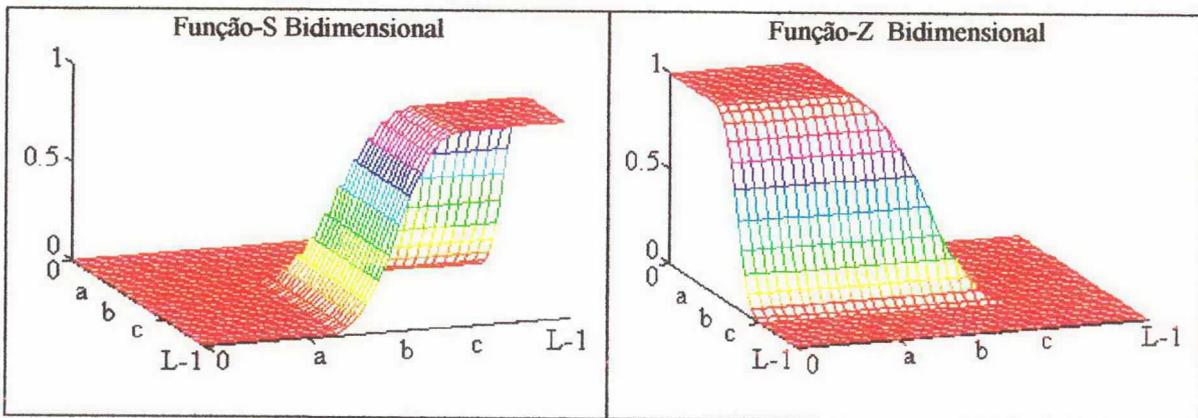


Fig. 2.7 - Função de pertinência 2D.

Note que os conjuntos Claro e Escuro não são complementares um em relação ao outro, i.e., a soma de $\mu_{Claro}(x,y)$ para todos (x,y) de um histograma 2D não é necessariamente igual a 1, ou seja:

$$\mu_{Claro}(x,y) \neq 1 - \mu_{Escuro}(x,y)$$

2.8 Entropia

De acordo com a Teoria de Informação [18], a entropia de um sistema é uma medida da quantidade de informação de um sistema. Consideremos x_i , para $i = 1, 2, \dots, L$, ser a possível saída para a fonte A com a probabilidade $P(x_i)$. A entropia é definida por:

$$H_{\text{nonfuzzy}}(A, P) = - \sum_{i=1}^L P(x_i) \ln(P(x_i)) \quad (2.16)$$

onde

$$\sum_{i=1}^L P(x_i) = 1$$

O subscrito “*nonfuzzy*” é usado para distingüir a entropia “*fuzzy*”. Um alto valor de entropia significa uma grande quantidade de informação.

Podemos definir a entropia difusa levando em consideração a probabilidade e a pertinência [19]. Considere A ser um conjunto difuso com função de pertinência $\mu_A(x_i)$, onde x_i , para $i = 1, \dots, L$, são as possíveis saídas da fonte A com a probabilidade $P(x_i)$. A entropia difusa do conjunto A é definida por:

$$H_{\text{fuzzy}}(A, P) = - \sum_{i=1}^L \mu_A(x_i) P(x_i) \ln(P(x_i)) \quad (2.17)$$

A diferença entre a Eq. (2.16) e a Eq. (2.17) é o termo $\mu_A(x_i)$, que serve como um peso multiplicativo na Eq. (2.17). Assim, a entropia difusa é também chamada de entropia de pesos.

Nós vamos ilustrar através de um exemplo numérico como a entropia pode ser usada para medir a quantidade de informação de um sistema.

Supondo dois sistemas A e B , ambos contendo 10 elementos, sendo que o primeiro tem distribuição uniforme, e o segundo, uma probabilidade unitária, então:

$$P(a_1) = P(a_2) = \dots = P(a_{10}) = 0.1, \text{ para } A$$

$$P(b_1) = 1 \quad \text{e} \quad P(b_2) = P(b_3) = \dots = P(b_{10}) = 0, \text{ para } B$$

Assim, aplicando a Eq. (2.16) obtém-se:

$$H(A, P_A) = 2.3026 \quad \text{e} \quad H(B, P_B) = 0$$

Pode-se então constatar, que a máxima entropia ocorre para um sistema uniformemente distribuído.

MÉTODOS DE REFERÊNCIA

3.1 Introdução

Podemos encontrar na literatura diversos métodos de binarização baseados no histograma da imagem. Apresentaremos aqui alguns desses métodos.

3.2 Método 1D

A idéia básica desse método [5], é encontrar um limiar t , no histograma 1D, de forma que a informação avaliada nos conjuntos objeto e fundo, seja maximizada. Essa informação é medida através da entropia 1D. Os passos desse método são mostrados a seguir.

3.2.1 Descrição do Algoritmo

Supondo que o histograma 1D pode ser dividido em dois grupos (ou conjuntos), A e B, que representam, respectivamente, os conjuntos objeto e o fundo da imagem devemos então encontrar um valor de nível de cinza que separe eficientemente os dois grupos; esse valor é chamado limiar (t). Para um determinado valor t , as entropias para os grupos A e B podem ser definidas, respectivamente, por [5]:

$$H_A(t) = - \sum_{i=1}^t (p_i / P_t) \ln(p_i / P_t) \quad (3.1)$$

$$H_B(t) = - \sum_{i=t+1}^L (p_i / (1 - P_t)) \ln(p_i / (1 - P_t)) \quad (3.2)$$

onde

$$P_t = \sum_{i=1}^t p_i \quad \text{e} \quad p_i = \frac{f_i}{N^2}$$

O critério de discriminação entre o objeto e o fundo, $\Psi(t)$, é definido como o somatório das duas entropias acima, que após algumas manipulações algébricas resulta:

$$\Psi(t) = \ln(P_t(1 - P_t)) + H_t / P_t + (H_L - H_t) / (1 - P_t) \quad (3.3)$$

onde

$$H_t = - \sum_{i=1}^t p_i \ln(p_i) \quad \text{e} \quad H_L = - \sum_{i=1}^L p_i \ln(p_i)$$

Para encontrar o limiar é necessário uma pesquisa exaustiva em todos os valores de nível de cinza. O nível de cinza que leva à máxima entropia, segundo o critério definido na Eq. (3.3), é o valor limiar t . Fixando os níveis de cinza acima do valor limiar t igual a 1 e o resto igual a 0, obteremos uma imagem binária.

3.3 Método 2D

A idéia básica desse método [8], é encontrar os limiares (t, s) , no histograma 2D, de forma que a informação avaliada nos conjuntos objeto e fundo, seja maximizada. Essa informação é medida através da entropia 2D. Os passos desse método são mostrados a seguir.

3.3.1 Descrição do Algoritmo

Supondo que o histograma 2D pode ser dividido em dois grupos, A e B, que representam, respectivamente, os conjuntos objeto e o fundo da imagem, devemos então encontrar os valores do par (nível de cinza, média local) que separe eficientemente os dois grupos; esses valores são chamados limiares (t, s) . Para um determinado par (t, s) , as entropias para os grupos A e B podem ser definidas, respectivamente, por [8]:

$$H_A(t, s) = - \sum_{i=1}^t \sum_{j=1}^s (p_{ij} / P_{ts}) \ln(p_{ij} / P_{ts}) \quad (3.4)$$

$$H_B(t, s) = - \sum_{i=t+1}^L \sum_{j=s+1}^L (p_{ij} / (1 - P_{ts})) \ln(p_{ij} / (1 - P_{ts})) \quad (3.5)$$

onde

$$P_{ts} = \sum_{i=1}^t \sum_{j=1}^s p_{ij}$$

O critério de discriminação entre o objeto e o fundo, $\Psi(t, s)$, é definido como o somatório das duas entropias acima, que após algumas manipulações algébricas resulta:

$$\Psi(t, s) = \ln(P_{ts}(1 - P_{ts})) + H_{ts} / P_{ts} + (H_{LL} - H_{ts}) / (1 - P_{ts}) \quad (3.6)$$

onde

$$H_{ts} = - \sum_{i=1}^t \sum_{j=1}^s p_{ij} \ln(p_{ij}) \quad \text{e} \quad H_{LL} = - \sum_{i=1}^L \sum_{j=1}^L p_{ij} \ln(p_{ij})$$

O algoritmo então determina o vetor limiar (t, s) que maximiza $\Psi(t, s)$.

Brink [9] demonstra que a maximização da entropia total [8], pode não significar a máxima entropia de ambos os conjuntos; portanto, ele propõe a maximização da

entropia dos conjuntos, objeto e fundo, através do critério “maximin”, Eq. (3.7), a qual conduz a um melhor vetor limiar (t, s) . Assim,

$$\Psi(t, s) = \max \left(\begin{array}{l} \min_{t = 0, \dots, L-1} \\ \min_{s = 0, \dots, L-1} \end{array} \{H_A(t, s), H_B(t, s)\} \right) \quad (3.7)$$

3.4 Método 1D Difuso

O objetivo desta técnica é usar uma medida de difusão para achar o limiar no histograma de nível de cinza da imagem [15]. O índice de difusão (ID) é calculado para cada valor de nível de cinza da região difusa, em relação ao conjunto objeto e ao conjunto fundo. O limiar é encontrado através do ponto de intersecção das curvas dos índices de difusão normalizados.

3.4.1 Descrição do Algoritmo

Deve-se, em princípio, definir dois conjuntos difusos de referência R_A e R_B , que pertencem aos conjuntos A (objeto) e B (fundo), respectivamente. Considerando X como o conjunto universo cujo suporte são os números $\{0, 1, \dots, L-1\}$, então $R_A \subset X$; $R_B \subset X$; e $A \cup B = X$. Os conjuntos de referência são associados respectivamente ao intervalos do histograma $[x_L, x_j]$ e $[x_r, x_H]$. x_j e x_r são os limites, final e inicial, dos níveis de cinza para os conjuntos R_A e R_B , respectivamente. x_L e x_H são os níveis de cinza, menor e maior, do histograma da imagem, respectivamente.

O vale entre os conjuntos de referência pode ser visto como um intervalo difuso; nesse intervalo os níveis de cinza possuem uma forte ambigüidade. Em seguida, baseado no índice de difusão, cada nível de cinza do intervalo difuso é atribuído a um dos dois conjuntos R_A e R_B . O nível de cinza do conjunto que apresentar ID (ambigüidade) mínimo é o selecionado. Para cada conjunto, representando um intervalo no histograma, a função de pertinência $\mu_A(x_i) = Z(x_i; a, b, c)$ e $\mu_B(x_i) = S(x_i; a, b, c)$ é calculada, usando a Função-Z e Função-S, respectivamente para os conjuntos R_A e R_B .

Antes de inicializar a alocação dos níveis de cinza do intervalo difuso, a medida de ID é normalizada através do fator de equalização α , que é definido por:

$$\alpha = \Psi(R_A) / \Psi(R_B) \quad (3.8)$$

Desse modo, certifica-se que os índices estão relacionados permitindo, assim, uma comparação entre eles. Os passos do processo de classificação são efetuados pelo algoritmo descrito a seguir:

para $i = j$ até r

passo 1: calcular $\Psi_{R_A}(R_A \cup \{x_i\})$;

passo 2: calcular $\Psi_{R_B}(R_B \cup \{x_i\})$;

passo 3: Se $\Psi_{R_B}(R_B \cup \{x_i\}) < \alpha \cdot \Psi_{R_A}(R_A \cup \{x_i\})$

então x_i é incluído no conjunto R_B ;

senão x_i é incluído no conjunto R_A ;

fim

fim

A Fig. 3.1 mostra o gráfico da função $\Psi_{R_A}(R_A \cup \{x_i\})$, $\Psi_{R_B}(R_B \cup \{x_i\})$ e $\alpha \cdot \Psi_{R_A}(R_A \cup \{x_i\})$, para $i = 1, 2, \dots, L-1$. O limiar é determinado pela intersecção das curvas dos índices de difusão normalizados. O conjunto objeto A é composto por todos os níveis de cinza acima do ponto de intersecção e o conjunto fundo B por aqueles abaixo.

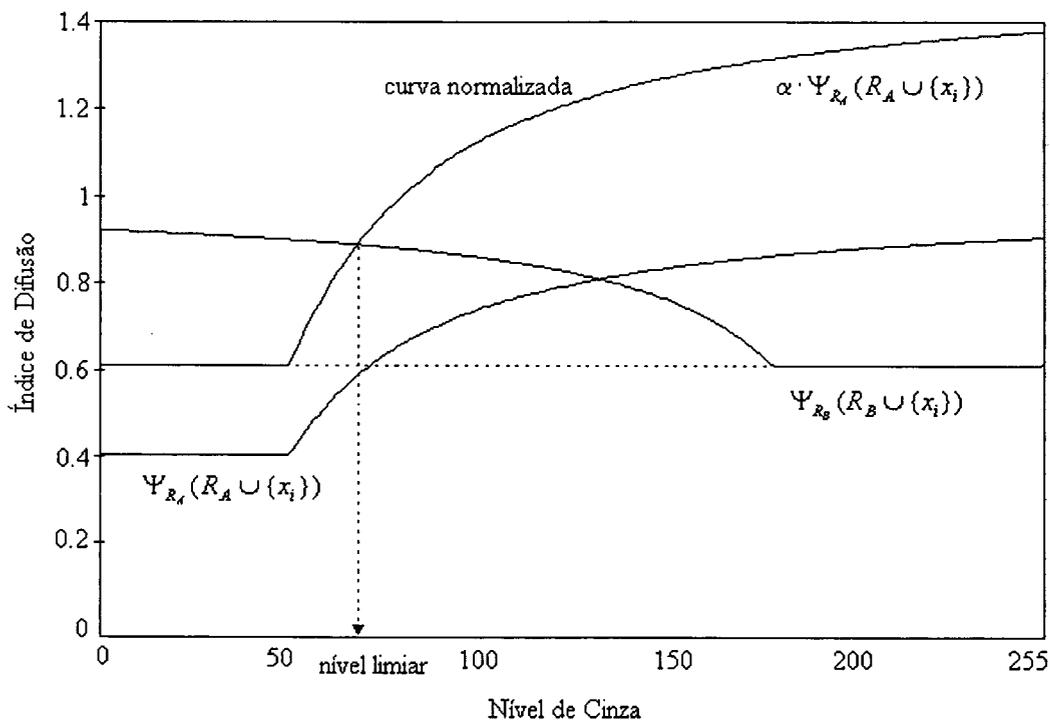


Fig. 3.1 - Variação dos índices de difusão.

3.5 Método 2D Difuso

A idéia básica desta técnica [20], é encontrar a separação difusa ótima que divide todos os pontos da imagem em dois subconjuntos difusos (i.e., classes de objeto e classes de fundo), que maximize a entropia da imagem. Essa é a soma das entropias dos dois subconjuntos difusos em relação à combinação dos parâmetros a , b , e c . Para encontrar a

solução ótima é utilizado um algoritmo genético [21], visto que uma pesquisa exaustiva demandaria muito esforço computacional. Outros métodos de otimização também poderiam ser utilizados [10].

3.5.1 Descrição do Algoritmo

O algoritmo consiste de três passos:

- i) achar o histograma 2D da imagem;
- ii) fazer uma separação difusa sobre o histograma 2D;
- iii) calcular a entropia da imagem.

O passo 1 necessita ser executado somente uma vez, enquanto os passos 2 e 3 precisam ser executados iterativamente para cada conjunto (a,b,c) . A máxima entropia determina o ótimo conjunto (a,b,c) que gera a região difusa (i.e., o intervalo $[a,c]$). O limiar é selecionado como o ponto de intersecção entre as Função-S e Função-Z, ponto esse que apresenta pertinência 0.5.

3.5.2 Cálculo da Entropia

Depois do histograma 2D ser dividido em classes de objeto e fundo ($Bloco_A$ e $Bloco_B$) e as pertinências $\mu_{claro}(x,y)$ e $\mu_{Escuro}(x,y)$ serem determinadas, suas entropias são calculadas separadamente e a entropia da imagem total é definida por:

$$H(imagem) = H(Bloco_A) + H(Bloco_B) \quad (3.9)$$

O bloco escuro $Bloco_A$ pode ser dividido em uma região não-difusa R_E e uma região difusa R_I de acordo com o valor de pertinência $\mu_{Escuro}(x,y)$ igual ou não a 1, i.e.,

$$Bloco_A = R_E \cup R_1$$

$$R_E = \{(x, y) | \mu_{Escuro}(x, y) = 1, (x, y) \in Bloco_A\}$$

$$R_1 = \{(x, y) | \mu_{Escuro}(x, y) < 1, (x, y) \in Bloco_A\}$$

De um modo semelhante, o bloco Claro, $Bloco_B$, é composto de uma região não-difusa R_W e uma região difusa R_2 de acordo com o valor de pertinência $\mu_{claro}(x, y)$, i.e.,

$$Bloco_B = R_W \cup R_2$$

$$R_W = \{(x, y) | \mu_{Claro}(x, y) = 1, (x, y) \in Bloco_B\}$$

$$R_2 = \{(x, y) | \mu_{Claro}(x, y) < 1, (x, y) \in Bloco_B\}$$

$H(Bloco_A)$ é composto de duas entropias. Uma é a entropia não-difusa de R_E , a outra é a entropia difusa de R_1 . A mesma situação é aplicada para a avaliação de $H(Bloco_B)$.

Portanto, as entropias dos $Bloco_A$ e $Bloco_B$ são definidas por:

$$H(Bloco_A) = H_D(R_1) + H_{n-D}(R_E) \tag{3.10}$$

$$H(Bloco_B) = H_D(R_2) + H_{n-D}(R_W) \tag{3.11}$$

Aplicando a Eq. (2.17) para avaliar a entropia difusa de $H_D(R_1)$ e $H_D(R_2)$, e a Eq. (2.16) para avaliar a entropia não-difusa de $H_{n-D}(R_E)$ e $H_{n-D}(R_W)$, nós obteremos as quatro entropias seguintes:

$$H_D(R_1) = - \sum_{(x,y) \in R_1} \mu_{Escuro}(x, y) \frac{f_{xy}}{\sum_{(x,y) \in R_1} f_{xy}} \ln \frac{f_{xy}}{\sum_{(x,y) \in R_1} f_{xy}} \tag{3.12}$$

$$H_{n-D}(R_E) = - \sum_{(x,y) \in R_E} \frac{f_{xy}}{\sum_{(x,y) \in R_E} f_{xy}} \ln \frac{f_{xy}}{\sum_{(x,y) \in R_E} f_{xy}} \quad (3.13)$$

$$H_D(R_2) = - \sum_{(x,y) \in R_2} \mu_{Escuro}(x,y) \frac{f_{xy}}{\sum_{(x,y) \in R_{21}} f_{xy}} \ln \frac{f_{xy}}{\sum_{(x,y) \in R_2} f_{xy}} \quad (3.14)$$

$$H_{n-D}(R_W) = - \sum_{(x,y) \in R_W} \frac{f_{xy}}{\sum_{(x,y) \in R_W} f_{xy}} \ln \frac{f_{xy}}{\sum_{(x,y) \in R_W} f_{xy}} \quad (3.15)$$

onde f_{xy} é o elemento no histograma 2D que representa o número de ocorrência do par (x,y) . As funções de pertinências $\mu_{claro}(x,y)$ e $\mu_{Escuro}(x,y)$ são definidas nas Eq. (2.14) e (2.15), respectivamete. Deve ser notado que a probabilidade $\frac{f_{xy}}{\sum f_{xy}}$

computada nas quatro regiões são independentes uma das outras.

MÉTODO PROPOSTO

4.1 Introdução

Neste capítulo será apresentada uma descrição completa do método de binarização de imagem proposto. Esse método tem por objetivo associar informações relevantes da imagem, tais como, distribuição dos níveis de cinza, média local dos níveis de cinza, e orientação do gradiente dos pontos da imagem. Para isso, em uma primeira etapa, são determinados os limiares (níveis de cinza, média local) através dos procedimentos descritos pelo método 2D difuso (ver Capítulo 3); em seguida, um algoritmo de detecção de bordas, que utiliza a distribuição orientada do gradiente, encontra as bordas da imagem; então, finalmente é realizada a binarização da imagem associando todas essas informações.

Na Seção 4.2 é apresentada uma breve introdução à detecção de bordas. Na Seção 4.3 é apresentado um teste visual (subjetivo) para determinar um limiar variável, que indica quais são os mínimos valores de gradiente, para cada nível de cinza, que podem ser discriminados pelo olho humano. Na Seção 4.4 é feita uma descrição do algoritmo de detecção de bordas. E por último, na Seção 4.5 é apresentado o processo de binarização da imagem.

4.2 Breve Introdução à Detecção de Bordas

Detecção de bordas é uma etapa importante em muitos sistemas de análise de imagem, onde as características das bordas são usadas para representar várias propriedades do objeto. Atualmente muitos esquemas de detecção de bordas usam a informação da variação da intensidade para identificar bordas [18]. Há basicamente duas diferentes abordagens dentro dessa categoria. Uma é baseada na derivada de primeira ordem, na qual um ponto é considerado como um ponto de borda se seu gradiente é relativamente alto. A outra faz uso da derivada segunda, que executa detecção de bordas identificando os cruzamentos por zero na derivada de segunda ordem da imagem original. Esses métodos são muito sensíveis ao ruído da imagem digital. Assim, para estabilizar a performance destes procedimentos, um filtro passa-baixas pode ser usado para suavizar a imagem antes da aplicação do operador de gradiente.

Neste trabalho, nós utilizamos um método que utiliza a informação da orientação e a da magnitude do gradiente da imagem para detecção de bordas [22]. Dada uma imagem, primeiro classifica-se a vizinhança de cada ponto em um dos seguintes padrões: constante, orientado, mesclado ou texturizado. Pontos com vizinhanças constantes ou texturizadas são considerados pontos não-borda. Um ponto com alto gradiente é considerado ponto de borda somente se as amostras no seu entorno têm a mesma orientação (uma borda direta); nesse caso, ainda é necessário fazer um teste para determinar se o gradiente é máximo local. Pontos cuja vizinhança tem duas orientações (uma borda mista), são classificados como pontos de borda.

4.3 Teste Visual para JND

O primeiro passo no algoritmo de detecção de bordas é determinar se um bloco pode ser considerado como constante ou não de acordo com sua variação de intensidade. É bem conhecido que o olho humano possui diferentes limiares de distinção sob diversas condições do fundo da imagem. A “just noticeable difference” (JND) depende da intensidade da luminância do fundo, e também, em um menor grau da intensidade da luminância circunvizinha. Conseqüentemente, em vez de usar um valor de limiar fixo para a imagem inteira, usa-se um limiar que varia de acordo com a intensidade do fundo.

A JND é diretamente proporcional à intensidade do fundo. No entanto, esta relação é falsa para o intervalo $[x_1, x_2]$ (ver Fig. 4.1) de valor médio de nível de cinza. O limiar visual é menor nesse intervalo e maior nas regiões claras e escuras. Um complicador adicional é que a luminância percebida na tela de um monitor tem uma relação não-linear com o valor da intensidade da imagem digital. Essa relação depende das características da tela do monitor, da iluminação ambiente e da sensibilidade do observador. A seguir, é descrito o teste visual apresentado em [22].

O teste é realizado selecionando alguns observadores para examinar uma seqüência de padrões. Cada padrão é composto por um conjunto ordenado de quadrados sobre um fundo uniforme. O fundo tem uma determinada intensidade I , que difere de cada um dos padrões. O observador determina o primeiro quadro que aparece diferente do fundo. Se o primeiro quadro visível varia ΔI em relação ao fundo, então ΔI é definido como o JND para esta intensidade de fundo.

Os resultados obtidos por diversos observadores são mostrados na Fig. 4.1. As linhas pontilhadas mostram o resultado para cada um dos observadores; podemos notar

que o valor JND varia sensivelmente com cada um. A linha contínua foi usada no algoritmo de detecção de bordas para prover o valor limiar necessário para determinar se o ponto pode, ou não, ser classificado como constante. Um modelo experimental que descreve aproximadamente este efeito é dado por [22]:

$$JND(I) = \begin{cases} -0.85I + 40 & ,0 \leq I \leq 40 \\ 6 & ,40 \leq I \leq 100 \\ 0.09I - 3 & ,100 \leq I \leq 255 \end{cases}$$

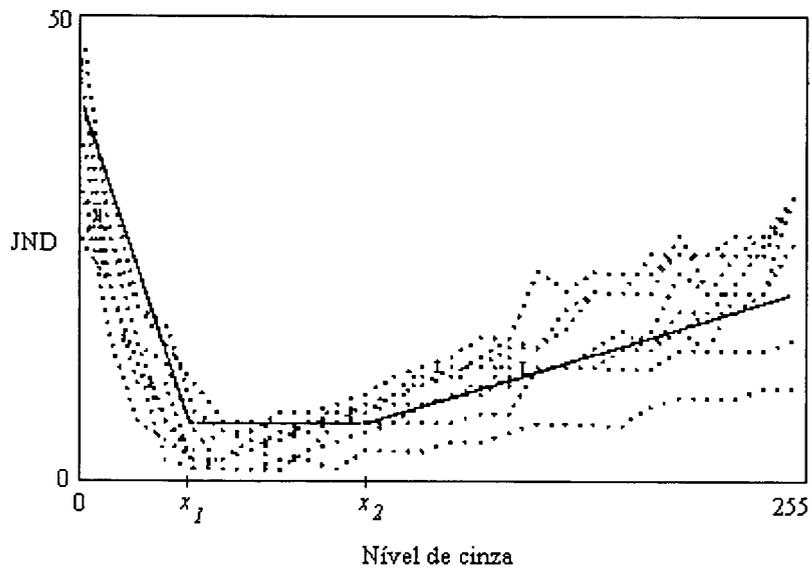


Fig. 4.1 - "Just noticeable difference" (JND).

4.4 Descrição do Algoritmo de Detecção de Bordas

O fluxograma do algoritmo de detecção de bordas proposto é apresentado na Fig. 4.2. Para cada *pixel*, primeiro avaliamos se o bloco que contém esse *pixel* pode ser considerado como constante. Para isso, comparamos a diferença máxima absoluta dentro do bloco com o valor *just noticeable difference* (JND) [22] multiplicado por t_1 (que controla a variação do limiar JND). Se a diferença é menor do que esse valor, então o bloco é considerado constante e o *pixel* é classificado como *pixel* não-borda. Senão, a classificação do bloco pode ser considerada orientada, mesclada ou texturizada. Isso é realizado obtendo-se a magnitude do gradiente e a orientação de cada *pixel* do bloco. Determinando-se o número de ocorrências do módulo do gradiente para cada orientação, obtém-se um histograma denominado histograma de orientação do gradiente. Se o histograma tem um único pico em uma determinada orientação, o bloco é considerado como orientado naquele sentido. Se há dois ou mais picos no histograma, o bloco pode conter vários fragmentos de linhas em diferentes direções, como, por exemplo, um canto ou cruzamento de linhas, e, assim, o bloco é considerado mesclado. Caso contrário, o bloco terá orientação igualmente distribuída em todas as direções, que é a característica de padrões de texturas irregulares.

Em nossas simulações, armazenamos o valor do maior pico do histograma de orientação do gradiente, na variável h_{max} e o valor do segundo maior pico, na variável h_{max2} . Se $h_{max} < t_2$, o *pixel* é considerado pertencente a um bloco texturizado (onde t_2 é um parâmetro usado como limiar para classificar um *pixel* como candidato, ou não, a borda); senão, se $h_{max2} \leq t_3 h_{max}$, podemos classificar o *pixel* como pertencente a um bloco

orientado (onde t_3 é um parâmetro usado como limiar para classificar se o bloco tem uma única orientação); senão, se $h_{max2} \geq t_2$, então o *pixel* é classificado como pertencente a um bloco mesclado (*pixel* de borda mista), senão será considerado como pertencente a um bloco texturizado.

Agora, para um *pixel* dentro de um bloco orientado, observamos a variação do gradiente no sentido ortogonal à orientação, determinando assim se o *pixel* é um máximo ou mínimo local. Para isso, a intensidade média, f_0 , calculada através dos *pixels* sobre a linha central da direção ortogonal à orientação atual, e das quatro linhas vizinhas, f_{-2}, f_{-1}, f_1, f_2 (duas em cada lado) são determinadas. O *pixel* é considerado como um *pixel* de borda direta se:

$$f_1 - f_{-1} > \max\{f_2 - f_0, f_0 - f_{-2}\}$$

ou

$$f_1 - f_{-1} < \min\{f_2 - f_0, f_0 - f_{-2}\}$$

A informação do gradiente, necessária no modelo de classificação, pode ser obtida usando diferentes operadores de gradiente. Em nossas simulações, usamos o operador de Sobel [18,22]. Mais especificamente, a magnitude m e a direção α do gradiente são determinadas por:

$$m = (dx + dy) / 8$$

$$\theta = Q(\arctan(dx / dy))$$

onde dx e dy são os gradientes vertical e horizontal obtidos pelo operador de Sobel; $Q[\circ]$ corresponde ao operador de quantização.

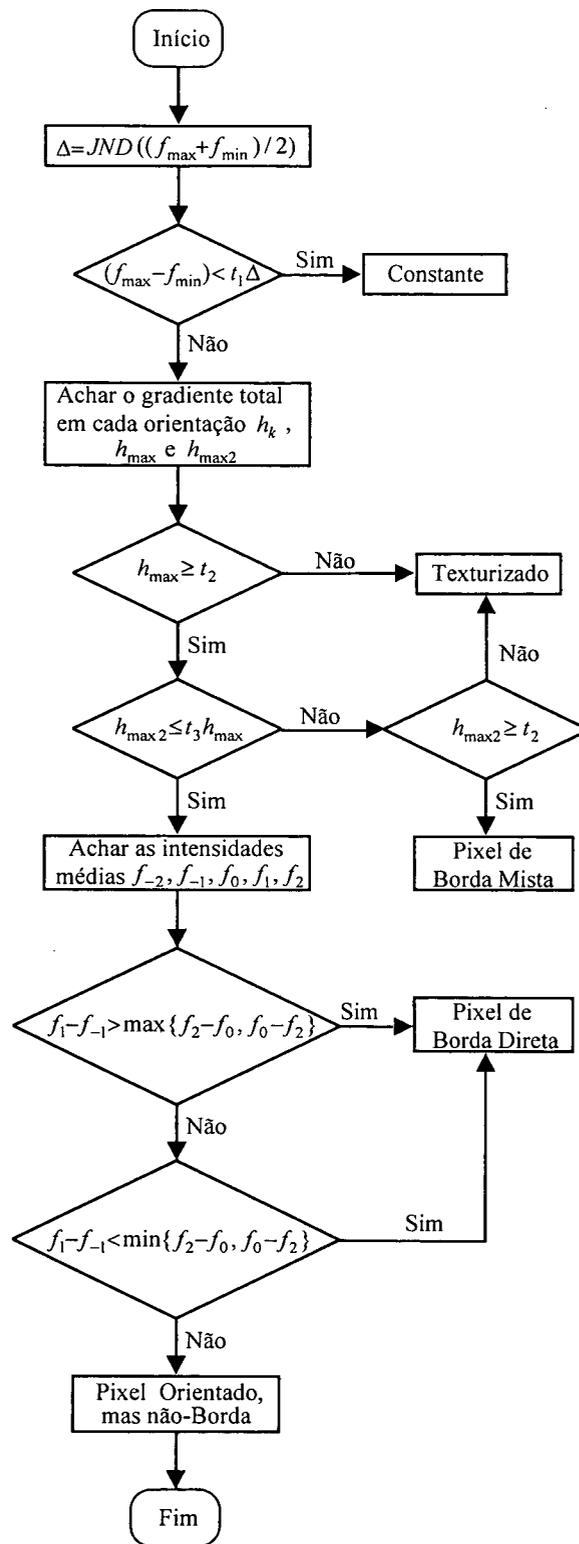


Fig. 4.2 - Fluxograma do Algoritmo de Detecção de Bordas.

4.5 Binarização através do Método Proposto

No processo de binarização proposto, primeiro é determinado um vetor limiar (t, s) através do método de referência 2D Difuso, discutido no capítulo anterior; em seguida obtém-se a imagem binária $b(x, y)$ das bordas utilizando o algoritmo de detecção de bordas apresentado na Fig. 4.2. Em nossas simulações, constatamos que um adequado limiar t para a intensidade dos níveis de cinza, associado à informação contextual da média local e da informação das bordas, resulta em uma imagem binária de qualidade superior aos outros métodos, salvo algumas exceções que serão abordadas no próximo capítulo. A extração do bloco escuro (conjunto objeto ou fundo) é expressa por:

$$f_{t,s,b}(x, y, \text{escuro}) = \begin{cases} 1 & , f(x, y) \geq t \cup g(x, y) \geq s \cup b(x, y) \\ 0 & , \text{outros} \end{cases} \quad (4.1)$$

onde $f(x, y)$ corresponde à função intensidade da imagem no ponto (x, y) ; $g(x, y)$ é a média local de $f(x, y)$ definida pela Eq. (2.3), e $b(x, y)$ é a imagem binária obtida pelo algoritmo de detecção de bordas.

Um ponto será classificado como escuro se sua intensidade de nível de cinza for maior ou igual ao limiar t , ou se sua média local for maior ou igual ao limiar s , ou ainda, se for considerado uma borda direta ou uma borda mista.

Inversamente, podemos extrair a classe claro modificando a Eq. (4.1) para:

$$f_{t,s,b}(x, y, \text{claro}) = \begin{cases} 0 & , f(x, y) < t \cup g(x, y) < s \cup b(x, y) \\ 1 & , \text{outros} \end{cases} \quad (4.2)$$

Dessa forma, um ponto será considerado claro se sua intensidade de nível de cinza for menor que o limiar t , ou se sua média local for menor que o limiar s , ou ainda, se for considerado uma borda direta ou uma borda mista.

RESULTADOS EXPERIMENTAIS**5.1 Introdução**

Neste capítulo são apresentados resultados obtidos na binarização de imagens monocromáticas, utilizando o algoritmo proposto e outros apresentados na literatura como referência.

Em seguida, são discutidas algumas restrições observadas no algoritmo proposto, assim como algumas propostas para superá-las.

5.2 Binarização da Imagem “TIFFANY”

Essa imagem (Fig. 5.1) apresenta um histograma de níveis de cinza com valores bastante altos, conforme mostra a Fig. 5.2. A Fig. 5.3 mostra seu respectivo histograma 2D (histograma bidimensional - (nível de cinza, média local)). Na Fig. 5.4 podemos observar o resultado obtido pelo método 1D [5]; o limiar encontrado foi 157. A Fig. 5.5 mostra a imagem binária do método 1D que usa lógica difusa [15]; o limiar encontrado foi 217. A Fig. 5.6 apresenta o resultado obtido do método 2D [8]; os limiares encontrados foram (162, 218). A Fig. 5.7 mostra a imagem binária obtida pelo método 2D usando lógica difusa [20]; cujos limiares são (195, 195). Na Fig. 5.8 apresentamos o resultado obtido pelo método proposto; esta imagem binária foi obtida com os limiares (195, 195) do método 2D usando lógica difusa, adicionando as bordas encontradas.

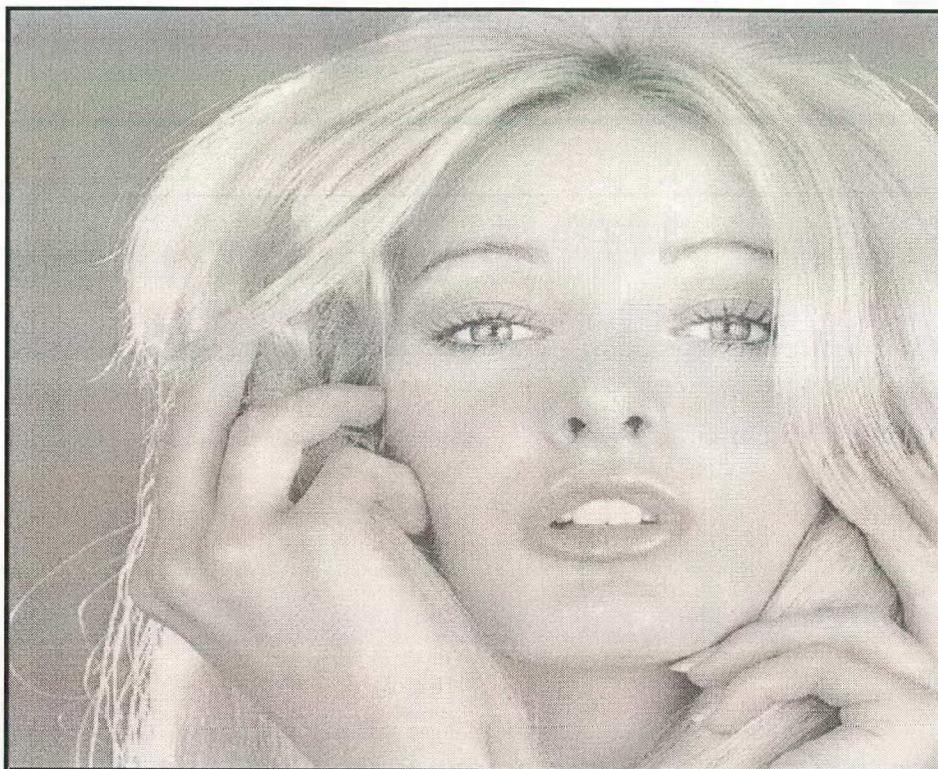


Fig. 5.1 - Imagem Tiffany em níveis de cinza.

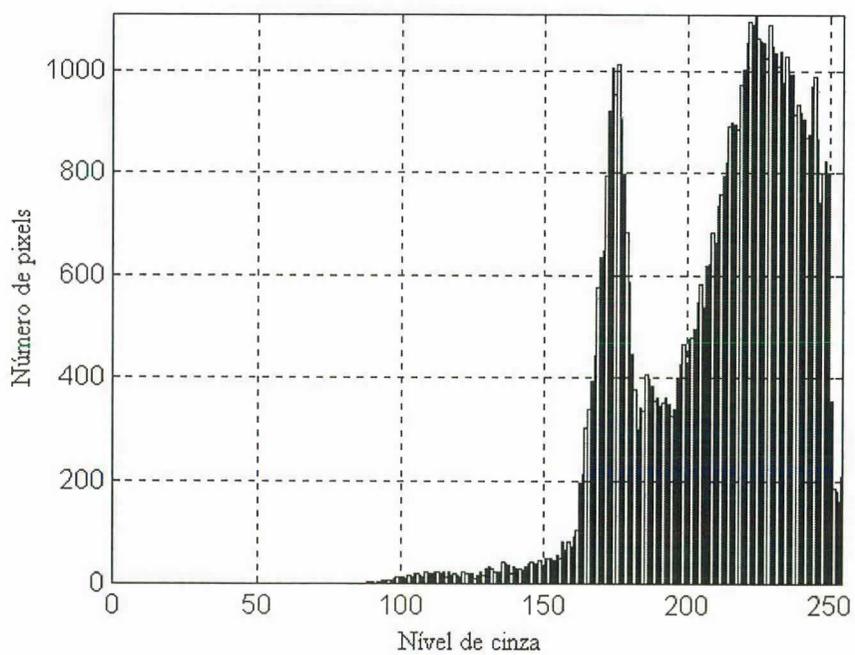


Fig. 5.2 - Histograma da distribuição dos níveis de cinza da imagem Tiffany.

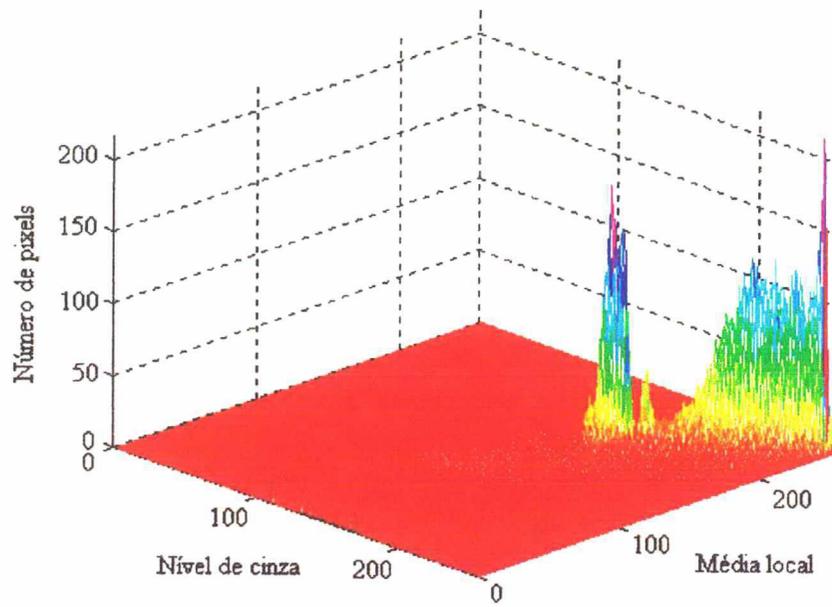


Fig. 5.3 - Histograma 2D da imagem Tiffany.

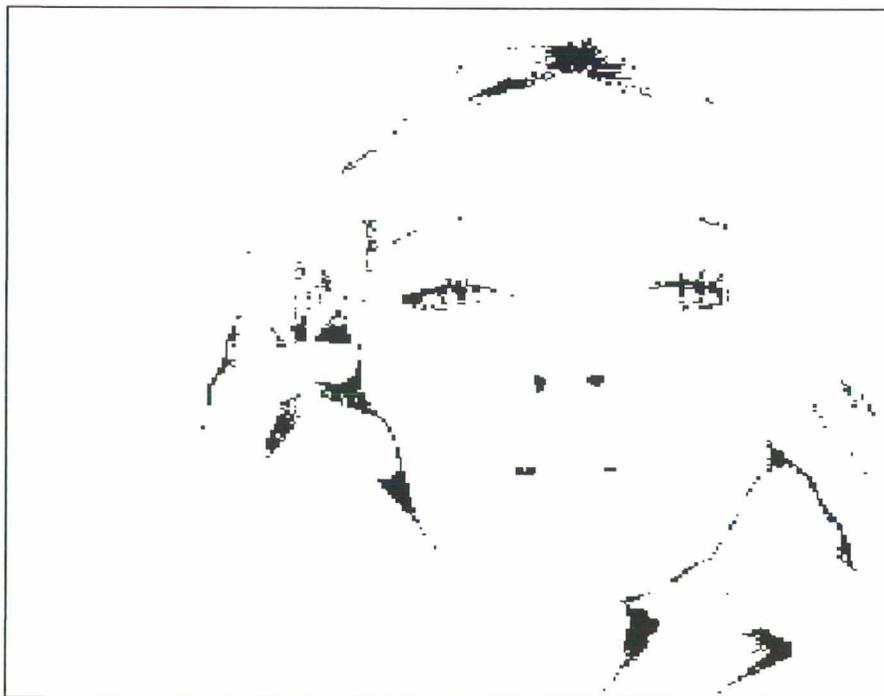


Fig. 5.4 - Imagem binária obtida do método 1D [5].



Fig. 5.5 - Imagem binária obtida do método 1D utilizando lógica difusa [15].



Fig. 5.6 - Imagem binária obtida do método 2D [8].



Fig. 5.7 - Imagem binária obtida pelo método 2D utilizando lógica difusa [20].



Fig. 5.8 - Imagem binária obtida pelo método proposto.

5.3 Comentários sobre os Resultados Obtidos da Imagem Tiffany

Essa imagem consiste de 256×256 pixels, cada pixel com nível de cinza representado entre 0 e 255. Para a operação de média local, foi utilizado uma janela de 5×5 .

O método baseado na entropia unidimensional (método 1D) [5], apresentou um resultado não satisfatório na extração do objeto; podemos notar que os detalhes do cabelo, mãos e rosto, não foram representados na imagem binária obtida, Fig. 5.4.

O método baseado no índice de difusão (método 1D difuso) [15], apresentou um bom resultado na classificação da classe objeto. Porém, erros de classificação podem ser observados na Fig. 5.5; o nariz, a boca, o pescoço e as mãos, possuem manchas indesejáveis.

O método baseado na entropia bidimensional (método 2D) [8], apresentou um resultado melhor em relação ao método 1D [5]. Isto se deve a informação local (ou contextual) de cada ponto, obtida através da média local. No entanto, podemos perceber, Fig. 5.6, regiões em que há erro de extração; o cabelo, o nariz, a boca, o pescoço e as mãos, possuem densas manchas indesejáveis.

O método baseado na entropia difusa 2D [20], apresentou um resultado melhor em relação ao método 2D [8]. Isto se deve ao fato de que dentro de uma região de incerteza no histograma 2D, a lógica difusa executa uma melhor ponderação em cada par (nível de cinza, média local). Porém, podemos notar (Fig. 5.7) a ausência de extração de detalhes importantes da imagem original; os detalhes do cabelo, dos dedos, da boca, nariz e sobrancelha, não foram extraídos corretamente.

O método proposto, apresentou um melhor desempenho na extração do objeto (detalhes do cabelo, mãos e rosto). Isso se deve à associação de informações relevantes da imagem; pontos do conjunto objeto que não foram classificados pelo seu valor de nível de cinza, podem ser classificados pelo seu valor de média local, ou ainda pelo módulo e orientação do gradiente local.

5.4 Binarização da Imagem “Lenna”

Essa imagem, Fig. 5.9, apresenta um histograma multimodal, conforme mostra a Fig. 5.10. A Fig. 5.11 mostra seu histograma 2D. Na Fig. 5.12 podemos observar o resultado obtido usando o método 1D [5]; o limiar encontrado foi 121. A Fig. 5.13 mostra a imagem binária obtida pelo método 1D usando lógica difusa; o limiar encontrado foi 101. A Fig. 5.14 apresenta o resultado obtido pelo método 2D [8], os limiares encontrados foram (95,155). A Fig. 5.15 mostra a imagem binária obtida pelo método 2D usando lógica difusa, cujos limiares são (111, 111). Na Fig. 5.16 apresentamos o resultado obtido para o método proposto; esta imagem binária foi obtida com os limiares (111, 111) do método 2D usando lógica difusa, adicionando as bordas detectadas.



Fig. 5.9 - Imagem Lenna em níveis de cinza.

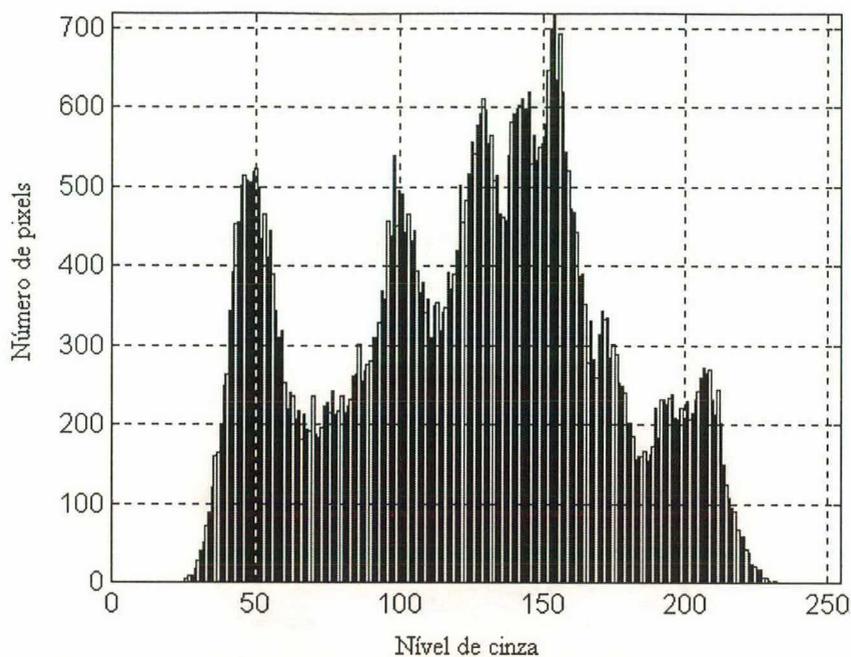


Fig. 5.10 - Histograma da distribuição dos níveis de cinza para a imagem Lenna.

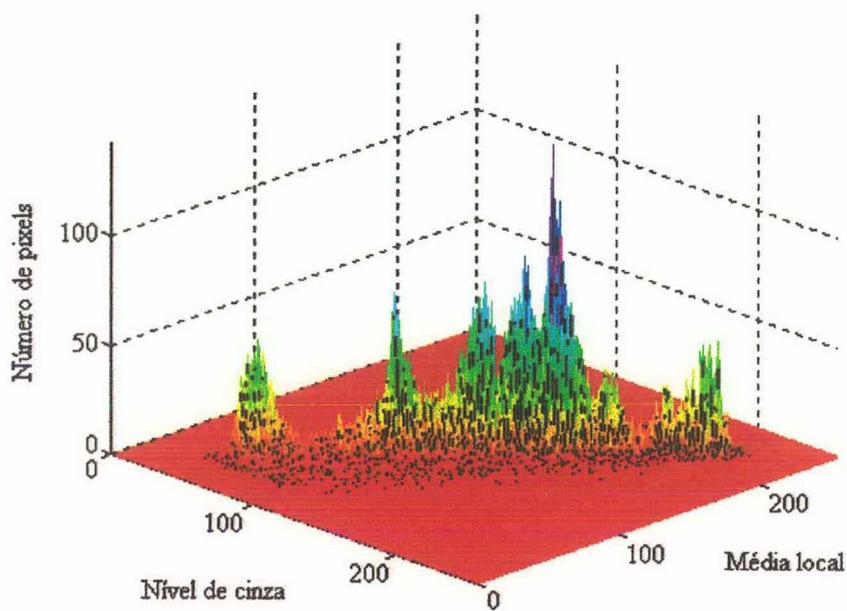


Fig. 5.11 - Histograma 2D da imagem Lenna.



Fig. 5.12 - Imagem binária obtida pelo método 1D [5].



Fig. 5.13 - Imagem binária obtida pelo método 1D utilizando lógica difusa [15].



Fig. 5.14 - Imagem binária obtida pelo método 2D [8].



Fig. 5.15 - Imagem binária obtida pelo método 2D utilizando lógica difusa [20].



Fig. 5.16 - Imagem binária obtida pelo método proposto.

5.5 Comentários sobre os Resultados Obtidos da Imagem Lenna

Essa imagem consiste de 256×256 pixels, cada pixel com nível de cinza representado entre 0 e 255. Para a operação de média local, foi utilizado uma janela de 5×5 .

O método baseado na entropia unidimensional (método 1D) [5] apresentou um bom resultado na extração do objeto. No entanto, podemos notar (Fig. 5.12), que alguns detalhes do chapéu e nariz, boca e queixo, não foram bem classificados

O método baseado no índice de difusão (método 1D difuso) [15], apresentou um bom resultado na classificação da classe objeto. Porém, erros de classificação podem ser observados na Fig. 5.13 (os detalhes do chapéu, nariz, boca e queixo).

O método baseado na entropia bidimensional (método 2D) [8] apresentou um resultado pior em relação ao método 1D. Isso é um bom exemplo de que a informação

local (ou contextual) de cada ponto, obtida através da média local, pode gerar um erro de extração para imagens com muitos detalhes; podemos notar (Fig. 5.14) que a imagem binária obtida por esse método, apresenta muitas manchas inexistentes.

O método baseado na entropia difusa 2D [20], apresentou um resultado melhor em relação ao método 2D [8]. Isto se deve ao fato de que dentro de uma região de incerteza no histograma 2D, a lógica difusa executa uma melhor ponderação em cada par (nível de cinza, média local). Porém, podemos notar (Fig. 5.15) a ausência de extração de detalhes importantes (contornos do chapéu, detalhes do nariz, boca e queixo) da imagem original.

O método proposto, apresentou um melhor desempenho na extração do objeto (detalhes do chapéu e rosto). Isso se deve à associação de informações relevantes da imagem; pontos do conjunto objeto que não foram classificados pelo seu valor de nível de cinza, podem ser classificados pelo seu valor de média local, ou ainda pelo módulo e orientação do gradiente local. No entanto, observando a Fig. 5.16, é possível notar que alguns detalhes ainda precisam ser melhor extraídos, e que ainda são necessários esforços para reduzir o surgimento de artefatos indesejáveis.

5.4 Binarização da Imagem “Lenna”

Essa imagem, Fig. 5.9, apresenta um histograma multimodal, conforme mostra a Fig. 5.10. A Fig. 5.11 mostra seu histograma 2D. Na Fig. 5.12 podemos observar o resultado obtido usando o método 1D [5]; o limiar encontrado foi 121. A Fig. 5.13 mostra a imagem binária obtida pelo método 1D usando lógica difusa; o limiar encontrado foi 101. A Fig. 5.14 apresenta o resultado obtido pelo método 2D [8], os limiares encontrados foram (95,155). A Fig. 5.15 mostra a imagem binária obtida pelo método 2D usando lógica difusa, cujos limiares são (111, 111). Na Fig. 5.16 apresentamos o resultado obtido para o método proposto; esta imagem binária foi obtida com os limiares (111, 111) do método 2D usando lógica difusa, adicionando as bordas detectadas.



Fig. 5.9 - Imagem Lenna em níveis de cinza.

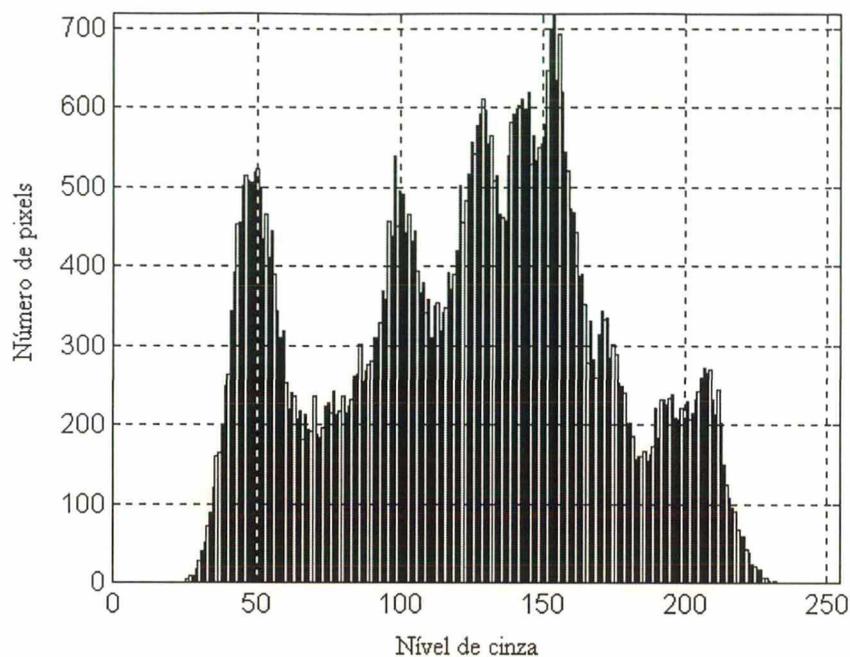


Fig. 5.10 - Histograma da distribuição dos níveis de cinza para a imagem Lenna.

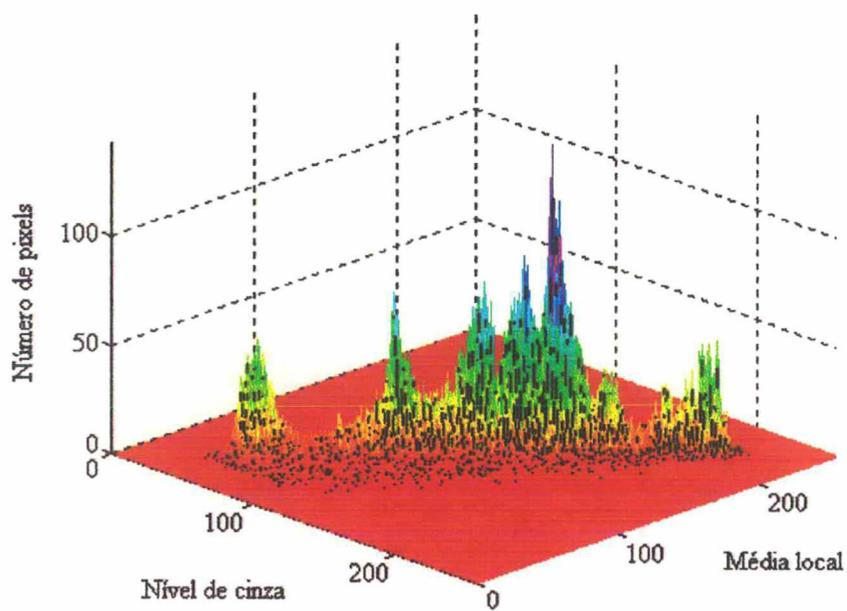


Fig. 5.11 - Histograma 2D da imagem Lenna.



Fig. 5.12 - Imagem binária obtida pelo método 1D [5].



Fig. 5.13 - Imagem binária obtida pelo método 1D utilizando lógica difusa [15].



Fig. 5.14 - Imagem binária obtida pelo método 2D [8].



Fig. 5.15 - Imagem binária obtida pelo método 2D utilizando lógica difusa [20].



Fig. 5.16 - Imagem binária obtida pelo método proposto.

5.5 Comentários sobre os Resultados Obtidos da Imagem Lenna

Essa imagem consiste de 256×256 pixels, cada pixel com nível de cinza representado entre 0 e 255. Para a operação de média local, foi utilizado uma janela de 5×5 .

O método baseado na entropia unidimensional (método 1D) [5] apresentou um bom resultado na extração do objeto. No entanto, podemos notar (Fig. 5.12), que alguns detalhes do chapéu e nariz, boca e queixo, não foram bem classificados

O método baseado no índice de difusão (método 1D difuso) [15], apresentou um bom resultado na classificação da classe objeto. Porém, erros de classificação podem ser observados na Fig. 5.13 (os detalhes do chapéu, nariz, boca e queixo).

O método baseado na entropia bidimensional (método 2D) [8] apresentou um resultado pior em relação ao método 1D. Isso é um bom exemplo de que a informação

local (ou contextual) de cada ponto, obtida através da média local, pode gerar um erro de extração para imagens com muitos detalhes; podemos notar (Fig. 5.14) que a imagem binária obtida por esse método, apresenta muitas manchas inexistentes.

O método baseado na entropia difusa 2D [20], apresentou um resultado melhor em relação ao método 2D [8]. Isto se deve ao fato de que dentro de uma região de incerteza no histograma 2D, a lógica difusa executa uma melhor ponderação em cada par (nível de cinza, média local). Porém, podemos notar (Fig. 5.15) a ausência de extração de detalhes importantes (contornos do chapéu, detalhes do nariz, boca e queixo) da imagem original.

O método proposto, apresentou um melhor desempenho na extração do objeto (detalhes do chapéu e rosto). Isso se deve à associação de informações relevantes da imagem; pontos do conjunto objeto que não foram classificados pelo seu valor de nível de cinza, podem ser classificados pelo seu valor de média local, ou ainda pelo módulo e orientação do gradiente local. No entanto, observando a Fig. 5.16, é possível notar que alguns detalhes ainda precisam ser melhor extraídos, e que ainda são necessários esforços para reduzir o surgimento de artefatos indesejáveis.

5.6 Limitações da Técnica Proposta

5.6.1 Pseudo Limiar 2D

Como já foi mencionado, a entropia é uma função que mede a quantidade de informação de um sistema. No nosso caso particular, a tentativa é encontrar a máxima informação contida nos conjuntos objeto e fundo.

Em nosso trabalho, simulações realizadas constataram que as imagens cujo histograma concentra muita informação em poucos níveis de cinza, possuem baixo valor de entropia e portanto, os métodos baseados na maximização da entropia da imagem não fornecem limiares confiáveis para a classificação do objeto. Nesses casos, sugerimos que se faça uma alteração de histograma, de modo a deixá-lo mais uniforme, visto que a máxima entropia equivale a um histograma uniformemente distribuído [18].

5.6.1.1 Alteração de Histograma

Nós temos encontrado na literatura muitas técnicas para alteração de histograma [18]. A seguir, nós utilizaremos uma dessas técnicas para alargamento de histograma, que será aplicada em um exemplo, para demonstrar que um melhor limiar pode ser obtido quando o histograma da imagem se torna mais uniforme [18].

A idéia básica é alargar a faixa dinâmica dos níveis de cinza da imagem processada. A função mapeamento é definida pela Eq. 5.1. A localização dos pontos (r_1, s_1) e (r_2, s_2) controlam a forma da função mapeamento. Se $r_1 = s_1$ e $r_2 = s_2$, a função não produz mudanças nos níveis de cinza. Se $r_1 = r_2$ e $s_1 = 0$ e $s_2 = L - 1$ a

função produz uma imagem binária. Valores intermediários de (r_1, s_1) e (r_2, s_2) produzem vários graus de dispersão dos níveis de cinza, afetando assim o contraste da imagem. Esta condição preserva a ordem dos níveis de cinza, prevenindo assim a criação de artefatos indesejáveis na imagem processada. A Fig. 5.17 mostra uma típica transformação de histograma de níveis de cinza. A variável r representa os atuais níveis de cinza e a variável s os novos níveis de cinza da imagem.

$$s = \begin{cases} a_1 \cdot r & , r < r_1 \\ a_2 \cdot r + b_2 & , r_1 \leq r \leq r_2 \\ a_3 \cdot r + b_3 & , r_2 \leq r \leq L - 1 \end{cases} \quad (5.1)$$

onde a_1, a_2 e a_3 são os coeficientes angulares e b_2 e b_3 são os coeficientes lineares das retas.

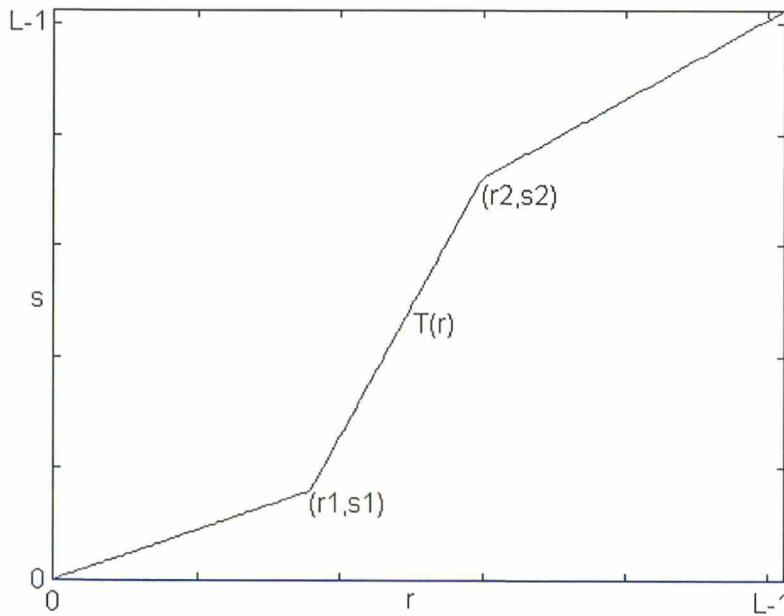


Fig. 5.17 - Transformação típica de um histograma de imagem.

Como exemplo, vamos utilizar a imagem “Couple”, Fig. 5.18. Podemos notar, através da Fig. 5.19 (histograma 1D), que a maior parte da informação de seu histograma está concentrada em um pequeno intervalo, prejudicando assim uma boa detecção do limiar através de técnicas baseadas na entropia. A Fig. 5.20 mostra a imagem binária resultante da segmentação binível da imagem original. As Figs. 5.21 e 5.22 mostram o histograma alterado e a imagem modificada, respectivamente, resultante do alargamento do histograma. A imagem binária, Fig. 5.23, resultante da binarização da imagem modificada, apresenta qualidade superior ao resultado obtido na binarização da imagem original.



Fig. 5.18 - Imagem “Couple” original.

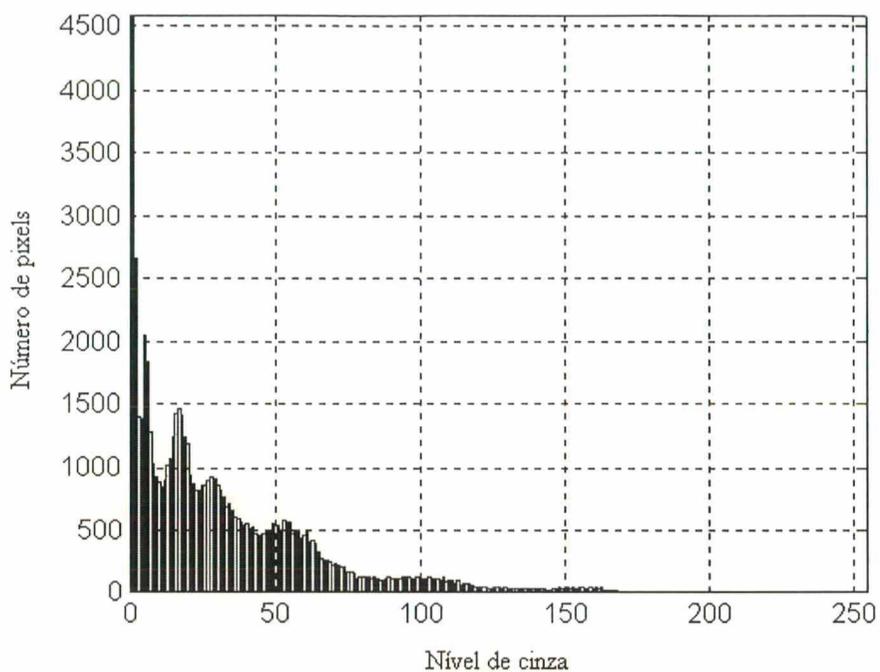


Fig. 5.19 - Histograma da distribuição dos níveis de cinza da imagem original.

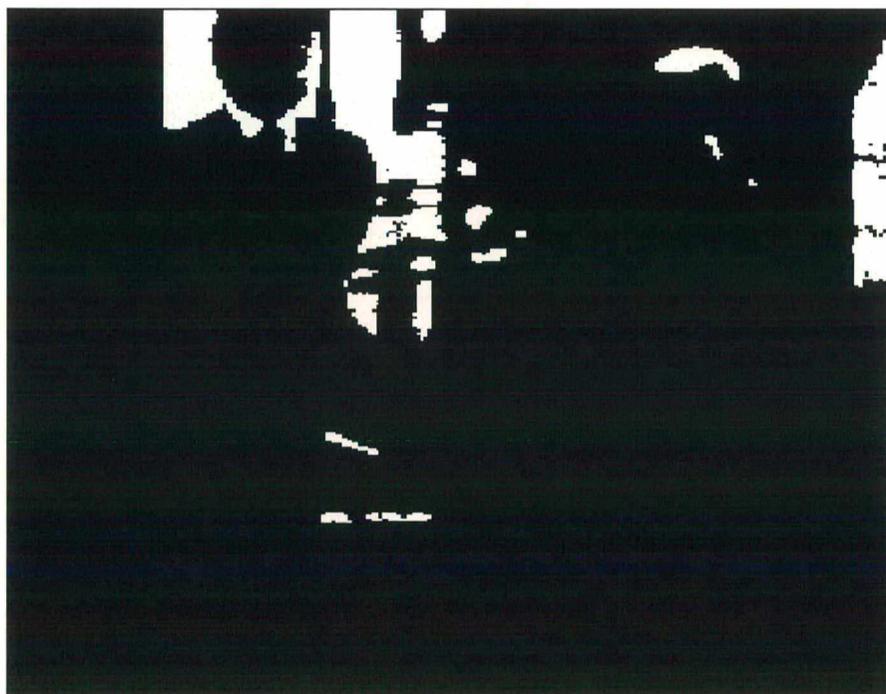


Fig. 5.20 - Imagem binária resultante da binarização da imagem original.

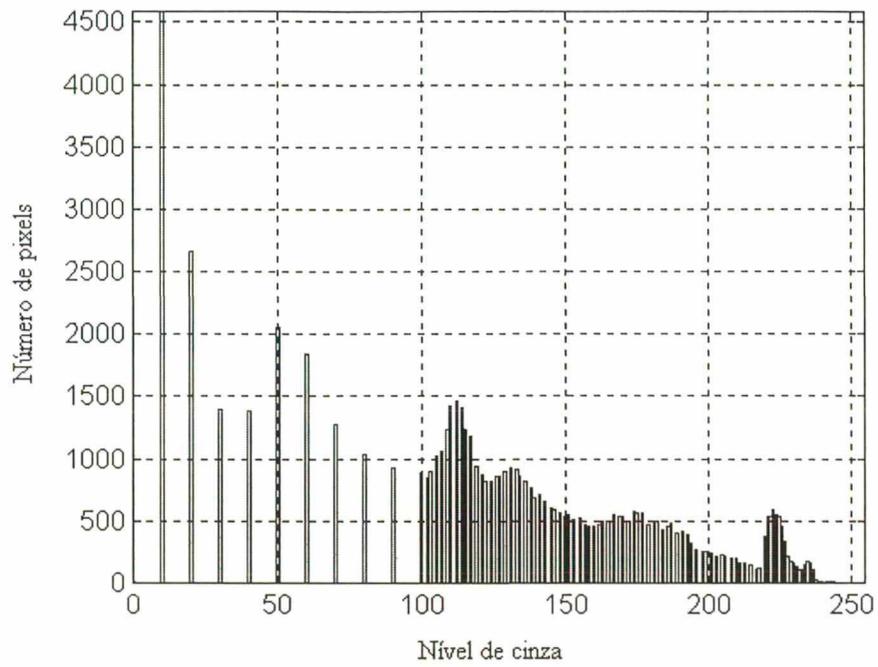


Fig. 5.21- Histograma alterado.



Fig. 5.22 - Imagem modificada resultante do alargamento do histograma.

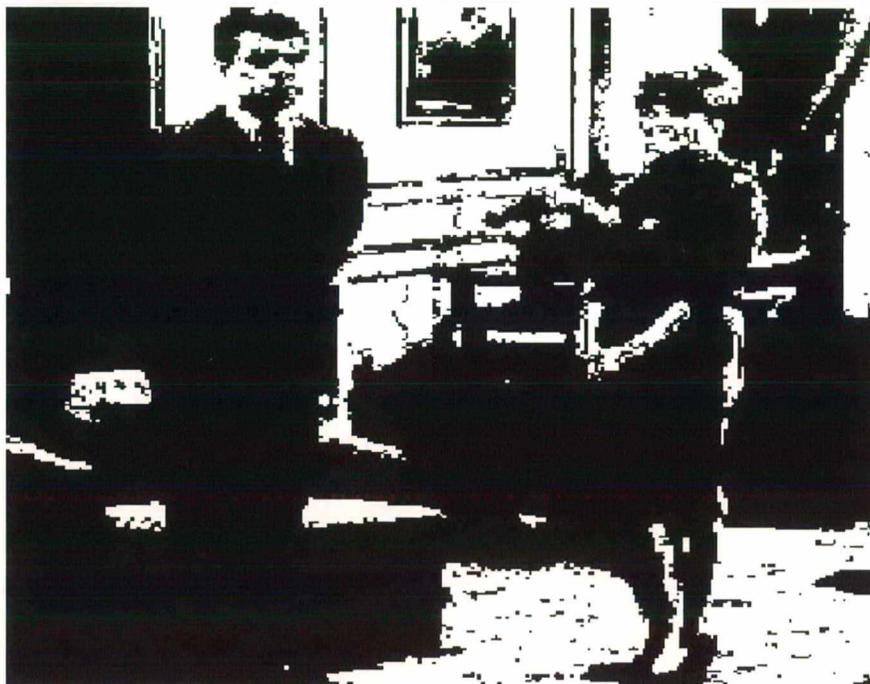


Fig. 5.23 - Imagem binária resultante da binarização da imagem modificada.

5.6.2 Pseudo Borda

Em algumas simulações, notamos que a imagem borda resultante apresentava falsas bordas ou a ausência de bordas existentes. Por ser a detecção de bordas realizada pelo gradiente local da imagem, alguns pontos borda não são detectados quando o limiar estabelecido é superior ao gradiente local desses pontos. Nesse caso, podemos diminuir o valor do limiar, mas isso também poderia gerar falsas bordas.

A imagem “Baboon”, Fig. 5.24, é uma típica imagem que gera esse tipo de problema. A região do cabelo apresenta altos valores de gradiente tanto para os pontos escuros como para os claros. Conseqüentemente, todos esses pontos serão detectados como borda. Podemos notar na imagem binária obtida pelo método proposto, mostrada na Fig. 5.25, que essa região apresenta vários pontos que não deveriam ser classificados como objeto. Nós propomos, como solução, recortar esta área e fazer um processamento separado, com limiares diferentes para as duas regiões. A Fig. 5.26 mostra o resultado obtido pelo método proposto, utilizando diferentes limiares; podemos notar uma sensível melhora na extração da região do cabelo e do contorno dos olhos.

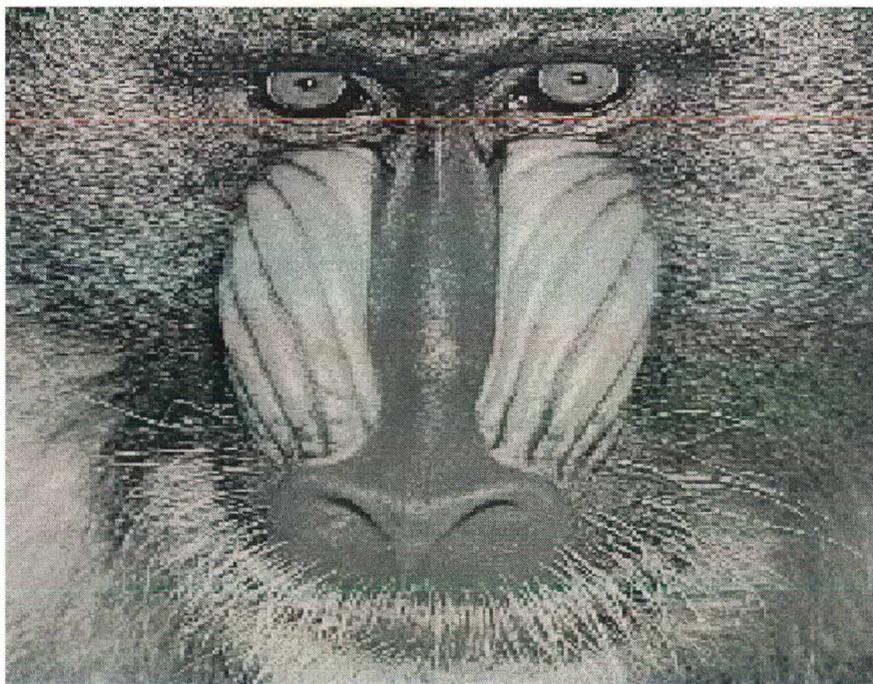


Fig. 5.24 - Imagem “baboon” original.

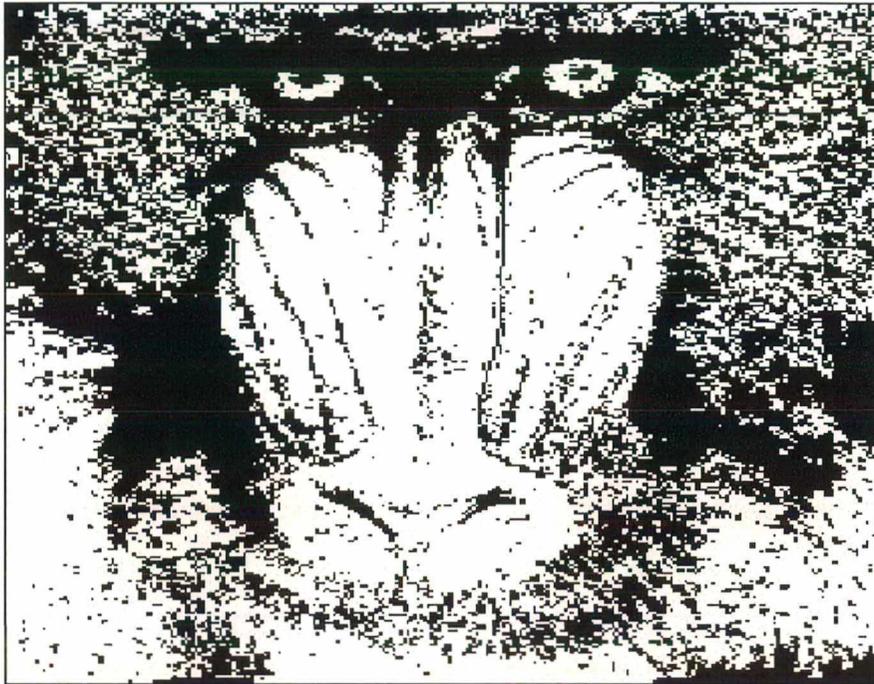


Fig. 5.25 - Imagem binária resultante com limiar único para a detecção de borda.



Fig. 5.26 - Imagem binária resultante com limiares diferentes para a detecção de borda.

CONCLUSÕES

Essa dissertação propõe um algoritmo para segmentação binível de imagem, utilizando entropia difusa bidimensional e distribuição orientada do gradiente. Isso é útil em sistemas de reconhecimento de padrões, onde se deseja classificar um determinado objeto.

A metodologia empregada visa uma melhor qualidade da imagem binária, que é obtida separando-se o objeto do fundo.

A lógica difusa tem sido bastante aplicada quando há necessidade de ponderar conceitos que carregam um certo grau de incerteza. Como a informação contida no histograma 2D da imagem, apresenta um região de forte ambigüidade, a utilização de funções de pertinência nessa região, melhora sensivelmente a classificação do objeto.

O conceito de entropia, tem sido largamente utilizado nas mais diferentes áreas; tendo como objetivo medir a quantidade de informação contida no sistema. A entropia difusa tem sido aplicada com sucesso, quando há um certo grau de incerteza presente em alguns elementos do sistema; assim, podemos obter uma medida mais precisa da informação existente no conjunto universo analisado.

Está comprovado que o olho humano utiliza diferentes limiares de nível de cinza para discriminar um ponto dos seus vizinhos; e que isso, é diretamente proporcional à intensidade do fundo e da vizinhança do ponto. Esse é o motivo que justifica a utilização do JND para determinar se um ponto pertence, ou não, a um bloco constante.

Os algoritmos de detecção de borda que não utilizam a orientação do gradiente, são muito sensíveis ao ruído, pois esse apresenta alto valor de gradiente, sendo assim, em muitas situações considerados como ponto de borda. No entanto, erros de detecção ainda são percebidos mesmo em algoritmos que utilizam a informação da orientação do gradiente.

Mais pesquisas com o objetivo de aperfeiçoar o algoritmo de detecção de bordas, são necessárias para se obter uma melhor classificação dos detalhes da imagem, o que reduziria os artefatos indesejáveis.

Os resultados experimentais mostraram que usando as informações presentes na intensidade dos níveis de cinza, na média local e na orientação da derivada local, podemos obter uma imagem binária de melhor qualidade quando comparada àquelas obtidas dos métodos que utilizam apenas uma dessas informações.

Uma sugestão para futuros trabalhos é usar o algoritmo proposto associado à outras informações da imagem; tais como, variância, correlação, dentre outras.

Outro trabalho que também deve ser explorado, é a procura de uma melhor extração de outras informações contidas no histograma 2D da imagem.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] J. S. Weszka, "A Survey of Threshold Selection Techniques", Computer Vision, Graphics, and Image Processing, Vol. 7, pp. 259-265, 1978.
- [2] S. K. Fu and J. K. Mu, "A Survey on Image Segmentation", Pattern Recognition, Vol. 13, pp. 3-16, 1981.
- [3] P. K. Sahoo, S. Soltani, A. K. C. Wong and Y. Chen, "A survey of Thresholding Techniques", Computer Vision, Graphics, and Image Processing, Vol. 41, pp. 233-260, 1988.
- [4] N. Otsu, "A Threshold Selection Method for gray-level Histograms", IEEE Trans. Systems Man Cybernet. SMC-9, N° 1, pp. 62-66, 1979.
- [5] J. N. Kapur, P. K. Sahoo and A. K. C. Wong, "A new method for gray-level picture thresholding using the entropy of the histogram", Computer Vision, Graphics, and Image Processing 29, pp. 273-285, 1985.
- [6] S. S. Reddi, S. F. Rundin, and H. R. Keshavan, "Na optimal threshold scheme for image segmentation", IEEE Trans. Systems Man Cybernet. SMC-14, N° 4, pp. 661-665, 1984.
- [7] W. Tsai, "Moment-Preserving Thresholding : A new approach", Computer Vision, Graphics, and Image Processing, Vol. 29, pp. 377-393, 1985.
- [8] A. S. Abutaleb, "Automatic Thresholding of Gray-Level Pictures Using Two-Dimensional Entropy", Computer Vision, Graphics, and Image Processing, Vol. 47, pp. 22-32, 1989.

- [9] A. D. Brink, "Thresholding of Digital Images Using Two-Dimensional Entropies", *Pattern Recognition*, Vol.25, N° 8, pp. 803-808, 1992.
- [10] W. T. Chen, C. H. Wen and C. W. Yang, "A Fast Two-Dimensional Entropic Thresholding Algorithm", *Pattern Recognition*, Vol. 27, No. 7, pp. 885-893, 1994.
- [11] Liang-Kai Huang and Mao-Jiun J. Wang, "Image Thresholding by Minimizing the Measures of Fuzziness", *Pattern Recognition*, Vol. 28, N° 1, pp. 41-51, 1995.
- [12] Zhiwei Zhao and H. D. Cheng, "Fuzzy Entropy Threshold Approach to Breast Cancer Detection", *Information Sciences* 4, pp. 49-56, 1995.
- [13] H. D. Cheng and Y. M. Lui, "Automatic Bandwidth Selection of Fuzzy Membership Functions", *Information Sciences* 103, pp. 1-21, 1997.
- [14] H. D. Cheng, Jim-Rong Chen and Jiguang Li, "Threshold Selection Based on Fuzzy c-Partition Entropy Approach", *Pattern Recognition*, Vol. 31, N° 7, pp. 857-870, 1998.
- [15] Orlando J. Tobias and Rui Seara, "Image Segmentation by Histogram Thresholding using Fuzzy Sets, *Pattern Recognition Letters*, 1999 (a ser publicado).
- [16] N. Ahuja and A. Rosenfeld, "A Note on the Use of Second-Order Gray-Level Statistics for Threshold Selection", *IEEE Trans. Systems Man Cybernet. SMC-8*, N° 12, pp. 895-898, 1978.

- [17] A. Kaufmann, *Introduction to the Theory of Fuzzy Subsets - Fundamental Theoretical Elements*, Academic Press, Vol. I, N.Y., 1980.
- [18] R.C. Gonzalez and R.E.Woods, *Digital Image Processing*, Addison-Wesley, Reading, MA, 1993.
- [19] L. A. Zadeh, "Probability Measures of Fuzzy Events", *Journal of Mathematical Analysis and Applications*, Vol. 23, pp. 421-427, 1968.
- [20] H. D. Cheng, Y. H. Chen and X. H. Jiang, "Thresholding Using Two-Dimensional Histogram and Fuzzy Entropy Principle", *IEEE Transaction on Image Processing*, 1999 (a ser publicado).
- [21] D. E. Goldberg, *Genetic Algorithm in Searching, Optimization, and Machine Learning*. Addison-Wesley, Reading, MA, 1989.
- [22] Yao Wang and Sanjit K. Mitra, "Edge Detection based on Orientation Distribution of Gradient Images", *Proceedings of the IEEE, International Conference on Acoustics, Speech, and Signal Processing*, Vol. 4, pp. 2569-2572, 1991.
- [23] Robert M. Haralick and K. Shanmugan, "Textural Feature for Image Classification", *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. SMC-3, N° 6, 1973.
- [24] Nikhil R. Pal and Sankar K. Pal, "Entropic Thresholding", *Signal Processing* 16, pp.97-108, 1989.