

CENTRO UNIVERSITÁRIO DA FEI  
LEANDRO CORREA

**ANÁLISE DISCRIMINANTE DA FRACTALIDADE EM IMAGENS DE ÍRIS**

São Bernardo do Campo

2010

LEANDRO CORREA

**ANÁLISE DISCRIMINANTE DA FRACTALIDADE EM IMAGENS DE ÍRIS**

Dissertação de Mestrado apresentada ao  
Centro Universitário da FEI para a obtenção  
do título de Mestre em Engenharia Elétrica,  
orientado pelo Prof. Dr. Carlos E. Thomaz

São Bernardo do Campo

2010

Correa, Leandro

Análise discriminante da fractalidade em imagens de íris / Leandro Correa. São Bernardo do Campo, 2010.

92 f. : il.

Dissertação - Centro Universitário da FEI.

Orientador: Prof. Dr. Carlos Eduardo Thomaz

1. Reconhecimento de Íris. 2. Fractal. 3. Dimensão Fractal. 4. Análise de Informação Redundante. 5. Discriminante. I. Thomaz, Carlos Eduardo, orient. II. Título.

CDU 681.3.06



Centro Universitário da FEI

# DEPÓSITO DE DISSERTAÇÃO

Departamento de Engenharia Elétrica

Mestrado

PGE-13

Eu, Leandro Correa, abaixo-assinado, tendo cumprido todo o programa de Mestrado no Curso de Pós-graduação em Engenharia Elétrica, anexo à presente 5 (cinco) exemplares da Dissertação intitulada: Análise Discriminante da Fractalidade em Imagens de Íris, formatados de acordo com as diretrizes publicadas pela Biblioteca do Centro Universitário da FEI juntamente com um disquete/CD contendo o resumo e o *abstract* da dissertação. Solicito ainda a autorização para apresentação da Dissertação perante a Comissão Julgadora.

  
\_\_\_\_\_  
Assinatura do Aluno

São Bernardo do Campo, 22 / 03 / 2010

Considero a Dissertação do meu orientado em condições de ser apresentada.

  
\_\_\_\_\_  
Assinatura do Orientador

São Bernardo do Campo, 22 / 03 / 2010

Situação Biblioteca: <u>nada consta</u>	
Situação Tesouraria: <u>nada consta</u>	
Visto	

RECEBIDO

22 1031 10

  
\_\_\_\_\_  
Pós-graduação

Aos meus pais, Marcos e Sônia, pelo esforço enorme para dar-me a melhor criação, à minha companheira e amiga, Eliane, aos meus irmãos Cristiano, Denis e William pelo apoio na realização dos meus sonhos.

## AGRADECIMENTOS

Inicialmente, gostaria de agradecer aos professores do Programa de Mestrado do Centro Universitário da FEI, em especial o professor Dr. Carlos Eduardo Thomaz pela paciência, compreensão e apoio para que este trabalho se realizasse. Gostaria de agradecer aos meus pais e irmãos, amigos e familiares pela dedicação, força, apoio e, principalmente, o amor. E por falar no amor, agradeço à minha amiga e companheira Eliane pela dedicação e apoio nos momentos de cansaço.

Gostaria de agradecer à Maryanna de Carvalho Alegro por fornecer o código-fonte que serviu de base para o cálculo das dimensões fractais das imagens de íris utilizando o método Área de Superfície de Prisma Triangular. E agradeço, também, à Maysa Macedo do Centro Brasileiro de Pesquisas Físicas (CBPF), por disponibilizar o código-fonte utilizado para calcular as dimensões fractais das imagens de íris utilizando o método *Box-Counting*.

*"...Ora, não percebeis que com os olhos alcançais toda a beleza do mundo? (...) Ó coisa admirável, superior a todas as outras criadas por Deus! (...) Que povos, que línguas poderão descrever completamente a sua função! O olho é a janela do corpo humano pela qual ele abre os caminhos e se deleita com a beleza do mundo. Por causa do olho, a alma se compraz em ficar presa ao corpo, pois sem ele essa prisão seria uma tortura."*

*Leonardo da Vinci (1452-1519)*

## RESUMO

O reconhecimento automático de pessoas tem recebido extensa atenção devido à confiabilidade fornecida pelo uso da biometria. Dentre as diversas estruturas do corpo humano utilizadas em sistemas de identificação de pessoas, a íris é considerada a estrutura mais confiável devido à riqueza de características singulares presentes em suas imagens. Este trabalho tem como objetivo analisar a quantidade de informação redundante existente em imagens de íris em tons de cinza e, posteriormente, realizar uma análise discriminante dessa informação redundante para verificar se o comportamento fractal existente neste tipo de imagem pode caracterizar melhor a diferença entre íris de sujeitos distintos. Três tipos de texturas de imagens de íris normalizadas e equalizadas foram comparados: a textura da intensidade dos pixels (comumente utilizada) e outros dois tipos de texturas resultantes do cálculo de assinaturas fractais realizados pelos métodos denominados *Covering Blanket* e Área de Superfície de Prisma Triangular. Para esta comparação, 130 classes de imagens de íris foram analisadas, onde cada classe foi representada por 5 amostras, totalizando 650 imagens retiradas do banco de imagens UBIRIS (v1), disponível para uso acadêmico e citado na literatura afim. Utilizando a distância de Bhattacharyya e o classificador de distância Euclidiana, verificou-se que as intensidades dos pixels equalizados indicam uma melhor caracterização discriminante das imagens se comparados com os métodos de extrações fractais citados, sem a necessidade de utilização de todas as componentes principais possíveis e, conseqüentemente, com boa redução de dimensionalidade. Portanto, os resultados desse trabalho indicam que a fractalidade das imagens de íris, embora quantificável por métodos fractais distintos, não implica necessariamente em uma maior redução de dimensionalidade das imagens (possível devido à auto-similaridade existente) e nem em uma extração de características mais discriminante que os métodos empregados hoje em dia para reconhecimento de íris.

Palavras-chave: Reconhecimento de Íris, fractal, dimensão fractal, e análise de informação redundante e discriminante.

## **ABSTRACT**

The automatic recognition of people has received extensive attention because of the reliability provided by the use of biometrics. Among the various structures of the human body used in systems for identification of subjects, the iris is considered the more reliable structure due to the wealth of unique features present in their images. This paper aims to analyze the amount of redundant information existent in grayscale images of iris and then perform a discriminant analysis of such redundant information to determine whether the fractal behavior inherent to these images can better characterize the difference between iris of distinct subjects. Three types of textures of normalized iris images have been compared and equalized: the texture of pixels intensities (commonly used) and two types of textures resulting from the calculation of fractal signatures made by the methods called Covering Blanket and Surface Area of Triangular Prism. For this comparison, 130 classes of iris images were analyzed, where each class was represented by 5 samples, totaling 650 images from the iris database called UBIRIS (v1), available for academic use and commonly cited in the literature. Using the Bhattacharyya distance and the Euclidean distance classifier, it was found that the intensities of the pixels equalized indicate a better discriminates characteristics of images when compared with the methods of fractal extraction implemented, using less principal components, and therefore, providing better dimensionality reduction as well. Therefore, the results of this study indicate that the fractal dimension of iris, although a characteristic behavior of such images, does not necessarily imply in a further reduction of dimensionality of these images and neither on a better discriminate separation of subjects than the methods used nowadays for iris recognition.

**Keywords:** Iris recognition, fractal, fractal dimension, and discriminate analysis of redundant information.

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>17</b>
<b>2</b>	<b>SISTEMA DE RECONHECIMENTO DE ÍRIS</b> .....	<b>21</b>
2.1	AQUISIÇÃO DA IMAGEM.....	22
2.2	SEGMENTAÇÃO DA IMAGEM .....	23
2.2.1	Detecção da Pupila.....	24
2.2.2	Detecção da Borda Externa da Íris .....	26
2.3	NORMALIZAÇÃO DA IMAGEM .....	31
2.4	EXTRAÇÃO DE CARACTERÍSTICAS DA IMAGEM.....	34
2.5	CLASSIFICAÇÃO DA IMAGEM .....	36
2.6	COMENTÁRIOS ADICIONAIS .....	36
<b>3</b>	<b>CONCEITOS BÁSICOS DE FRACTAIS, GEOMETRIA E DIMENSÃO FRACTAIS</b> .....	<b>39</b>
3.1	GEOMETRIA FRACTAL.....	39
3.2	DIMENSÃO FRACTAL .....	45
<b>4</b>	<b>TEXTURA, MÉTODOS ESTATÍSTICOS E FRACTAIS</b> .....	<b>50</b>
4.1	EQUALIZAÇÃO DE HISTOGRAMA.....	51
4.2	ANÁLISE DE COMPONENTES PRINCIPAIS .....	54
4.3	MÉTODOS FRACTAIS .....	58
4.3.1	Método <i>Box-Counting</i> .....	58
4.3.2	Método <i>Covering Blanket</i> .....	62
4.3.3	Método Área de Superfície de Prisma Triangular .....	71
4.4	COMENTÁRIOS ADICIONAIS .....	73
<b>5</b>	<b>EXPERIMENTOS E RESULTADOS</b> .....	<b>75</b>
5.1	BANCO DE IMAGENS UBIRIS .....	75
5.2	PRÉ-PROCESSAMENTO DAS IMAGENS .....	76
5.3	CÁLCULO DAS DIMENSÕES FRACTAIS DAS IMAGENS .....	77
5.4	CÁLCULO DAS COMPONENTES PRINCIPAIS.....	81
5.5	CÁLCULO DA DISTÂNCIA DE BHATTACHARYYA .....	84
5.6	CLASSIFICAÇÃO .....	86
<b>6</b>	<b>CONCLUSÃO E TRABALHO FUTURO</b> .....	<b>89</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	<b>91</b>

## LISTA DE FIGURAS

Figura 1 - Imagem colorida de íris rica em detalhes em sua textura: sulcos (A) e (B), ligamentos, cavernas, cumes e coroas – adaptado de <a href="http://www.bbc.co.uk/portuguese/especial/1454_olhos/page2.shtml">http://www.bbc.co.uk/portuguese/especial/1454_olhos/page2.shtml</a> . ....	19
Figura 2 – Imagem criada a partir da técnica Arte Fractal (Adaptada de COOPER, J., 2007)	20
Figura 3 - Ilustração de uma imagem típica de íris. (Imagem extraída de CASIA (CASIA Íris Image Database)).....	21
Figura 4 – Ilustração de contração (superior) e dilatação (inferior) causada por excesso ou ausência, respectivamente, de luminosidade no ambiente durante a captura da imagem – (Adaptado de RUIZ, J. C., 2007).....	23
Figura 5 – Histograma da imagem de íris do qual é determinado o limiar para a binarização da imagem e, posteriormente, a detecção da pupila. ....	25
Figura 6 - Detecção da pupila: imagem original (esquerda) e imagem binária correspondente (direita). ....	25
Figura 7 - Detector de bordas de Canny não otimizado. Neste caso, detectou-se apenas a pupila por ser a estrutura mais escura presente na imagem.....	26
Figura 8 - Detecção da borda externa da íris pelo algoritmo de Canny: (a) destaque das bordas através de correções do parâmetro gama; (b) ajuste dos aglomerados de pontos de borda através do parâmetro supressão não-máxima e utilizando 8 direções; e (c) binarização da imagem através do <i>hysteresis thresholding</i> empiricamente otimizado. ....	27
Figura 9 - Detecção da borda externa da íris pela Transformada de Hough em uma imagem do banco de imagens CASIA (CASIA Íris Image Database) - (adaptado de MA, L., 2003). ....	28
Figura 10 - Detecção das bordas da pupila e externa da íris através do operador íntegro-diferencial - (adaptado de DAUGMAN, J., 2004). ....	29
Figura 11 – O método “Contorno Ativo” melhora a segmentação porque permite bordas não circulares. Os quadros nos cantos inferiores-esquerdo mostram as bordas internas e externas da íris. Se as íris fossem circulares nos quadros haveriam íris planas e retas. Em (a) percebe-se uma forma mais circular e em (b) a interrupção na íris representada no quadro representa a oclusão pela pálpebra superior - (adaptado de DAUGMAN, J., 2007).....	30
Figura 12 – Inferência estatística dos cílios a partir de histogramas e limiarização que os desconsidera - (adaptado de DAUGMAN, J., 2007).....	31

Figura 13 - Normalização da imagem da íris (DAUGMAN, J., 1993; 2001; 2003). A imagem da íris, neste caso retirada do banco de imagens CASIA (CASIA Íris Image Database), é isolada (a) e o formato circular é convertido no formato normalizado retangular (b) e, posteriormente, considerado apenas o retângulo de dimensões 270x56 pixels (c), para compensar deformações causadas pela contração e dilatação da pupila. ....	33
Figura 14 - Alguns exemplos de íris normalizadas. ....	34
Figura 15 – Processo de demodulação usado para codificar os padrões da textura das imagens de íris. Pequenos blocos da imagem são projetados na quadratura 2D dos filtros de Gabor, onde o ângulo resultante indicará qual o quadrante da projeção e será codificado pelos dois bits correspondentes. Este processo ocorre repetidamente até que são gerados 2048 bits, chamados de <i>iriscode</i> que representarão a imagem de íris – adaptado de DAUGMAN, J., 2004.....	35
Figura 16 – Modelagem da superfície de uma montanha através de uma figura fractal criada em computador – <a href="http://pt.wikipedia.org/wiki/Ficheiro:Animated_fractal_mountain.gif">http://pt.wikipedia.org/wiki/Ficheiro:Animated_fractal_mountain.gif</a>	41
Figura 17 – Floco de neve de Koch: Os perímetros são reduzido na escala de 1/3 – adaptado de <a href="http://pt.wikipedia.org/wiki/Ficheiro:Von_Koch_curve.gif">http://pt.wikipedia.org/wiki/Ficheiro:Von_Koch_curve.gif</a> .....	41
Figura 18 – Objetos fractais encontrados na Natureza: (a) Árvore; (b) Paisagem litorânea; (c) Alvéolos pulmonares. - adaptado de <a href="http://matematicanacidadela.blogspot.com/2007/06/fractais.html">http://matematicanacidadela.blogspot.com/2007/06/fractais.html</a> .....	43
Figura 19 – Conjunto de Mandelbrot: (a) Todo o conjunto; (b) Aumento de zoom em 4x; (c) Aumento de zoom em 30x; (d) Aumento de zoom em 350x. Pode-se observar a auto-similaridade invariante à escala - adaptado de <a href="http://pt.wikipedia.org/wiki/Fractal">http://pt.wikipedia.org/wiki/Fractal</a> .....	44
Figura 20 - Processo para representar o comprimento de uma curva qualquer, percorrendo o traçado com segmentos de retas cujo comprimento é a escala $\epsilon$ . – Adaptado de (CARVALHO, M.C.C.S. e outros, 1986). ....	44
Figura 21 – Gráfico de superfícies em que a dimensão fractal vai aumentando no sentido de (A) a (E). (Adaptado de PENTLAND, A.P., 1984).....	48
Figura 22 – Gráfico de superfícies de quatro imagens distintas de íris em tons de cinza, representando as intensidades dos pixels. ....	49
Figura 23 – (a) Imagem de face, onde o reconhecimento pode ocorrer pela localização de estruturas da face baseando-se em formas – adaptado de <a href="http://www.brasiliano.com.br/">http://www.brasiliano.com.br/</a> ; (b) Imagem de íris, onde o reconhecimento ocorre por características extraídas da textura – Imagem retirada do banco de imagens UBIRIS v1 (PROENÇA, H.; ALEXANDRE, L.A. 2005). ....	50

Figura 24 – Subimagem $w$ de dimensão $8 \times 8$ de uma imagem qualquer em tons de cinza.....	51
Figura 25 – Histograma da subimagem $w$ ilustrada na Figura 24. ....	52
Figura 26 – Função de distribuição acumulativa ( $fda$ ) da subimagem $w$ ilustrada na Figura 24. .....	52
Figura 27 – Resultado da equalização da subimagem $w$ ilustrada na Figura 19. ....	53
Figura 28- (a) Imagem normalizada de íris retirada de CASIA (CASIA Íris Image Database); (b) Histograma de imagem normalizada; (c) Gráfico de superfície de imagem normalizada; (d) Imagem equalizada de íris; (e) Histograma de imagem equalizada; (f) Gráfico de superfície de imagem equalizada.....	54
Figura 29- Concatenação das linhas de uma imagem de íris para formação do vetor $xTn1 \times n2$ - dimensional.....	55
Figura 30 – Agrupamento das componentes principais de 10 em 10. Pode-se verificar que em (a) mais de 90% das informações contidas em imagens de íris normalizadas são explicadas pelas dez primeiras componentes apenas. Enquanto que em (b) as dez primeiras componentes explicam quase 50% apenas das informações contidas em imagens de íris equalizadas. ....	57
Figura 31 – A contagem dos quadrados $Q_\epsilon$ que pertencem às grades nos itens de (A) até (D) – para cada tamanho de caixa gera-se pontos no gráfico em (E). Neste, o valor da dimensão fractal (DF) do objeto é obtido pela divisão dos lados ( $\Delta y/\Delta x$ ) do triângulo formado (Adaptado de COSTA, L.; BIANCHI, A. G. C., 2002). ....	59
Figura 32 – Imagens normalizadas e equalizadas (superiores), e binarizadas (inferiores). ....	61
Figura 33 – Valores mínimos, médios e máximos de dimensões fractais de imagens de íris originalmente retiradas do banco de imagens CASIA (CASIA Íris Image Database).....	61
Figura 34 – Ilustração dos passos para o cálculo das camadas superior U e inferior L para escalas maiores do que zero através do kernel $\mu$ considerando como vizinhos os pixels imediatamente ao lado nas direções vertical e horizontal. ....	64
Figura 35 - Imagem de íris equalizada retirada do banco de imagens UBIRIS v1 (PROENÇA, H.; ALEXANDRE, L.A. 2005) convertidas para a dimensão 2D, calculando-se a média de cada coluna de pixel, convertendo a imagem e as superfícies em linhas. ....	65
Figura 37 – (a) Camada superior com escala igual a 11, (b) imagem original e (c) camada inferior com escala igual a 11, em 3D.....	66
Figura 38 – Assinaturas fractais de quatro imagens de duas classes de nuvens. Adaptado de (PELI, T., 1990).....	67

Figura 39 – Discriminação em uma única escala: (a) Imagem original e (b) destacadas as regiões cuja dimensão fractal é superior a 2,4. Adaptado de (PELI, T., 1990).....	68
Figura 40 – Discriminação em uma única escala: (a) Imagem original e (b) destacadas as regiões cuja dimensão fractal é superior a média 2,2.....	69
Figura 41 – Subimagem $w$ tamanho $r \times r$ , onde os pontos A, B, C e D representam os valores dos pixels como alturas. ....	72
Figura 42 – (a) Imagem normalizada e equalizada e (b) imagem fractal resultante do PTPSA com janela de tamanho $3 \times 3$ . ....	72
Figura 43 - Amostras de imagens de íris – UBIRIS v1 (PROENÇA, H.; ALEXANDRE, L.A. 2005).....	76
Figura 44 – Processo de pré-processamento: (a) imagem original retirada do banco de imagens UBIRIS v1; (b) Binarização da imagem; (c) Detector de bordas Canny; (d) Correção de gama; (e) Supressão não-máxima; (f) Detector de bordas Canny otimizado; (g) Pupila e íris detectadas; (h) Normalização e (i) Equalização de histograma.....	77
Figura 45 – Método <i>Covering Blanket</i> : (a) Imagem pré-processada (linha1, coluna1), imagens com janela $w = 3 \times 3$ e escala $\mathcal{E}$ de 3 a 10 (linhas 2 a 9, coluna1); (b) Imagem pré-processada (linha1, coluna2), imagens com janela $w = 5 \times 5$ e escala $\mathcal{E}$ de 3 a 10 (linhas 2 a 9, coluna2); (c) Imagem pré-processada (linha1, coluna3), imagens com janela $w = 7 \times 7$ e escala $\mathcal{E}$ de 3 a 10 (linhas 2 a 9, coluna3). ....	79
Figura 46 – Método PTPSA: Imagem pré-processada (primeira linha), imagens com janela $w = 3 \times 3, 5 \times 5, 7 \times 7$ e $9 \times 9$ (linhas 2, 3, 4 e 5). ....	80
Figura 47 – Método <i>Covering Blanket versus</i> PTPSA: (a) Imagem pré-processada; (b) Imagem processada com o método <i>Covering Blanket</i> e destacados os pixels cujas dimensões fractais são maiores que 2,2; (c) Imagem processada com o método PTPSA e destacados os pixels cujas dimensões fractais são maiores que 3,5. ....	80
Figura 48 – Representação do fluxo utilizado para a Análise de Componentes Principais das imagens: (a) Equalizadas; (b) Calculadas pelo método <i>Covering Blanket</i> ; (c) Calculadas pelo método PTPSA. ....	81
Figura 49 - Projeções nas três componentes principais de cada textura: imagens equalizadas e imagens fractais resultantes dos métodos <i>Covering Blanket</i> e PTPSA.....	82
Figura 50 – Ampliação das projeções nas três componentes principais das imagens fractais resultantes dos métodos <i>Covering Blanket</i> e PTPSA. ....	83

Figura 51 - Agrupamento das componentes principais de 10 em 10. Pode-se verificar que mais de 50% das informações contidas em imagens fractais resultantes do método *Covering blanket* podem ser explicadas pelas 10 primeiras componentes..... 84

Figura 52 – Gráfico de taxas de reconhecimento dos testes com os melhores desempenhos, utilizando as componentes principais para as 130 classes de texturas de íris para as imagens equalizadas (intensidade dos pixels) e resultantes dos métodos fractais *Covering Blanket* com janela  $w=5 \times 5$  e escala  $\xi = 5$  e *PTPSA* com janela  $w=9 \times 9$ ..... 88

## LISTA DE TABELAS

Tabela 1 – Performance do sistema de reconhecimento em produção nos Emirados Árabes Unidos – Novembro de 2008 – (adaptado de MATEY, J.R. et al, 2010).....	38
Tabela 2 – Médias e desvios padrão das distâncias de Bhattacharyya entre as 130 classes de texturas de íris para as imagens equalizadas (intensidade dos pixels) e resultantes dos métodos fractais <i>Covering Blanket</i> e PTPSA.....	85
Tabela 3 – Índices de ordenação das imagens.....	87

## 1 INTRODUÇÃO

O reconhecimento automático e inteligente de pessoas tem recebido extensa atenção devido à confiabilidade fornecida pelo uso da biometria, isto é, o estudo de estruturas fisiológicas ou características comportamentais humanas que tornam as pessoas únicas. Dentre as diversas estruturas do corpo humano utilizadas em sistemas de identificação de pessoas através da biometria, como por exemplo, face, digitais, geometria das mãos, voz, retina, linhas das mãos, e etc., a íris é considerada a estrutura mais confiável devido à riqueza de características aleatórias presentes em suas estruturas. Essas características, comumente denominadas de textura da íris, possuem detalhes considerados únicos para cada pessoa (DAUGMAN, J., 1993; 2001; 2003).

Devido ao crescimento da necessidade de reconhecimento e identificação automático de pessoas, as representações tradicionais, tais como o uso de senhas, cartões magnéticos de proximidade e números de identificação pessoal (PIN), tornaram-se inviáveis ou inseguras, na maioria dos modos de aplicação, pois apresentam sérios problemas de segurança e/ou desempenho. Por exemplo, senhas ou cartões podem ser perdidos ou extraviados, tornando-se conhecidos por pessoas não autorizadas. Ou ainda mais grave, as informações podem ser furtadas e utilizadas de maneira indevida, como, por exemplo, acesso a áreas restritas, movimentações não autorizadas em contas bancárias, roubo de informação e etc.

A fim de solucionar estas questões de baixo desempenho e/ou baixa segurança, surgiram os sistemas automáticos de identificação baseados em biometria, que passaram a ser utilizados com maior frequência devido ao seu elevado grau de confiança. Estes sistemas envolvem representação e caracterização fisiológica humana através da face digital, geometria da mão, íris e etc. Contudo, por serem implementados através de métodos de reconhecimento de padrões, os principais problemas se baseiam na relação das variabilidades inter-classes e intra-classes, ou seja, objetos podem ser classificados confiavelmente somente se a variabilidade entre diferentes amostras de uma determinada classe dada é menor do que a variabilidade entre classes diferentes. Por exemplo, no reconhecimento de faces, apesar de ser um caminho natural para reconhecer as pessoas de maneira não intrusiva e de fácil acesso, as dificuldades se concentram no fato de que a face é um órgão sujeito a mudanças sociais que podem indicar uma variedade de expressões e também por ser um objeto 3D ativo cuja imagem varia com o ângulo de visão, pose, iluminação e idade. Além disso, imagens de face podem possuir apenas diferenças sutis entre gêmeos idênticos, quando há diferenças (E.C. Kitani, C.E. Thomaz, 2007). De fato a face é uma informação biométrica, com alto nível de

confiança, questionável quanto ao reconhecimento de pessoas. Outro exemplo de sistemas biométricos, a geometria das mãos, muito usada em segurança de acesso local, é muito simples, barato e é baseado nas medidas das mãos humanas. Porém, o uso desta técnica apresenta grande dificuldade que é o fato de as mãos humanas não serem tão distintas umas das outras e apresentarem mudanças durante o crescimento humano.

Em contrapartida, o reconhecimento de íris tem se tornado uma técnica de reconhecimento de pessoas eficiente para sistemas em larga escala. Embora as imagens sejam pequenas (em torno de 11 milímetros de diâmetro) e às vezes problemáticas, pois capturar imagens da íris não é uma tarefa trivial, a íris tem uma vantagem matemática importante por sua variabilidade ou aleatoriedade de padrões entre pessoas diferentes ser significativa estatisticamente (DAUGMAN, J., 2001). Sabe-se que a formação da íris humana começa no terceiro mês de gestação do feto e as estruturas que caracterizam o seu padrão estão completas pelo oitavo mês, embora o crescimento do pigmento possa continuar nos primeiros anos após o nascimento (DAUGMAN, J., 2003). Na verdade, pode-se observar pela Figura 1 que o padrão complexo de uma imagem de íris pode conter muitas características distintas tais como ligamentos, sulcos, cumes, cavernas, anéis, coroas, sardas, e um colarinho em arco, tornando cada íris única, como as impressões digitais. Portanto, as íris de gêmeos idênticos são tão diferentes quanto as duas íris de uma mesma pessoa. E ainda, por ser um objeto plano, sua imagem é relativamente insensível ao ângulo de iluminação, e mudanças no ângulo de visualização causam transformações de afinidades (DAUGMAN, J., 2004). Até mesmo a distorção do padrão de não afinidade causada pela dilatação da pupila é possivelmente reversível à leitura de uma imagem de íris.

Este trabalho tem como objetivo analisar a quantidade de informação redundante existente em imagens de íris com escala de cores em tons de cinza e, posteriormente, realizar uma análise discriminante dessa informação redundante para averiguar se o comportamento fractal existente neste tipo de imagem pode melhor caracterizar a diferença entre íris de sujeitos distintos. Em outras palavras, objetiva-se averiguar se existe uma auto-similaridade nas imagens de íris quantificável, como aquelas comuns às imagens fractais artificiais e se essa auto-similaridade pode discriminar melhor as imagens em comparação com as intensidades dos pixels comumente utilizadas. Conforme ilustrado na Figura 1, características observadas visualmente em imagens de íris, tais como as estruturas A e B destacadas, revelam que essas regiões possuem formações muito parecidas, porém em dimensões diferentes. Portanto, investiga-se aqui a possibilidade de existirem estruturas nas imagens de íris que podem se repetir em escalas diferentes, efeito exatamente igual ao que ocorre em imagens

geradas a partir de comportamentos fractais como, por exemplo, a Arte Fractal (MITCHELL, K., 1999), ilustrada na Figura 2. Através dessas análises fractais das imagens de íris, verifica-se a influência de uma extração de características baseada nesta auto-similaridade sobre o poder discriminante das imagens e, conseqüentemente, as taxas de reconhecimento desta característica biométrica.

No Capítulo 2, descrevem-se algumas das principais técnicas de sistemas automáticos

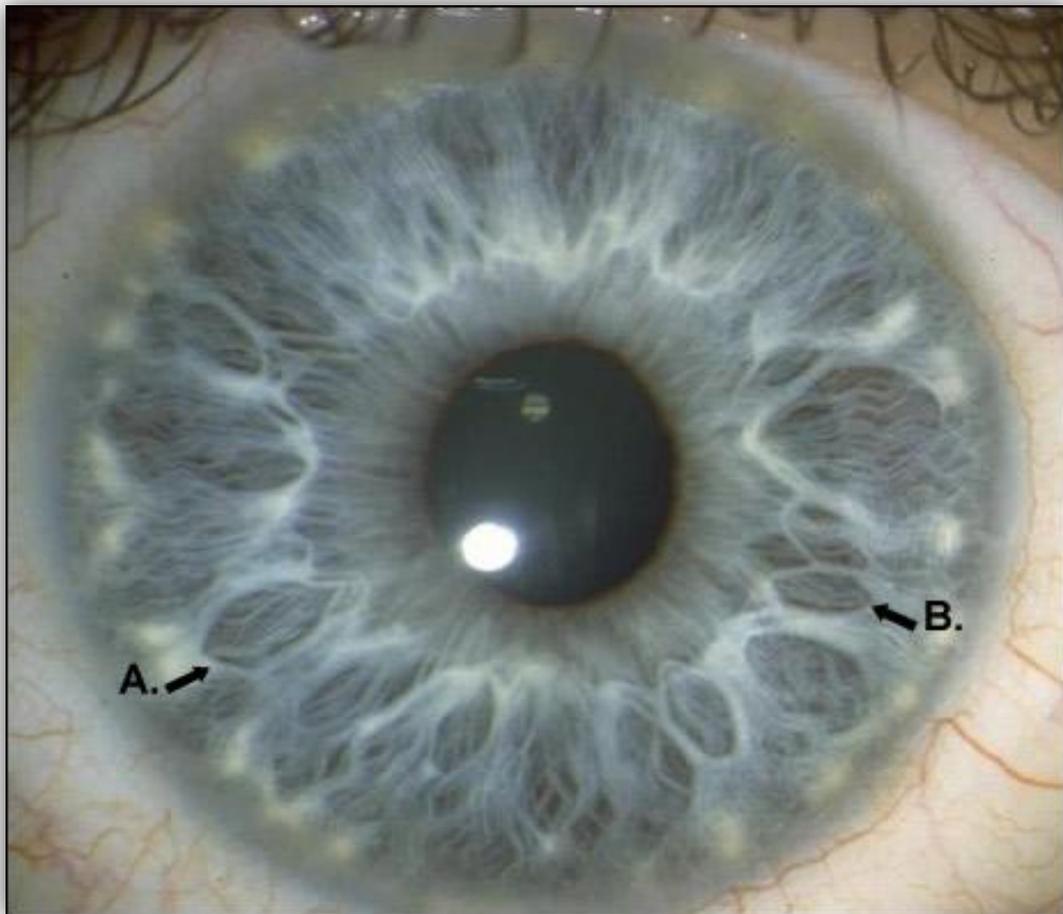


Figura 1 - Imagem colorida de íris rica em detalhes em sua textura: sulcos (A) e (B), ligamentos, cavernas, cumes e coroas – adaptado de [http://www.bbc.co.uk/portuguese/especial/1454\\_olhos/page2.shtml](http://www.bbc.co.uk/portuguese/especial/1454_olhos/page2.shtml).

de identificação de pessoas através de imagens de íris. Todos os sistemas encontrados na literatura utilizam algum método de extração de características que armazenam esses atributos em estruturas como, por exemplo, um vetor binário chamado de *íris-codes* no caso do sistema de John Daugman (DAUGMAN, J., 2003). No Capítulo 3, apresenta-se uma descrição introdutória dos conceitos de fractal, fractalidade, geometria e dimensão fractais. No Capítulo 4, descreve-se de forma teórica e, em algumas situações, com exemplos práticos, os métodos

investigados neste trabalho, principalmente as abordagens fractais para caracterização de texturas em imagens, tais como o método *Covering Blanket* (PELI, T., 1990) e o método Área de Superfície de Prisma Triangular (IFTEKHARUDDIN, K.M. et al, 2003). Em seguida, no Capítulo 5, explica-se os experimentos realizados e os resultados correspondentes obtidos neste trabalho, bem como o banco de imagens de íris UBIRIS v1 (PROENÇA, H.; ALEXANDRE, L.A. 2005) disponível academicamente e utilizado aqui. Por fim, no sexto e último capítulo, concluiu-se essa dissertação resumindo as principais contribuições deste trabalho e possibilidades de extensões futuras.



Figura 2 – Imagem criada a partir da técnica Arte Fractal (Adaptada de COOPER, J., 2007)

## 2 SISTEMA DE RECONHECIMENTO DE ÍRIS

Este capítulo descreve em detalhes as principais etapas de um sistema de reconhecimento baseado em imagens de íris.

A íris, ilustrada na Figura 3, é um órgão interno protegido do ambiente pela córnea do olho, é colorido e tem a função de controlar os níveis de luz assim como faz o diafragma de uma câmera fotográfica. A pupila é a abertura para a entrada de luz que é controlada pela íris (KRONFELD, P., 1962). Uma íris é composta por um tecido dinâmico limitado pela pupila em uma das bordas e pela esclerótica ou esclera na outra borda, e sua cor é determinada principalmente pela densidade do pigmento melanina (ERICKSON, M., 1996) na sua camada anterior e estroma.

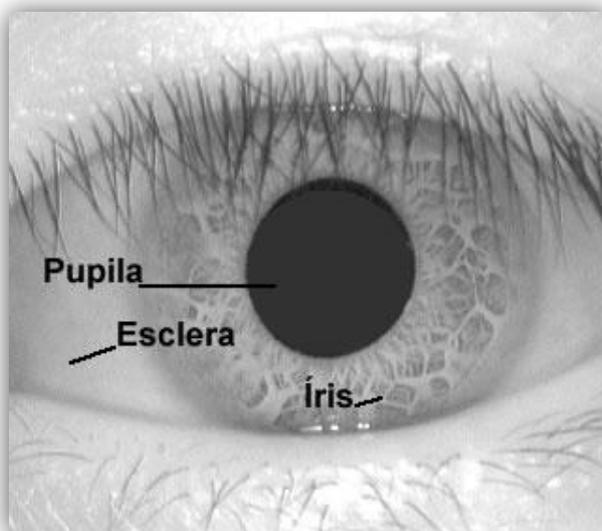


Figura 3 - Ilustração de uma imagem típica de íris. (Imagem extraída de CASIA (CASIA Íris Image Database))

Embora os primeiros sistemas baseados em reconhecimento de íris humana fossem caros e exigissem considerável colaboração do usuário, os sistemas atuais são mais amigáveis e acessíveis em termos comerciais.

Conforme detalhado nas próximas seções, um sistema de reconhecimento de íris contém, basicamente, os seguintes passos (DAUGMAN, J., 2003; WILDES, R. P., 1997; BOLES, W., 1998; MA, L., 2003; MA, L., 2004): aquisição de imagem, segmentação da íris, normalização e extração de características, e classificação.

## 2.1 Aquisição da Imagem

Este passo é uma das mais importantes etapas de um sistema de reconhecimento de íris humana. Neste estágio, parâmetros da imagem como contraste, nitidez e brilho precisam ser caracterizados corretamente para prover uma imagem da íris de boa qualidade e resolução. O primeiro problema crítico, basicamente, é a aquisição das imagens da íris baseado no fato de que suas características, especialmente em íris de cores escuras, não são visíveis quando os dispositivos de aquisição de imagem utilizam uma radiação na faixa equivalente a da luz visível.

Para que, efetivamente, sejam mapeados os detalhes de uma íris, alguns pesquisadores utilizam iluminação por radiação infravermelha (Near Infra-Red – NIR). Por exemplo, em íris azuis que resultam da ausência do pigmento melanina, ondas de comprimento longo penetram e são absorvidas pelo pigmento do epitélio, enquanto ondas de comprimento mais curto são refletidas e dispersadas pelo estroma. As malhas estriadas trabeculares do ligamento pectinoso criam a textura predominante sob a luz visível, visto que nas ondas de comprimento próximo de infravermelho (NIR), mesmo com pigmentação escura, as íris revelam características ricas e complexas (DAUGMAN, J., 2004).

Como explicado anteriormente, a íris reage à iluminação contraindo ou relaxando conforme a variação da intensidade da luz do ambiente. Por exemplo, em ambientes muito escuros a iluminação inadequada na aquisição das imagens pode fazer com que a íris se contraia drasticamente diminuindo a sua área, como mostra a Figura 4.

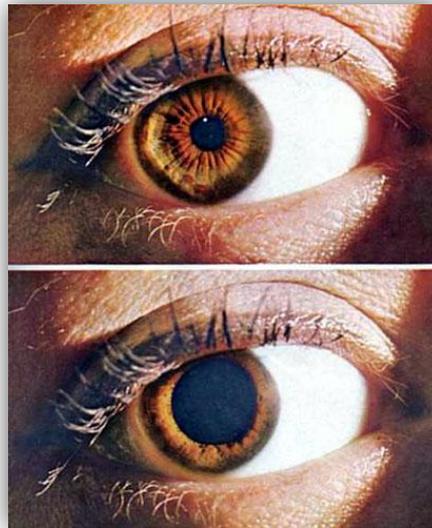


Figura 4 – Ilustração de contração (superior) e dilatação (inferior) causada por excesso ou ausência, respectivamente, de luminosidade no ambiente durante a captura da imagem – (Adaptado de RUIZ, J. C., 2007).

Além disso, a fim de minimizar o problema de nitidez, as câmeras são reguladas para trabalhar com uma distância focal fixa, entre 20 cm e 100 cm, para que o processo de aquisição de imagem seja menos intrusivo. Deve-se tomar um cuidado especial com o reflexo produzido no próprio olho durante a aquisição da imagem, ou ainda, oclusões pelas pálpebras e/ou pelos cílios e até mesmo o posicionamento do olho com relação à câmera, pois a porção da imagem que contém a íris pode ser reduzida drasticamente, conseqüentemente, as características da íris podem não ser incorporadas à imagem para a classificação da mesma.

## 2.2 Segmentação da Imagem

A primeira zona de interesse para a localização da íris é a região interna cuja extremidade forma as bordas da pupila, e a segunda zona é o restante da imagem que se estende da borda externa da íris para a extremidade da imagem. Em geral, a imagem da íris está localizada entre essas duas maiores zonas. Embora a detecção destas regiões não seja uma tarefa trivial, a precisão na representação destas zonas é determinante para prover confiabilidade e robustez em um sistema de reconhecimento de íris humana.

Uma vez que a imagem é adquirida em uma boa qualidade e resolução, é necessário separar a imagem da íris do restante das informações capturadas pelo dispositivo de aquisição de imagem. Este processo é chamado de segmentação da imagem, comumente presente em sistemas de reconhecimento de imagens, e envolve basicamente dois passos: a) detecção dos limites da pupila, e b) detecção dos limites entre a íris e a esclera.

O processo de segmentação de imagem da íris possui uma grande e crítica dificuldade, a sobreposição de regiões não discriminantes do olho. Mais especificamente, a sobreposição ocorre principalmente em regiões como os cílios e as pálpebras, além das áreas de reflexão, citadas na seção anterior e imagens cujo olhar está em um ângulo diferente do ângulo da câmera. O objetivo da etapa de segmentação é separar a íris do restante da imagem, sendo que qualquer erro nesta etapa implicará em informações equivocadas em todas as etapas seguintes e, conseqüentemente, o reconhecimento será prejudicado.

Existem diversos trabalhos na literatura (NASCIMENTO, R.; FEITOSA, R., 2005) que executam a segmentação de características particulares na imagem usando algoritmos que permitem a detecção de formas específicas, como contornos circulares. Nestes tipos de problemas são comumente usados a Transformação de Hough (BALLARD, D.; BROWN, C., 1982) para a detecção de círculos ou o operador íntegro-diferencial (DAUGMAN, J., 2004). A Transformação de Hough pode ser descrita resumidamente como uma técnica matemática para a detecção de formas geométricas como reta, círculos ou elipses em imagens digitais. Já o operador íntegro-diferencial age de forma muito semelhante buscando localizar contornos em forma de círculos ou arco, porém a partir de coordenadas centrais. Ambas as técnicas serão mais bem explicadas nas subseções seguintes.

### 2.2.1 Detecção da Pupila

Para se utiliza a Transformação de Hough para a detecção da pupila deve-se determinar inicialmente um valor limiar através do histograma da imagem, a fim de isolar a pupila do restante da imagem. Então, a partir do histograma da imagem fora determinado o limiar igual a 100. Este valor corresponde ao limiar, conforme ilustrado a linha vertical vermelha na Figura 5, que na conversão em uma imagem binária serão mantidos apenas os pixels cujas intensidades sejam menores que este limiar, na maioria das vezes, os pixels pertencentes à pupila e, em alguns casos, aos cílios e/ou às pálpebras que acabam por ser incorporados. Em outras palavras, selecionam-se os pontos mais escuros da imagem menores que este limiar, os quais pertencem às estruturas mais escuras da imagem original, como a pupila, por exemplo, após a conversão para uma imagem binária. Nos casos em que outras estruturas que não a pupila são visíveis na imagem binária, uma operação de fechamento (erosão e dilatação) (GONZALEZ, R.; WOODS, R., 1992) é suficiente para descartá-las. A Figura 6 ilustra este primeiro passo para a detecção do posicionamento da pupila em uma

imagem original do banco de imagens de íris, publicamente disponível, CASIA (CASIA Íris Image Database).

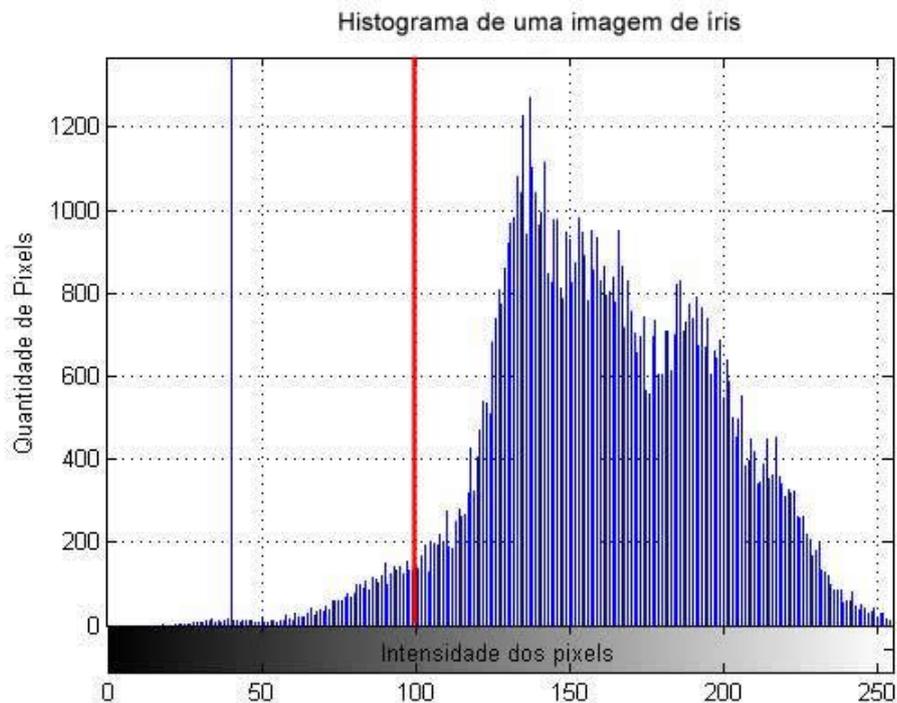


Figura 5 – Histograma da imagem de íris do qual é determinado o limiar para a binarização da imagem e, posteriormente, a detecção da pupila.

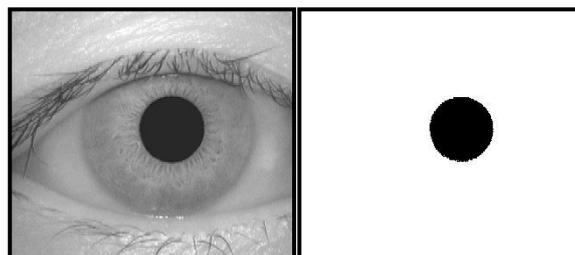


Figura 6 - Detecção da pupila: imagem original (esquerda) e imagem binária correspondente (direita).

Após a obtenção da imagem da pupila, o ponto central da estrutura é encontrado através do cálculo das equações:

$$x_c = \frac{\max(x) + \min(x)}{2},$$

$$y_c = \frac{\max(y) + \min(y)}{2},$$
(1)

onde  $\max(x)$  é a posição do pixel aceso mais a direita,  $\min(x)$  a posição do pixel aceso mais a esquerda no eixo  $x$  na Figura 6,  $\max(y)$  e  $\min(y)$  as posições dos pixels acesos mais acima e mais abaixo, respectivamente, da pupila no eixo  $y$  da mesma imagem. Logo,  $x_c$  e  $y_c$  correspondem às coordenadas  $(x, y)$  do ponto central da pupila. Essas coordenadas são utilizadas como parâmetros na detecção da íris, pois se sabe que a relação entre o raio da pupila e o raio da íris possui uma escala entre 0.1 e 0.8 (DAUGMAN, J., 2004), ou seja, após se determinar o raio da pupila é possível estimar que o raio da íris seja entre 10% e 80% maior.

### 2.2.2 Detecção da Borda Externa da Íris

Com a aplicação do operador de detecção de bordas de Canny (CANNY, J.F., 1986), na imagem original, pode-se obter todos os pontos de bordas da imagem. Conforme ilustrado na Figura 7, a estrutura mais escura da imagem tende a ser a pupila, a utilização do operador Canny sem otimização dos seus parâmetros (CANNY, J.F., 1986) pode resultar na detecção da pupila apenas, mas não os pontos da borda externa da íris.

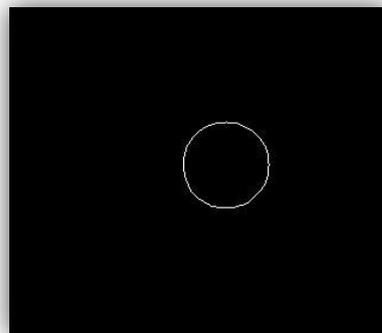


Figura 7 - Detector de bordas de Canny não otimizado. Neste caso, detectou-se apenas a pupila por ser a estrutura mais escura presente na imagem.

Assim, para a detecção da borda externa da íris, aplica-se uma correção gama (CANNY, J.F., 1986) para que as bordas fiquem mais evidentes e, em seguida, uma supressão

não-máxima. Posteriormente, aplica-se o método de *hysteresis thresholding* (CANNY, J.F., 1986), que utiliza dupla limiarização. Este método permite que os pontos de bordas cujos valores sejam menores que um limiar (inferior) pré-determinado sejam eliminados, porém aqueles que estão conectados a pontos de bordas maiores permaneçam, formando uma cadeia de pixels onde todos são maiores que o limiar inferior escolhido. A Figura 8 mostra essa correção de parâmetros disponível no algoritmo de detecção de bordas de Canny. Em outras palavras, os pixels acima de um limiar (inferior) são separados. Então, estes pontos são marcados como pontos de borda somente se todos os pixels circunvizinhos são maiores do que outro limiar (superior). Comumente, esses valores de limiares são encontrados empiricamente, como no trabalho desenvolvido por MA, L. (MA, L., 2003), no qual os limiares superiores e inferiores foram definidos como sendo 0,19 e 0,20, respectivamente.

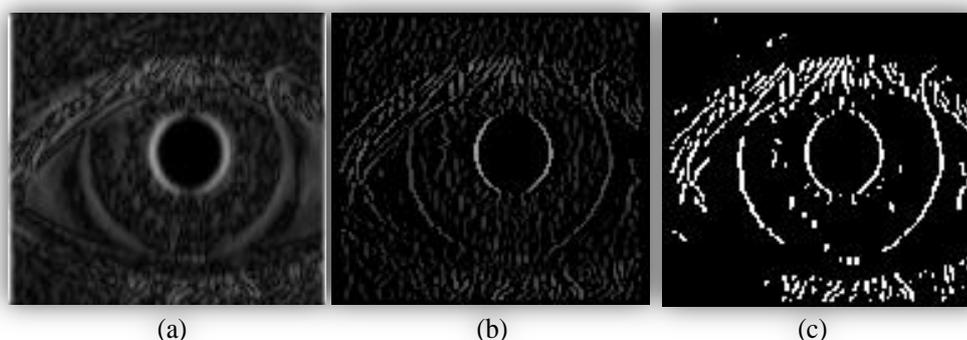


Figura 8 - Detecção da borda externa da íris pelo algoritmo de Canny: (a) destaque das bordas através de correções do parâmetro gama; (b) ajuste dos aglomerados de pontos de borda através do parâmetro supressão não-máxima e utilizando 8 direções; e (c) binarização da imagem através do *hysteresis thresholding* empiricamente otimizado.

O último passo dessa etapa de pré-processamento consiste em calcular a Transformada de Hough para encontrar os círculos na imagem da borda, utilizando os parâmetros obtidos anteriormente e executando uma operação de votação para encontrar a circunferência da íris. A Figura 9 ilustra o resultado dessa transformada utilizada no trabalho de (MA, L., 2003) em uma imagem de íris do banco de imagens CASIA (CASIA Íris Image Database).

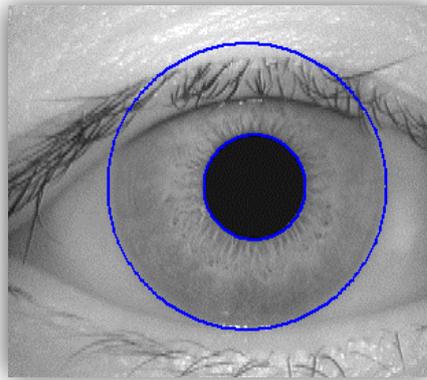


Figura 9 - Detecção da borda externa da íris pela Transformada de Hough em uma imagem do banco de imagens CASIA (CASIA Íris Image Database) - (adaptado de MA, L., 2003).

Já o operador íntegro-diferencial, proposto por (DAUGMAN, J., 2004), busca detectar as bordas da pupila e da íris através da estimação de parâmetros separados para a detecção de cada uma destas estruturas, realizando uma busca por bordas a partir de raios crescentes em escalas sucessivas e finas através da Equação (2):

$$\max_{(r, x_c, y_c)} \left| G_\sigma(r) * \frac{\partial}{\partial r} \oint_{r, x_c, y_c} \frac{x(i, j)}{2\pi r} ds \right|, \quad (2)$$

onde  $x(i, j)$  é a imagem de uma íris qualquer como a ilustrada na Figura 3. Sobre o domínio da imagem serão realizadas buscas iterativas com arcos circulares  $ds$  a partir de raios  $r$  crescentes, cujas coordenadas centrais são os pontos  $x_c$  e  $y_c$ .  $G_\sigma(r)$  é uma função de suavização gaussiana de escala  $\sigma$  com a qual é realizada uma operação de convolução na imagem, representada pelo símbolo  $*$ .

O operador íntegro-diferencial age como um detector de bordas circulares utilizando como parâmetro as coordenadas centrais  $x_c$  e  $y_c$  e o raio  $r$  para encontrar a borda da pupila e a borda externa da íris. Este método se mostrou muito eficiente em detecção de íris com a precisão de 1 pixel (DAUGMAN, J., 2004) em imagens em tons de cinza, isto é, imagens capturadas com iluminação NIR. Em um segundo passo, é empregada uma aproximação para detectar bordas curvilíneas a fim de localizar as bordas das pálpebras superiores e inferiores, modificando a Equação (2) para detectar bordas em forma de arcos ao invés de círculos. O resultado da detecção das quatro bordas (pupila, extremidades externas da íris, pálpebra inferior e pálpebra superior) pode ser visto na Figura 10.

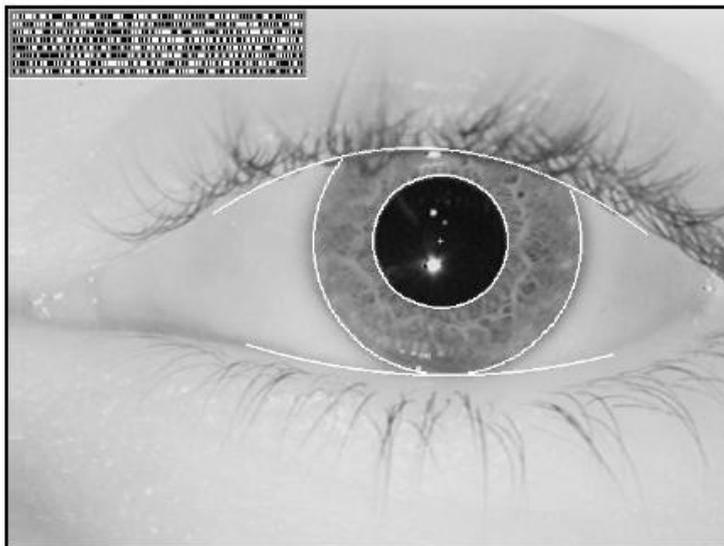


Figura 10 - Detecção das bordas da pupila e externa da íris através do operador íntegro-diferencial - (adaptado de DAUGMAN, J., 2004).

Ao se utilizar a Transformação de Hough, assume-se que tanto a pupila quanto a íris possuem formas circulares perfeitas, o que não é verdade, e acarreta na incorporação de outras estruturas da imagem tais como pequenas partes da pupila, cílios e/ou pálpebras. Na verdade, alguns autores (BOLES, W., 1998; MA, L., 2004; WILDES, R. P., 2002; MA, L., 2002; TOENNIES, K.; BEHRENS, F.; AUERNHAMMER, M., 2002) sugerem ser mais apropriado usar a Transformação de Hough para a detecção de elipses além de círculos para descartar toda a região dos limites externos entre a íris e as pálpebras.

Por se tratar de uma etapa crítica do processo de reconhecimento, em (DAUGMAN, J., 2007) fora proposto melhorias no método de segmentação da íris a fim de excluir qualquer elemento obscuro na imagem, tais como cílios, pálpebras e reflexos na córnea ou, até mesmo, em óculos e garantir que a porção da imagem segmentada seja somente composta pela íris. Uma vez que a robustez e confiança do processo de identificação biométrica pela íris se dão pela variação aleatória presente na textura da íris de diferentes pessoas, qualquer outra estrutura incorporada afetará as etapas seguintes do sistema.

O método mais recente de segmentação proposto por (DAUGMAN, J., 2007) descreve as bordas internas e externas da íris como “contornos ativos”, baseando-se nas Séries de Fourier. Através deste método é possível descrever as bordas da íris e da pupila exatamente como elas estão representadas na imagem, com formas irregulares e excluindo as oclusões por pálpebras, como pode ser observado na Figura 11.

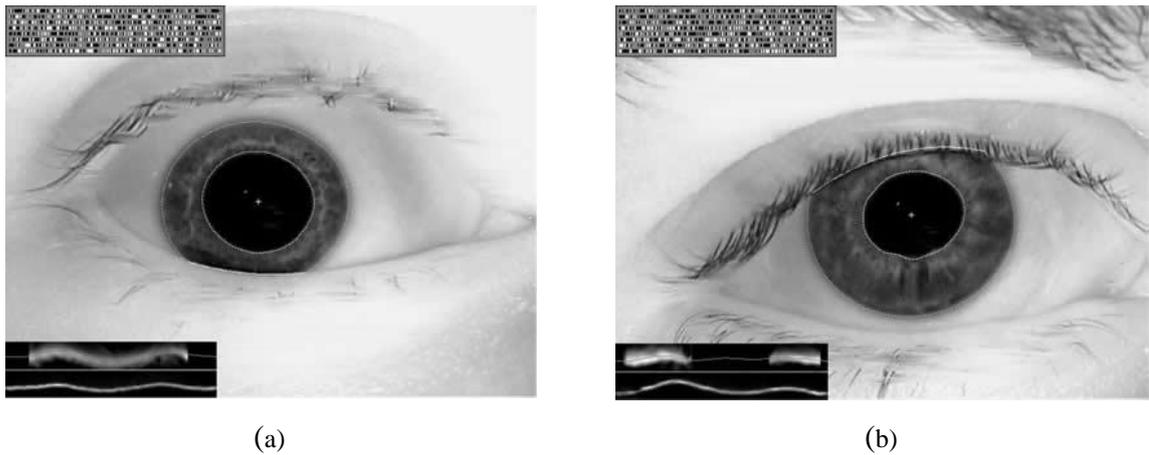


Figura 11 – O método “Contorno Ativo” melhora a segmentação porque permite bordas não circulares. Os quadros nos cantos inferiores-esquerdo mostram as bordas internas e externas da íris. Se as íris fossem circulares nos quadros haveriam íris planas e retas. Em (a) percebe-se uma forma mais circular e em (b) a interrupção na íris representada no quadro representa a oclusão pela pálpebra superior - (adaptado de DAUGMAN, J., 2007).

Em muitas imagens, pode-se observar a sobreposição da íris por cílios, normalmente os superiores. Os cílios possuem formas aleatórias e complexas, então DAUGMAN, J. propôs, também em (DAUGMAN, J., 2007) um método baseado em inferência estatística para a exclusão de cílios que sobrepõem à íris. Os cílios podem ser interpretados como sinais fortes em imagens de íris, em se tratando de contraste. Então, uma limiarização adequada utilizando quatro histogramas da porção segmentada da imagem é realizada. O primeiro histograma é computado da área da íris segmentada com intervalo de  $[0, 255]$ , o segundo é realizado com a parte inferior da íris, o terceiro com a parte superior da íris e o quarto seria a diferença entre os histogramas das partes superiores e inferiores da íris (primeiro), isto é, a diferença dos histogramas das regiões onde ocorrem e não ocorrem oclusões por cílios. A partir deste quarto histograma é realizado um teste estatístico de separação com o primeiro (toda a região da íris). Havendo pontos significativos, então se entende que há oclusões por cílios e o limiar é definido para que os pixels referentes aos cílios sejam detectados e desconsiderados nas próximas etapas de pré-processamento. Em outras palavras, os pixels referentes aos cílios recebem o valor zero, observável na Figura 12 pela cor branca.

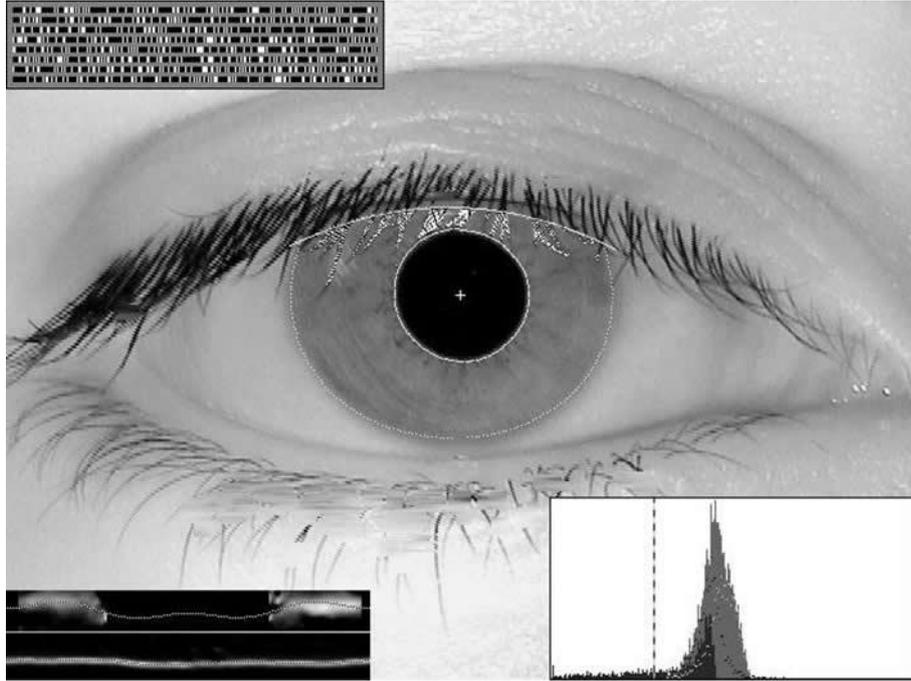


Figura 12 – Inferência estatística dos cílios a partir de histogramas e limiarização que os desconsidera - (adaptado de DAUGMAN, J., 2007).

### 2.3 Normalização da Imagem

A normalização das imagens das íris é outra importante etapa de pré-processamento do sistema de reconhecimento de íris humana. Sabendo que a pupila é um tecido dinâmico cujo diâmetro pode variar durante o processo de aquisição das imagens, as dimensões da imagem segmentada da íris serão também claramente variáveis.

Conforme descrito anteriormente, a íris pode sofrer deformações provocadas pela contração ou dilatação da pupila. Por conseguinte, a luminosidade do local no momento da aquisição da imagem pode provocar, além de diferenças na composição da imagem, alterações nas dimensões da íris. Ou seja, a luminosidade baixa provoca a dilatação da pupila e a contração da íris que, por sua vez, tem sua área reduzida consideravelmente.

A distância entre a pessoa e o dispositivo de aquisição das imagens é outro fator que também pode alterar as dimensões da íris. Essas alterações podem provocar erros em sistemas de identificação de pessoas que se baseiam em imagens de íris. Por exemplo, o sistema não reconhece adequadamente uma determinada pessoa, julgando as imagens dessa íris como sendo de outro indivíduo por consequência das diferentes dimensões da íris.

Para compensar estas e outras deformações que podem ocorrer nas imagens de íris, alguns trabalhos como (DAUGMAN, J., 1993; 2001; 2003) indicam um procedimento de

normalização das imagens baseado na conversão de um sistema de coordenadas cartesianas em um sistema de coordenadas pseudo-polar. Neste novo sistema, a imagem anelar da íris passa a ser representada por um retângulo, conforme ilustrado na Figura 13. Após esta etapa de normalização, todas as imagens retangulares geradas possuem dimensões idênticas de  $n \times m$  e as distorções causadas pela contração da pupila são reduzidas significativamente.

O algoritmo de normalização proposto por (DAUGMAN, J., 1993; 2001; 2003) transforma formas de anéis da íris em blocos retangulares com dimensões fixas. Este é um dos algoritmos de normalização de maior sucesso, apesar de este procedimento não ser comum e qualquer deformação elástica na textura da íris poder afetar decisivamente o procedimento de reconhecimento. Para compensar o problema causado pela deformação, Daugman converteu as coordenadas cartesianas da íris em coordenadas polares (DAUGMAN, J., 1993; 2001; 2003). Este algoritmo tem gerado bons resultados, pois simplifica significativamente os passos subsequentes de processamento, reduzindo parte das distorções causadas pelos movimentos da pupila, mencionados anteriormente.

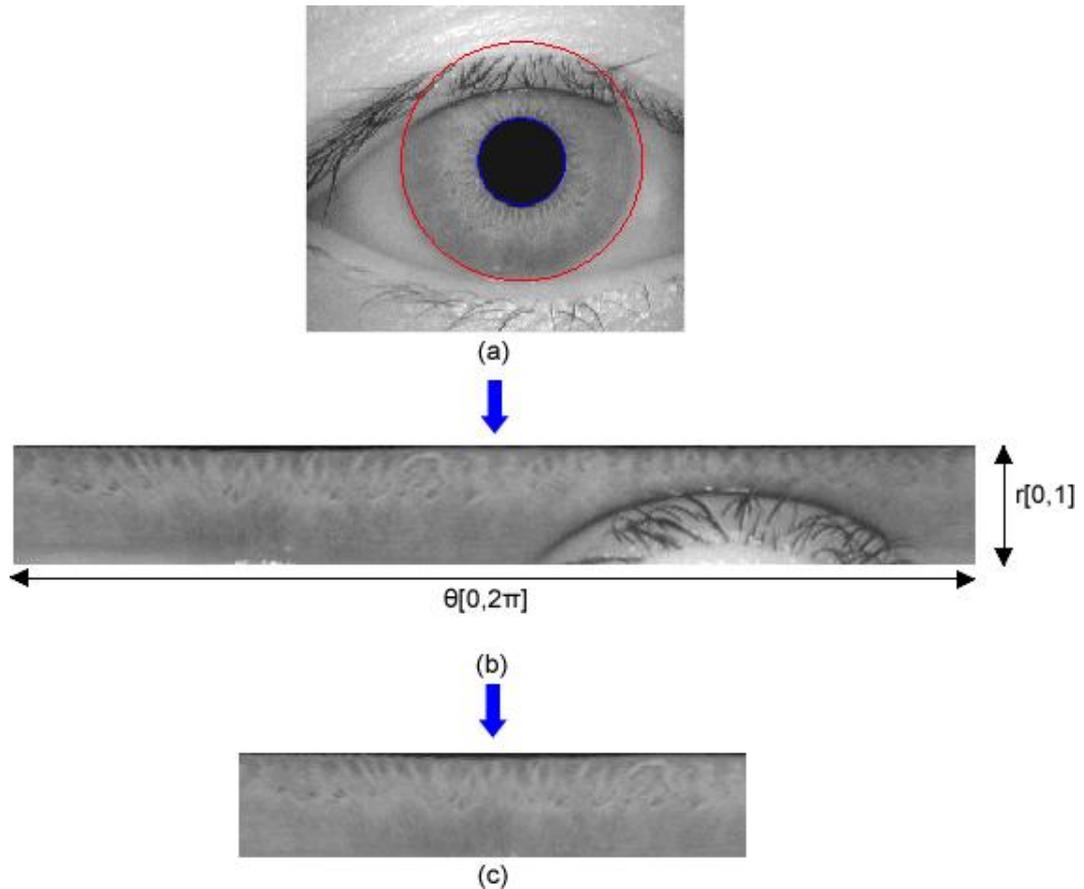


Figura 13 - Normalização da imagem da íris (DAUGMAN, J., 1993; 2001; 2003). A imagem da íris, neste caso retirada do banco de imagens CASIA (CASIA Íris Image Database), é isolada (a) e o formato circular é convertido no formato normalizado retangular (b) e, posteriormente, considerado apenas o retângulo de dimensões 270x56 pixels (c), para compensar deformações causadas pela contração e dilatação da pupila.

Assim, após a detecção da íris e obtenção do anel através do recorte da porção da imagem entre o círculo menor (pupila) e o círculo maior (borda externa da íris), transforma-se a estrutura original da imagem em um retângulo de dimensões pré-fixadas. Em outras palavras, a partir da imagem original  $I(x, y)$ , obtém-se a imagem normalizada  $I(r, \theta)$  através do cálculo das equações:

$$\begin{aligned}
 I(x(r, \Theta), y(r, \Theta)) &\rightarrow I(r, \Theta) \\
 x(r, \Theta) &= (1-r)x_p(\Theta) + rx_s(\Theta) \\
 y(r, \Theta) &= (1-r)y_p(\Theta) + ry_s(\Theta)
 \end{aligned} \tag{3}$$

onde as coordenadas cartesianas do círculo menor são representadas por  $x_p(\theta), y_p(\theta)$  e do círculo maior por  $x_s(\theta), y_s(\theta)$  correspondentes ao ângulo  $\theta$  e pertencente ao intervalo  $[0, 2\pi]$  e  $r$  pertencente ao intervalo  $[0, 1]$ . A Figura 14 ilustra alguns exemplos do resultado desse procedimento de normalização em imagens do banco CASIA (CASIA Íris Image Database).

Esta nova representação normalizada torna a íris invariante ao seu tamanho na imagem capturada, determinada pela distância da câmera ou contrações da pupila causadas pela luminosidade no momento da captura da imagem (assumindo que a elasticidade da íris seja uniforme).

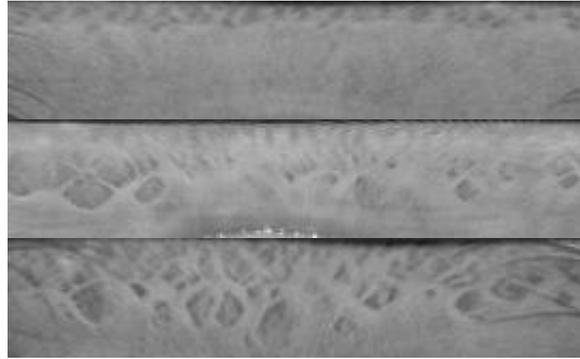


Figura 14 - Alguns exemplos de íris normalizadas.

## 2.4 Extração de Características da Imagem

Para representar a textura da íris J. Daugman utiliza um banco de Filtros de Gabor (DAUGMAN, J., 1985; 2004), os filtros de Gabor são capazes de representar diferentes texturas com resultados expressivos e são definidos sobre o domínio sem dimensões da íris ( $r$ ,  $\theta$ ) por um complexo senoidal modulado por uma função Gaussiana com a seguinte equação:

$$H(r, \theta) = e^{-j\omega(\theta_0 - \theta)^2} e^{-(r_0 - r)^2 / \alpha^2} e^{-(\theta_0 - \theta)^2 / \beta^2}, \quad (4)$$

onde  $r$  e  $\theta$  são as coordenadas polares da imagem normalizada,  $r_0$  e  $\theta_0$  estabelecem a posição do filtro de Gabor sobre a imagem da íris,  $\alpha$  e  $\beta$  são as aberturas das gaussianas que compõem o filtro nas direções de  $r$  e  $\theta$  e  $\omega$  a frequência.

Cada imagem de íris normalizada é demodulada para extrair a informação de fase usando uma quadratura 2D (DAUGMAN, J. 2004), a imagem normalizada é dividida em blocos de dimensões fixas, sendo que cada bloco é projetado sobre o filtro de Gabor, conforme a equação (4), variando os parâmetros  $\alpha$  e  $\beta$  com o inverso de  $\omega$  de modo que são produzidos filtros centralizados em  $(r_0, \theta_0)$ , ponto central de cada bloco. Uma representação gráfica do método está ilustrada na Figura 15.

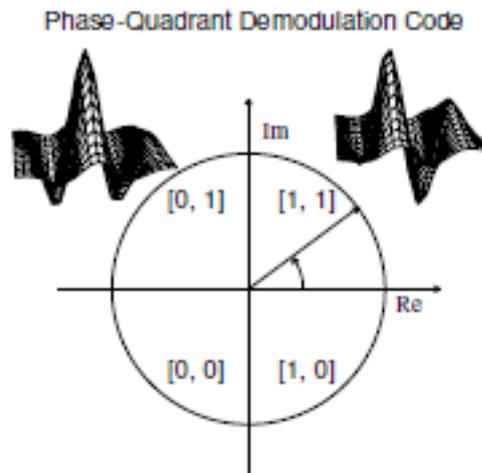


Figura 15 – Processo de demodulação usado para codificar os padrões da textura das imagens de íris.

Pequenos blocos da imagem são projetados na quadratura 2D dos filtros de Gabor, onde o ângulo resultante indicará qual o quadrante da projeção e será codificado pelos dois bits correspondentes. Este processo ocorre repetidamente até que são gerados 2048 bits, chamados de *íriscode* que representarão a imagem de íris – adaptado de DAUGMAN, J., 2004.

Posteriormente, dependendo dos resultados das partes real e imaginária da Equação (4), se positivo ou negativo, a projeção do coeficiente será realizada no quadrante correspondente e este bloco será representado por 2 bits. Ao final do processo em que todos os blocos que compõem a imagem tiverem sido submetidos à equação, são totalizados 2048 bits ou 256 bytes que representarão a imagem de íris como uma espécie de código de barras. Tal representação foi denominada por Daugman de *íriscode*, que será utilizada na próxima etapa do sistema de reconhecimento de íris. Exemplos de *íriscode* podem ser observados nos cantos superiores direitos das Figura 10, Figura 11 e Figura 12.

A representação dos quadrantes de demodulação na Figura 15 retrata a representação ideal, isto é, cíclica, pois qualquer rotação para um quadrante adjacente resulta na alteração de apenas 1 bit o que diminui o custo de erros arbitrários. Um número igual de bits é calculado para indicar se qualquer região da íris possui qualquer oclusão ou reflexos, criando uma máscara de bits que deverão ser ignorados na demodulação.

No entanto, a definição dos parâmetros do banco de filtros ainda é um aspecto não completamente claro nas numerosas publicações de Daugman reportando apenas aproximações como critérios para seleção destes parâmetros.

## 2.5 Classificação da Imagem

O reconhecimento se dá pela comparação de um *íriscode* com os demais armazenados em um banco de dados. Esta comparação é realizada através de um teste de independência estatística implementado por um operador binário denominado XOR (eXclusive OR).

Considerando que A e B são dois modelos de *íriscode*s obtidos de duas íris diferentes, a similaridade entre estes *íriscode*s é calculada pela equação:

$$DH = \frac{1}{2048} \sum_{j=1}^{2048} A_j(XOR)B_j, \quad (5)$$

onde DH é a Distância de Hamming normalizada que pode receber valores no intervalo [0, 1]. Distância de Hamming é o nome dado ao número de posições de bits em que dois *íriscode*s diferem entre si (DAUGMAN, J., 2004). Na prática, essa medida é utilizada para sinalizar erros na transmissão de bits entre um emissor e um receptor. O receptor executa uma operação binária XOR (eXclusive OR) na cadeia recebida. A decisão se ambos *íriscode*s são da mesma imagem de íris ou não é dada pela comparação *DH* com um limiar estabelecido empiricamente.

Uma otimização no procedimento de reconhecimento mencionado anteriormente pode ser introduzido pelo tratamento de áreas ocultas por cílios e pálpebras, por exemplo. Em outras palavras, a Equação (5) pode ser substituída pela Equação (6):

$$HD = \frac{\|\sum[(A \otimes B) \cap maskA \cap maskB]\|}{\|\sum(maskA \cap maskB)\|}, \quad (6)$$

onde *maskA* e *maskB* são máscaras que indicam as áreas não ocultas em ambas as íris que estão sendo comparadas. O operador XOR  $\otimes$  detecta os bits que se diferem entre os *íriscode*s correspondentes e o operador AND  $\cap$  certifica de que este bit não corresponda a uma área de oclusão por cílios, pálpebras ou outro ruído como reflexos, por exemplo. O denominador da Equação (6) normaliza os resultados do operador XOR para os *íriscode*s dos modelos A e B e as respectivas máscaras *maskA* e *maskB*.

## 2.6 Comentários Adicionais

De todos os sistemas automáticos de reconhecimento, o sistema baseado em imagens de íris tem se mostrado o mais promissor para reconhecimento em larga escala. Isto se deve

ao fato da íris ter características únicas que são próprias de cada pessoa. Por exemplo, durante o processo de envelhecimento, a partir de certa idade, a íris não se altera biometricamente, sendo essa uma das suas características fisiológicas mais importantes. Além disso, a formação da íris depende do meio no qual é formado o embrião e, dessa forma, muitos de seus detalhes não tem correlação com a carga genética. Cada pessoa tem uma íris diferente, mesmo que sejam gêmeos univitelinos. Adicionalmente, a íris direita e a íris esquerda da mesma pessoa também são diferentes (DAUGMAN, J., 1993). Os órgãos do olho, o humor aquoso e a córnea protegem a íris do ambiente. Essa proteção impede ou dificulta a mudança das características da íris sem correrem graves riscos de lesão. Essa singularidade torna o reconhecimento através da íris vantajoso, por exemplo, em relação ao de impressão digital, face e geometria das mãos.

Apesar de toda essa complexidade estrutural presente nas íris, os algoritmos computacionais desenvolvidos hoje em dia conseguem realizar as tarefas de análise e verificação de autenticidade em tempos aceitáveis para a construção de sistemas comerciais. Atualmente encontram-se vários desses sistemas em funcionamento como, por exemplo, nos aeroportos de Frankfurt na Alemanha, Amsterdã na Holanda e Manchester na Inglaterra, para controle de imigração. Em 2001 os Emirados Árabes Unidos (EAU), que é uma federação composta por sete emirados localizados no sudeste da Península Arábica no sudoeste da Ásia, implantou um sistema de segurança nacional baseado no reconhecimento de íris, o qual utiliza o algoritmo proposto por Daugman (DAUGMAN, J., 1993), a fim de controlar o acesso das pessoas que possuem visto de entrada na EAU. Segundo (DAUGMAN, J., 2006) o número total de pessoas cadastradas no sistema em junho de 2005 era em torno de 316.250, divididas em 152 nacionalidades o que totalizava 632.500 diferentes padrões de íris cadastradas no banco de dados. Em um dia típico chegam a serem submetidas 6.000 pessoas ao teste de reconhecimento de ambas as íris o que totaliza algo em torno de 7,2 bilhões de comparações de *iriscodes* por dia. Este sistema se tornou um exemplo de confiabilidade e de robustez desta tecnologia quando em novembro de 2008 a empresa ÍrisGuard divulgou alguns números referentes à performance, conforme descritos na Tabela 1.

No entanto, pode-se observar que os *iriscodes* são baseados nas intensidades dos pixels, ou seja, as diferenças nas texturas das imagens de íris são representadas por valores que variam entre 0 e 255. Poucos são os trabalhos que investigaram a possibilidade de representar a textura das imagens de íris não pelas intensidades dos pixels, mas sim pelas dimensões fractais dessa medida biométrica.

Operação	Quantidade
Pessoas pesquisadas no banco de dados	>1,6 milhões
Total de comparações cruzadas	>20 trilhões
Falsos positivos	Zero
Total de pessoas abordadas	>300.000

Tabela 1 – Performance do sistema de reconhecimento em produção nos Emirados Árabes Unidos – Novembro de 2008 – (adaptado de MATEY, J.R. et al, 2010)

Pode-se citar alguns trabalhos na literatura como, por exemplo, (CONCI, A.; AQUINO, F.R., 2005; FISHER, Y., 1994) que utilizam as dimensões fractais na compressão de imagens e outros como (PELLI, T., 1990; IFTEKHARUDDIN, K.M. et al, 2002; ALEGRO, M.C., 2009) que utilizam as dimensões fractais para a caracterização de texturas de imagens naturais, artificiais e imagens médicas. Mas, há um número ainda pequeno de trabalhos que utilizam as dimensões fractais para analisar texturas em imagens de íris, tais como (GU, H. Y. ET AL, 2005; MURTY, P.S.R.C. et al, 2009), os quais utilizam a dimensão fractal para extrair informações sobre as características das texturas das íris e representá-las como medidas discriminantes para posterior classificação. Tais fatos contribuíram para a motivação e confirmação de que o objetivo deste trabalho é plausível, visto que visa investigar o comportamento das texturas das imagens de íris utilizando métodos fractais em conjunto com métodos estatísticos a fim de descrever as informações contidas nestas imagens e verificar se ainda as intensidades dos pixels permanecem sendo a melhor maneira para extrair características e classificar as imagens de íris.

### **3 CONCEITOS BÁSICOS DE FRACTAIS, GEOMETRIA E DIMENSÃO FRACTAIS**

Ainda na infância as pessoas aprendem a lidar com os objetos e suas formas, a fim de compreender o meio em que se vive e de maneira muito intuitiva passam a manipular os objetos com certa destreza. Uma vez que o domínio e a compreensão das formas avançam, as pessoas se tornam capazes de criar novos objetos cujas formas são mais complexas, porém compartilham características de formas mais simples. Esta forma intuitiva que as pessoas lidam com os objetos e o espaço é estudada por uma parte da matemática denominada Geometria. A geometria clássica fornece uma primeira aproximação das estruturas físicas dos objetos, sendo uma linguagem usada para a criação de novos produtos tecnológicos muito próximos das formas de criações da Natureza (BARNSELY, M.F., 1989). No entanto, existem estruturas na Natureza que não podem ser representadas com fidelidade através de formas da geometria clássica como, por exemplo, as nuvens. Mandelbrot observou a existência de uma “Geometria da Natureza” (MANDELBROT, B.B., 1982) que através de novos caminhos científicos conseguiria explicar, por exemplo, os contornos das nuvens, as copas das árvores de uma floresta, entre outras formas existentes na Natureza. Esta geometria foi denominada de Geometria Fractal.

#### **3.1 Geometria Fractal**

Embora Mandelbrot seja considerado o pai da Geometria Fractal, tendo como marco uma de suas principais obras o livro “Objetos Fractais: forma, acaso e dimensão” (MANDELBROT, B.B., 1975), um novo conceito de dimensão já havia sido proposto por matemáticos como Koch, Peano, Hausdorff, Besicovitch, Hilbert, Julia entre outros (PEITGEN, H.; JÜRGENS, H.; SAUPE, D., 2004) no final do século 19, após a criação de imagens cujos objetos não tinham mais uma dimensão inteira, como na Geometria Euclidiana, e sim uma dimensão fracionária. Estas criações, bem como outros trabalhos destes grandes matemáticos do passado, foram primordiais para que Mandelbrot chegasse ao conceito desta nova dimensão denominada Geometria Fractal cuja origem vem da palavra fractus, do latim, que significava segmentos irregulares. Mandelbrot propôs esta nova geometria a fim de explicar formas encontradas na Natureza como, por exemplo, encostas de montanhas, nuvens, flocos de neve, copa de árvores, além de objetos artificiais com formações complexas como, por exemplo, o conjunto de Mandelbrot, a curva de Koch, o triângulo de Sierpinski e a

esponja de Menger. Uma vez que estas estruturas não podem ser explicadas pela Geometria Euclidiana, a qual se baseia em elementos tais como retas, quadriláteros, triângulos, círculos, esferas e, etc. Estes elementos se mostram inadequadas para representar estes objetos, embora visualmente se tenha a sensação do contrário, isto é, ao observar a distância ou de maneira despercebida objetos como montanhas, árvores e nuvens, se tem a sensação de que é possível representar estes objetos utilizando-se estas estruturas euclidianas. Porém, ao observar o detalhe da formação destes objetos percebe-se a existência de padrões irregulares e fragmentados, os quais podem ser explicados mais adequadamente por objetos da geometria fractal (CARVALHO, M.C.C.S. e outros, 1986). Abaixo, copia-se um dos textos de Mandelbrot que mostra a sua grande motivação em explorar conceitos geométricos até então pouco evidentes.

*“Alguma razão para a geometria não descrever o formato das nuvens, das montanhas, das árvores ou a sinuosidade dos rios? Nuvens não são esferas, montanhas não são troncos de cones, árvores não são hexágonos e muito menos os rios desenham espirais”.*  
(MANDELBROT, B.B., 1982).

A geometria fractal é usada na criação de imagens de paisagens sintéticas, na caracterização de comportamento de sistemas caóticos, para desenvolver novas modelagens matemáticas (BARNSELY, M.F., 1989), na compressão de arquivos de imagens, processamento e análise de imagens (FISHER, Y., 1994) e em técnicas para segmentação de imagens (PENTLAND, A.P., 1984; CHAUDHURI, B. B.; SARKAR, N., 1995) entre outras áreas.

Um fractal pode ser caracterizado pelo resultado final de processos físicos que modificam uma figura por meio de ações locais e iterativas. De tal modo que esses processos, após inúmeras repetições, produzem uma figura com superfície tipicamente fractal (PENTLAND, A.P., 1984), como por exemplo, formação de montanhas ou de galáxias, erosão, flocos de neve e etc. Na Figura 16 está ilustrada a superfície de uma montanha criada artificialmente por um processo computacional iterativo.

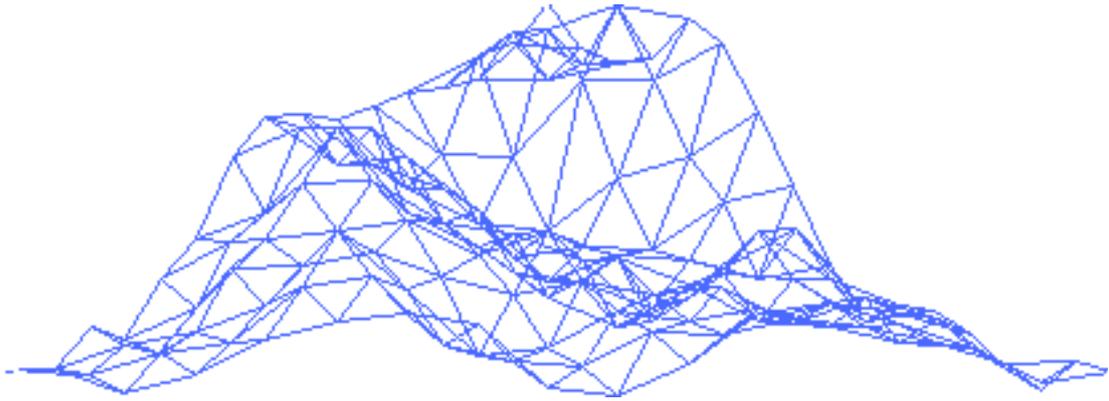


Figura 16 – Modelagem da superfície de uma montanha através de uma figura fractal criada em computador – [http://pt.wikipedia.org/wiki/Ficheiro:Animated\\_fractal\\_mountain.gif](http://pt.wikipedia.org/wiki/Ficheiro:Animated_fractal_mountain.gif)

Um objeto fractal tem, geralmente, como uma de suas principais características a auto-similaridade, isto é, suas características são semelhantes em qualquer que seja a escala observada. Portanto, cada pequena porção do objeto pode ser vista como uma réplica reduzida do todo e, portanto, estatisticamente semelhante. Como, por exemplo, a curva de Koch ilustrada na Figura 17, cujo nome homenageia o matemático Helge Koch.

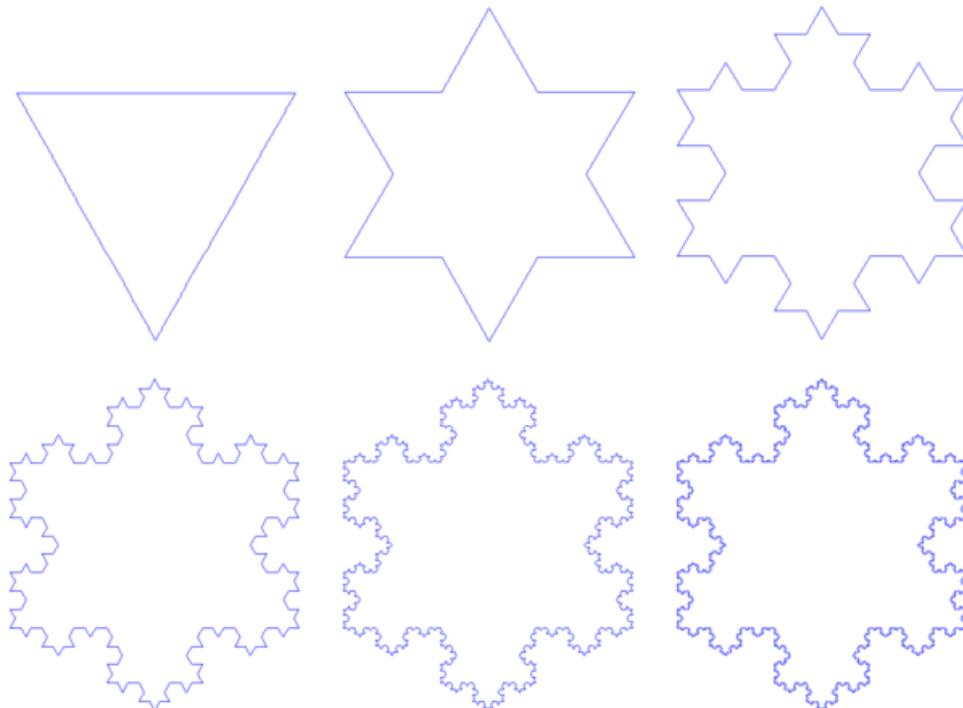


Figura 17 – Floco de neve de Koch: Os perímetros são reduzido na escala de  $1/3$  – adaptado de [http://pt.wikipedia.org/wiki/Ficheiro:Von\\_Koch\\_curve.gif](http://pt.wikipedia.org/wiki/Ficheiro:Von_Koch_curve.gif)

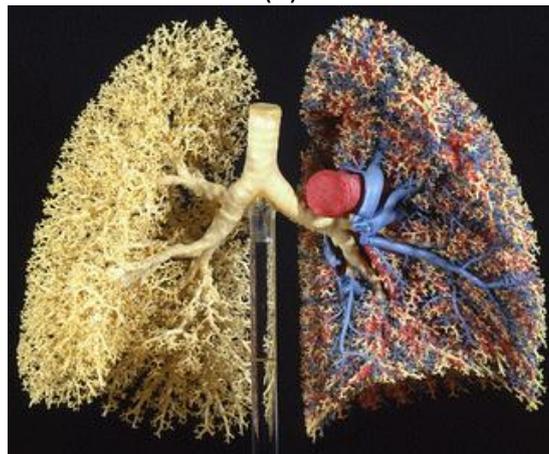
Considera-se uma curva auto-similar aquela que em qualquer segmento é, matematicamente, semelhante ao todo, isto é, ao se ampliar ou contrair, o objeto fractal é igualmente complexo, no todo ou no detalhe. Há muitos objetos auto-similares na Natureza como, por exemplo, uma árvore, uma paisagem litorânea ou os alvéolos de um pulmão, conforme ilustrados na Figura 18. Há também objetos fractais artificiais, criados computacionalmente, como a curva de Koch apresentada na Figura 17 e o conjunto de Mandelbrot, ilustrado na Figura 19.



(a)



(b)



(c)

Figura 18 – Objetos fractais encontrados na Natureza: (a) Árvore; (b) Paisagem litorânea; (c) Alvéolos pulmonares. - adaptado de <http://matematicanacidadela.blogspot.com/2007/06/fractais.html>

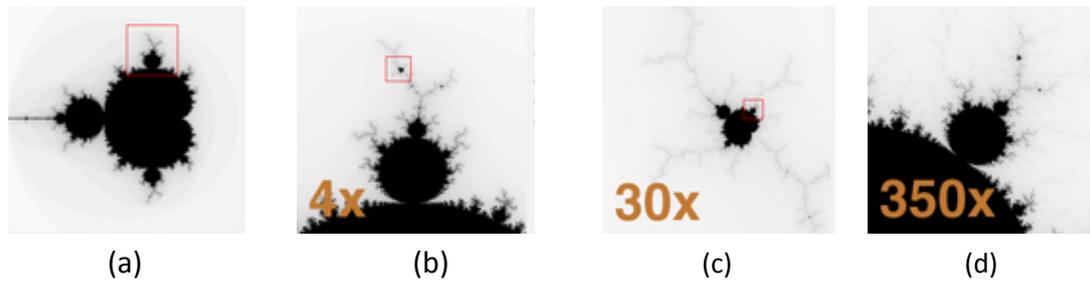


Figura 19 – Conjunto de Mandelbrot: (a) Todo o conjunto; (b) Aumento de zoom em 4x; (c) Aumento de zoom em 30x; (d) Aumento de zoom em 350x. Pode-se observar a auto-similaridade invariante à escala - adaptado de <http://pt.wikipedia.org/wiki/Fractal>

Percebe-se que há relação entre os conceitos de comprimento, dimensão e a auto-similaridade ao se examinar os métodos de representação de uma determinada curva  $C$  em uma determinada escala  $\varepsilon$ , quando se percorre esta curva com segmentos de reta  $R$  cujo comprimento é a própria escala (CARVALHO, M.C.C.S. e outros, 1986). Na Figura 20 está ilustrado este processo para três escalas diferentes, onde se pode observar que quanto maior a escala, menor é a quantidade de segmentos de reta necessário para percorrer a curva. Logo, quanto maior a escala, menor é o detalhamento e precisão do percurso.

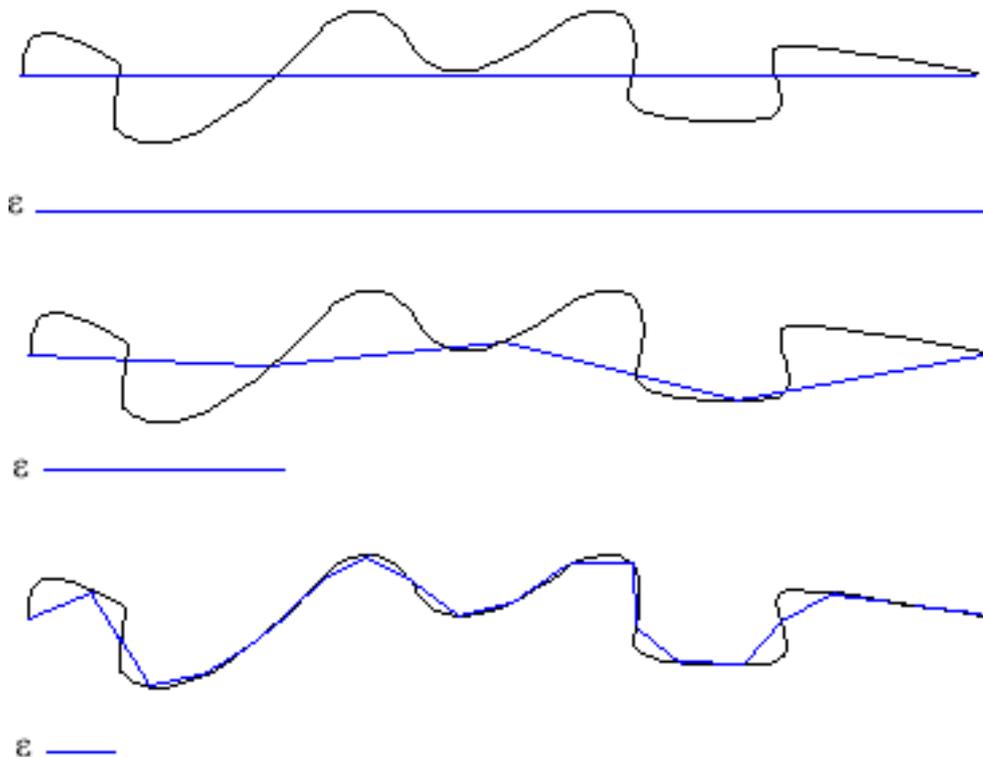


Figura 20 - Processo para representar o comprimento de uma curva qualquer, percorrendo o traçado com segmentos de retas cujo comprimento é a escala  $\varepsilon$ . – Adaptado de (CARVALHO, M.C.C.S. e outros, 1986).

Portanto, o comprimento da curva  $C(\varepsilon)$ , na escala  $\varepsilon$ , pode ser definido pela equação (CARVALHO, M.C.C.S. e outros, 1986):

$$C(\varepsilon) = \varepsilon \cdot R(\varepsilon), \quad (7)$$

onde  $R(\varepsilon)$  é o número de segmentos de reta de comprimento  $\varepsilon$  necessário para percorrer a curva de um extremo ao outro, sendo que a definição da escala  $\varepsilon$  seja tal que  $R(\varepsilon)$  seja um número inteiro positivo. Então, o comprimento total da curva  $C$  será definido por:

$$C = \lim_{\varepsilon \rightarrow 0} R(\varepsilon), \quad (8)$$

Sabe-se que a propriedade de auto-similaridade está ligada com a noção intuitiva de outro conceito da Geometria, a dimensão, que será descrita a seguir (CARVALHO, M.C.C.S. e outros, 1986).

### 3.2 Dimensão Fractal

Na geometria clássica é possível medir as dimensões euclidianas de um determinado objeto de maneira muito intuitiva, tal como o comprimento de uma reta ou a área de um losango. É, também, com certa facilidade que se consegue comparar as dimensões entre estas formas e extrair informações para determinar se uma forma ocupa um espaço maior do que outra ou se uma forma está contida no espaço bidimensional enquanto a outra está contida no espaço tridimensional, ou seja, enquanto uma forma possui altura e largura a outra possui também profundidade. Porém, na Geometria Fractal a maioria das aplicações se baseia na Dimensão Fractal ( $DF$ ), para descrever esse conceito geométrico, principalmente, em sistemas de análise de imagens. A dimensão fractal possui um significado diferente. Não é possível afirmar que um objeto que tem uma dimensão fractal maior ocupe um espaço maior. Portanto, ao se comparar as dimensões fractais de objetos diferentes, na verdade, compara-se a complexidade destes objetos, o que não implica que estes objetos sejam semelhantes visualmente.

A dimensão fractal é um número fracionário que pode representar a complexidade de um objeto, a aspereza de uma superfície, a área de contato entre a superfície e o meio e serve também como parâmetro de comparações entre imagens.

A dimensão fractal é utilizada como medida para formas complexas que não podem ser medidas utilizando-se as dimensões topológicas, ou seja, a dimensão fractal surgiu como

alternativa de medição de formas complexas já que ela pode resultar em valores fracionários, ao contrário da Geometria Euclidiana, em que as dimensões topológicas de um ponto é 0, a reta tem dimensão 1, o plano tem dimensão 2 e o espaço usual tem dimensão 3. Pode-se afirmar que a dimensão fractal de um objeto é um valor que representa de maneira subjetiva a sensação que se tem do volume ocupado pelo objeto no espaço métrico em que esse objeto fractal reside (BARNSELY, M.F., 1989). Isto é, com a dimensão fractal é possível se estimar, por exemplo, a superfície de uma bolinha de papel amassado ou da Curva de Koch, citada anteriormente, que tem sua dimensão aproximada de 1,26.

Objetos da Geometria Euclidiana também têm a propriedade de ser descritas por partes menores similares como, por exemplo, um segmento de reta pode ser dividido em  $R$  partes idênticas reduzidas por um fator  $\varepsilon$ , portanto,

$$\varepsilon = 1/R. \quad (9)$$

Aplicando o conceito em um objeto bidimensional como um quadrado, por exemplo, o fator de redução seria  $\varepsilon = 1/\sqrt{R}$  e para um cubo, que é um objeto tridimensional, o fator seria  $\varepsilon = 1/\sqrt[3]{R}$ . Então, a dimensão  $DF$  de um objeto auto-similar dividido em  $R$  partes idênticas reduzidas pelo fator  $\varepsilon$  pode ser definida pela equação

$$\varepsilon = 1/\sqrt[DF]{R}, \quad (10)$$

que pode ser escrita como:

$$\varepsilon \cdot \sqrt[DF]{R} = 1,$$

ou, elevando os membros a  $DF$ , tem-se

$$\varepsilon^{DF} \cdot R = 1.$$

Aplicando-se o logaritmo decimal para se obter o valor de  $DF$  da equação exponencial acima, tem-se

$$\log(\varepsilon^{DF} \cdot R) = \log 1$$

$$\log \varepsilon^{DF} + \log R = \log 1,$$

isto é,

$$DF \cdot \log \varepsilon + \log R = 0$$

então

$$DF = \frac{-\log R}{\log \varepsilon} = \frac{\log R}{-\log \varepsilon} = \frac{\log R}{\log \varepsilon^{-1}}.$$

Portanto,

$$DF = \frac{R}{\log\left(\frac{1}{\varepsilon}\right)}.$$

Segundo Mandelbrot (MANDELROT, B.B., 1982), um fractal é definido como um conjunto para o qual a dimensão de *Hausdorff-Besicovitch* ( $D_h$ ) é maior que a dimensão topológica ( $D_t$ ), sendo a dimensão  $D_h$  definida pela razão logarítmica entre o número de  $R$  partes do objeto, com razão de redução  $\varepsilon$ :

$$D_h = \frac{\ln R}{\log\left(\frac{1}{\varepsilon}\right)}. \quad (11)$$

Alguns trabalhos como (GU, H. Y. ET AL, 2005) utilizam a dimensão fractal para extrair informações sobre as características das texturas das íris e representá-las em vetores multidimensionais para classificação. Há também o trabalho de (PENTLAND, A.P., 1984), que sugere que é possível calcular a área de superfícies irregulares, tais como superfícies de montanhas, água, plantas, árvores, entre outras, através das imagens dessas superfícies utilizando a dimensão fractal. Pentland (PENTLAND, A.P., 1984) sugere, na verdade, que a dimensão fractal de uma superfície corresponde quase que exatamente à nossa idéia intuitiva de rugosidade ou aspereza. Ao observar o gráfico de superfícies ilustrado na Figura 21 (PENTLAND, A.P., 1984) e o gráfico de superfícies de imagens de íris utilizadas neste trabalho, mostrado na Figura 22, intuitivamente é possível afirmar que o uso da dimensão fractal em imagens de íris é extremamente plausível. Assim como o uso da dimensão fractal em outros trabalhos que realizam análises de texturas em imagens médicas a fim de auxiliar em diagnósticos. Esta aplicabilidade e a relevância da geometria fractal em análises de imagens médicas se justificam pelo fato da auto-similaridade existir com bastante ênfase em imagens de objetos biológicos com resolução finita (LOPES, R.; BETROUNI, N., 2009). Em outras palavras, a geometria fractal possui a habilidade de descrever e caracterizar a complexidade de imagens ou a composição de sua textura.

Existem vários métodos para se computar a dimensão fractal em análises de imagens, cada método tem sua própria base teórica e, por isso, diferentes dimensões são obtidas por diferentes métodos para as mesmas características. Isto ocorre porque a dimensão *Hausdorff-*

*Besicovich* não é calculada, na maioria dos casos, como na Equação (11), ou seja, diferentes métodos utilizam diferentes algoritmos para estimar o parâmetro  $R$  que escreve as partes idênticas reduzidas (LOPES, R.; BETROUNI, N., 2009). Porém, utilizam basicamente os mesmos passos básicos: mede-se as quantidades do objeto usando vários tamanhos de escala; analisa-se o gráfico *log versus log* ajustado por uma regressão linear de todos os pontos, usando os mínimos-quadrados; e estima-se a  $DF$  através do ângulo de inclinação da regressão linear.

Dentre os diversos métodos, foram escolhidos três que possuem destaque na literatura para se investigar texturas em imagens, são eles: *Box-Counting*, *Covering Blanket* e Área de Superfície de Prisma Triangular (PTPSA). Esses métodos serão mais bem descritos no Capítulo 4 deste trabalho, depois de uma melhor compreensão do tipo de imagem e informação relevante preservados em um sistema de reconhecimento para análise de íris.

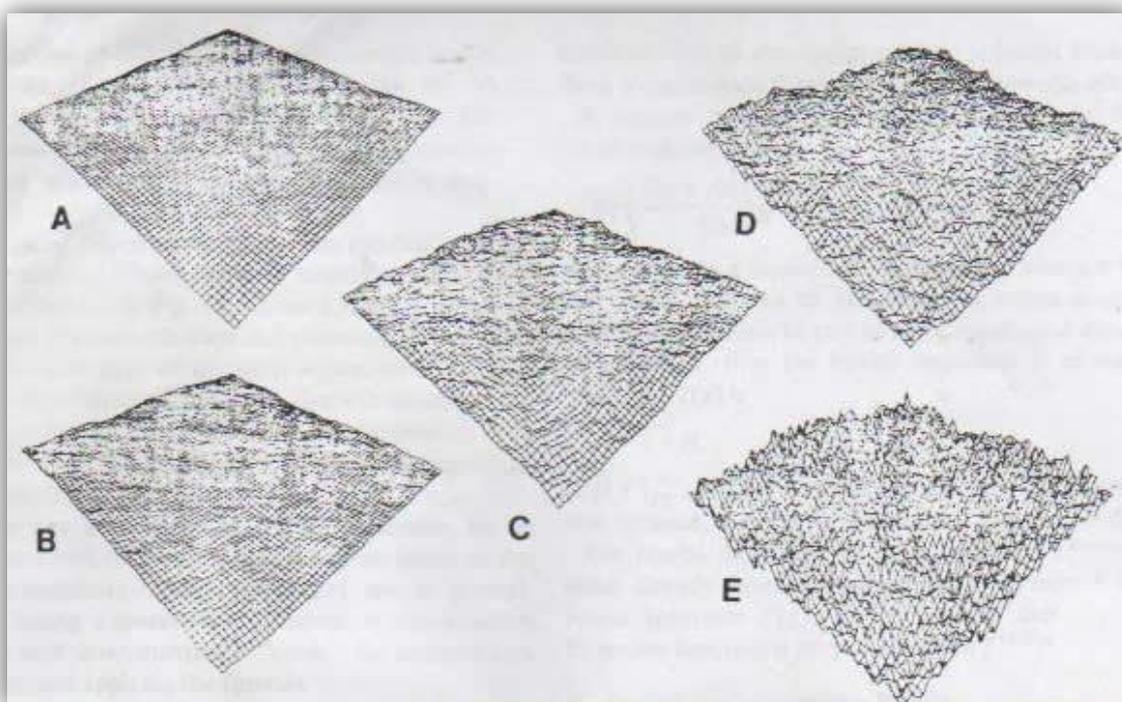


Figura 21 – Gráfico de superfícies em que a dimensão fractal vai aumentando no sentido de (A) a (E). (Adaptado de PENTLAND, A.P., 1984).

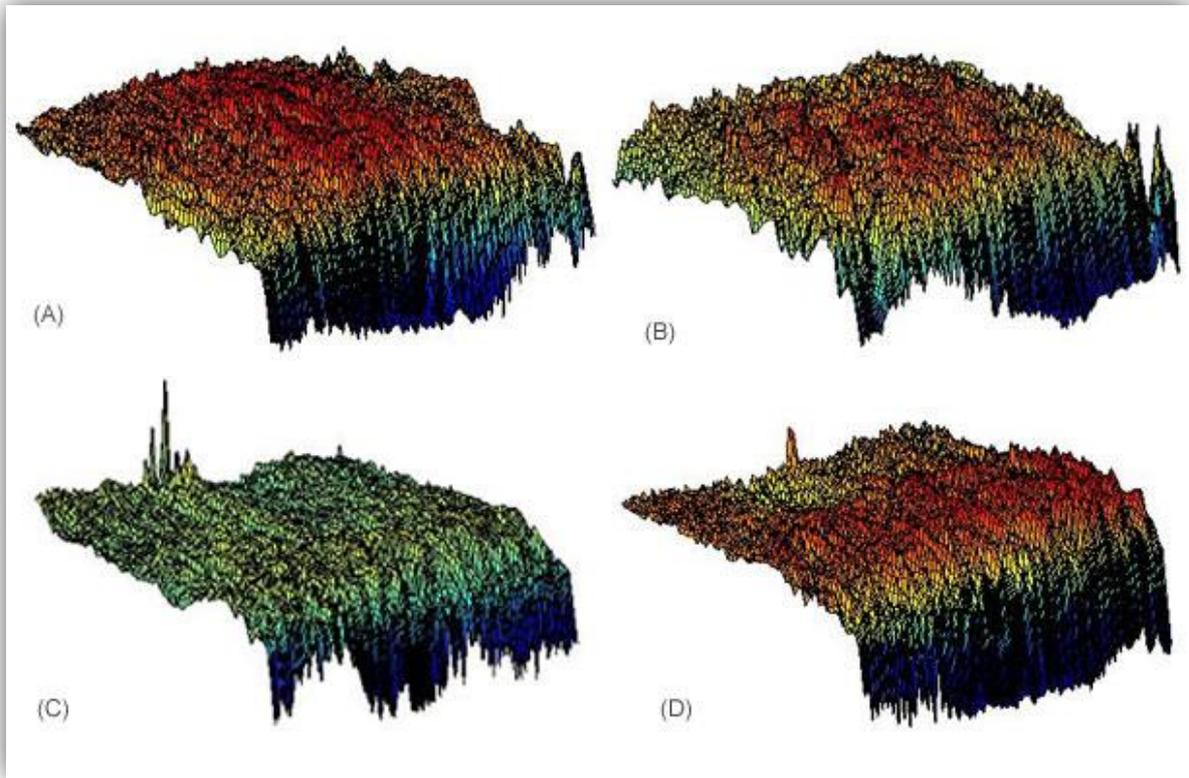


Figura 22 – Gráfico de superfícies de quatro imagens distintas de íris em tons de cinza, representando as intensidades dos pixels.

#### 4 TEXTURA, MÉTODOS ESTATÍSTICOS E FRACTAIS

A textura é uma propriedade da imagem que descreve o padrão de variação das intensidades dos pixels em uma imagem digital. Em outras palavras, a textura é a variação dos tons de cinza ou das cores de uma determinada imagem. A caracterização de uma textura se dá pela repetição de certos comportamentos sobre uma determinada parte da imagem. Este modelo pode se repetir de maneira idêntica ou com frações do comportamento sobre um mesmo tema. A partir de como esses comportamentos variam é que se pode, por exemplo, identificar texturas diferentes (NUNES, E. O.; CONCI, A., 2001). Alguns sistemas de reconhecimento automático de pessoas por biometria como, por exemplo, o reconhecimento por faces, se baseiam em formas geométricas presentes na imagem ao invés da textura, como, por exemplo, o reconhecimento de íris (Figura 23b).

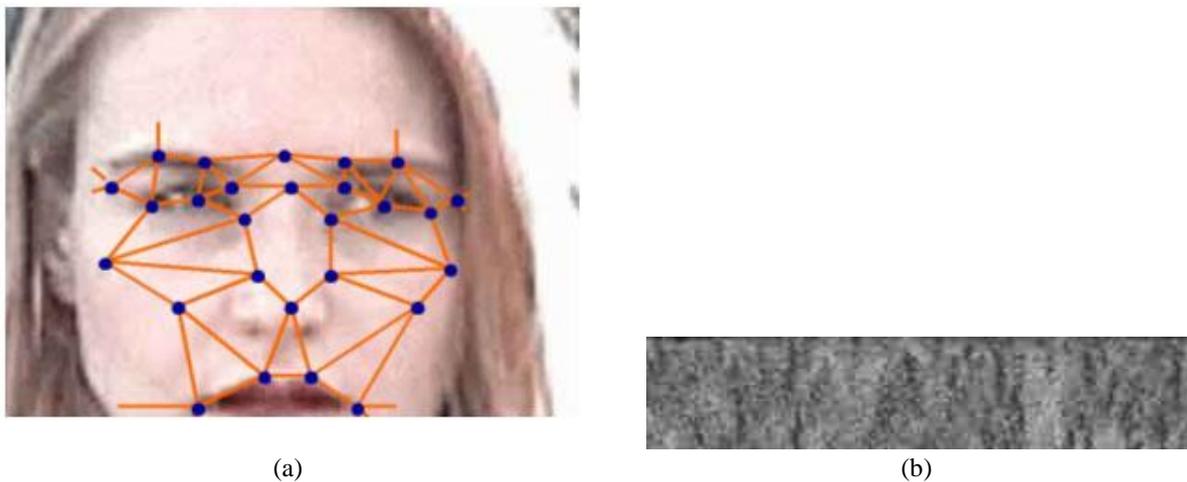


Figura 23 – (a) Imagem de face, onde o reconhecimento pode ocorrer pela localização de estruturas da face baseando-se em formas – adaptado de <http://www.brasiliano.com.br/>; (b) Imagem de íris, onde o reconhecimento ocorre por características extraídas da textura – Imagem retirada do banco de imagens UBIRIS v1 (PROENÇA, H.; ALEXANDRE, L.A. 2005).

Nas próximas seções deste capítulo, são descritos os métodos utilizados neste trabalho a fim de estudar o comportamento da textura de imagens de íris. Primeiramente, fora explorado um método para a otimização do contraste das imagens chamado Equalização de Histograma (GONZALEZ, R.; WOODS, R., 1992), normalmente utilizado em etapas de pré-processamento em métodos de reconhecimentos de padrões. Posteriormente, descreve-se um método estatístico muito utilizado para extração de características em reconhecimentos de padrões, conhecido como Análise de Componentes Principais (JOHNSON, R.A.; WICHERN,

D.W., 1998). Por fim, apresenta-se detalhes dos métodos fractais denominados: *Box-Counting*, *Covering Blanket* e Área de Superfície de Prisma Triangular.

#### 4.1 Equalização de Histograma

Para evidenciar a quantidade de informação relativa à textura existente nas imagens de íris normalizadas, investigou-se o método de equalização de histograma (EH) (GONZALEZ, R.; WOODS, R., 1992; MA, L., 2003). Este método tem como objetivo aperfeiçoar o contraste de cada imagem previamente normalizada.

A equalização adaptativa de histograma utilizada consiste em realçar o contraste da imagem operando em regiões pequenas de  $n \times m$  pixels, onde  $n$  e  $m$  têm de ser múltiplos de 2. O método consiste em utilizar uma janela  $w$  de tamanho  $n \times m$  e realizar uma operação de convolução na imagem gerando subimagens de mesmo tamanho. Para cada janela  $w$  são desconsiderados os pixels cujos valores são iguais a zero e contabilizado a repetição de cada valor de pixel, através do cálculo do histograma desta subimagem  $w$  (Figura 25), conforme exemplificado para uma janela  $w$  de dimensão  $8 \times 8$  (Figura 24).

$$w = \begin{array}{|c|c|c|c|c|c|c|c|} \hline \mathbf{52} & 55 & 61 & 66 & 70 & 61 & 64 & 73 \\ \hline 63 & 59 & 55 & 90 & 109 & 85 & 69 & 72 \\ \hline 62 & 59 & 68 & 113 & 144 & 104 & 66 & 73 \\ \hline 63 & 58 & 71 & 122 & \mathbf{154} & 106 & 70 & 69 \\ \hline 67 & 61 & 68 & 104 & 126 & 88 & 68 & 70 \\ \hline 79 & 65 & 60 & 70 & 77 & 68 & 58 & 75 \\ \hline 85 & 71 & 64 & 59 & 55 & 61 & 65 & 83 \\ \hline 87 & 79 & 69 & 68 & 65 & 76 & \boxed{78} & 94 \\ \hline \end{array}$$

Figura 24 – Subimagem  $w$  de dimensão  $8 \times 8$  de uma imagem qualquer em tons de cinza.

Em seguida, calcula-se a distribuição para cada um dos pixels através de uma função conhecida como função de distribuição acumulativa ( $fda$ ), pela qual são desconsiderados os pixels que não contribuem para um aumento da  $fda$ . A  $fda$  também mostra os pixels com maior (154) e menor (52) valores na subimagem. E então, o  $fda$  de  $w$ , ilustrado na Figura 26, deve ser normalizado entre os valores  $[0, 255]$  utilizando a equação:

$$h(n) = \text{round} \left( \frac{fda(n) - fda_{min}}{(n \times m) - fda_{min}} (L - 1) \right), \quad (12)$$

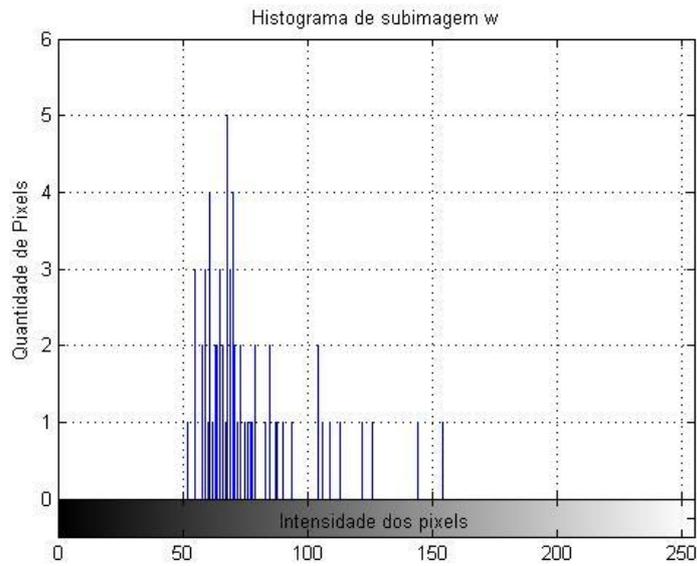


Figura 25 – Histograma da subimagem  $w$  ilustrada na Figura 24.

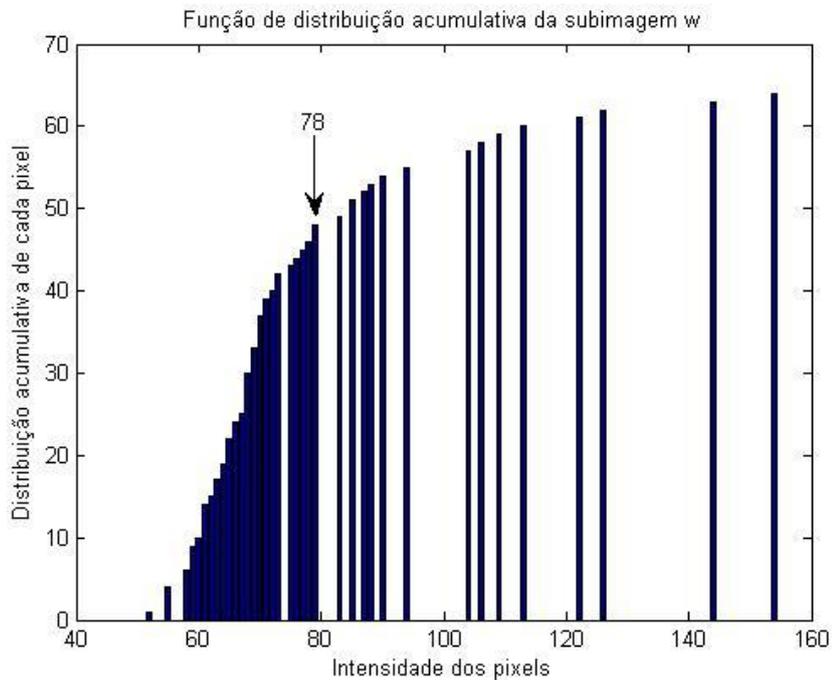


Figura 26 – Função de distribuição acumulativa ( $fda$ ) da subimagem  $w$  ilustrada na Figura 24.

onde  $round$  é uma função de arredondamento,  $fda_{min}$  é o valor mínimo da função de distribuição acumulativa,  $n_{xm}$  o número de pixels observado (ou seja, a quantidade de pixels da janela  $w$ ) e  $L$  é o número de níveis de cinza da imagem original, isto é,  $L = 256$ . A função

calcula o novo valor do pixel após a equalização. O resultado da equalização de histograma da janela  $w$  ilustrada na Figura 24 pode ser observado na Figura 27.

$$w = \begin{array}{|c|c|c|c|c|c|c|c|} \hline 0 & 12 & 53 & 108 & 93 & 146 & 73 & 166 \\ \hline 65 & 32 & 12 & 215 & 235 & 202 & 130 & 158 \\ \hline 57 & 32 & 117 & 239 & 251 & 227 & 93 & 166 \\ \hline 65 & 20 & 154 & 243 & 255 & 231 & 146 & 130 \\ \hline 97 & 53 & 117 & 227 & 247 & 210 & 117 & 146 \\ \hline 190 & 85 & 36 & 146 & 178 & 117 & 20 & 170 \\ \hline 202 & 154 & 73 & 32 & 12 & 53 & 85 & 194 \\ \hline 206 & 190 & 130 & 117 & 85 & 174 & 182 & 219 \\ \hline \end{array}$$

Figura 27 – Resultado da equalização da subimagem  $w$  ilustrada na Figura 19.

Por exemplo, a  $fda$  de 78 é 46 e seu valor normalizado é 182, pois aplicando a equação (12)

$$h(78) = \text{round} \left( \frac{fda(78) - 1}{(64) - 1} (256 - 1) \right), \quad \text{então}$$

$$h(78) = \text{round} \left( \frac{46 - 1}{64 - 1} 255 \right) = 182.$$

Basicamente, o resultado visual é um realce na textura da íris, como pode ser observado na Figura 28. Esta figura ilustra uma imagem de íris retirada do banco de imagens CASIA (CASIA Íris Image Database) normalizada (Figura 28a), equalizada (Figura 28d), bem como os histogramas (Figura 28b e Figura 28e) destas imagens e as superfícies no plano tridimensional (Figura 28c e Figura 28f), isto é, considerando as intensidades dos pixels.

O método EH geralmente aumenta o contraste local das imagens, especialmente quando os dados da imagem são representados por valores próximos do contraste. Com este ajuste, as intensidades podem ser mais bem distribuídas no histograma. Isto permite que as áreas de contraste local mais baixo ganhem um contraste mais elevado sem afetar o contraste global. A equalização de histograma é realizada eficazmente espalhando para os pixels ao redor os valores mais freqüentes de intensidade. Esse método é particularmente útil para imagens com fundos e primeiros planos brilhantes ou ambos escuros, conforme se observa nas imagens de íris estudadas neste trabalho.

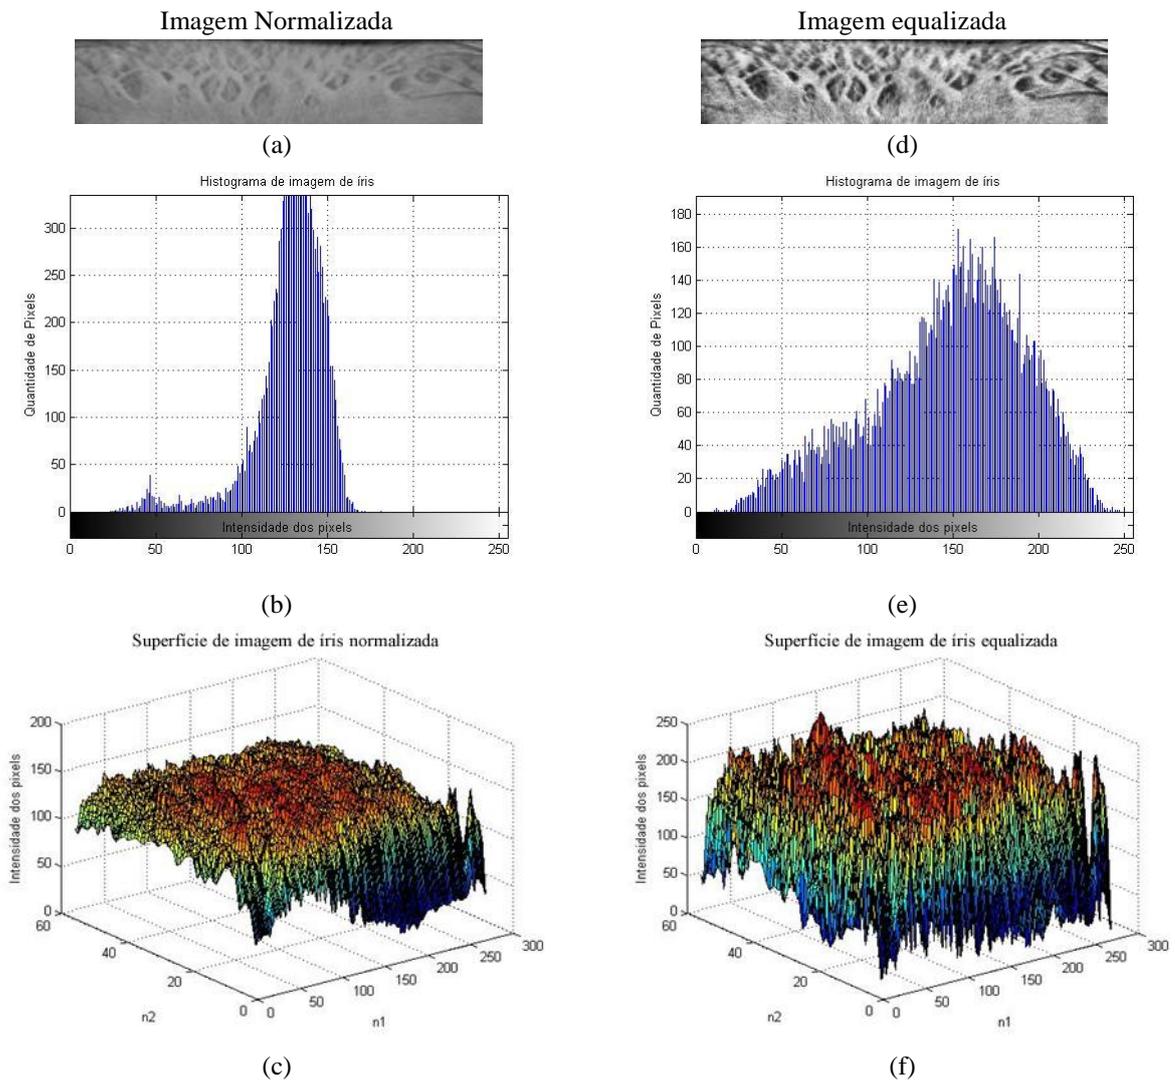


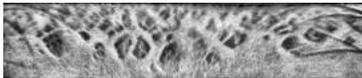
Figura 28- (a) Imagem normalizada de íris retirada de CASIA (CASIA Íris Image Database); (b) Histograma de imagem normalizada; (c) Gráfico de superfície de imagem normalizada; (d) Imagem equalizada de íris; (e) Histograma de imagem equalizada; (f) Gráfico de superfície de imagem equalizada.

## 4.2 Análise de Componentes Principais

A Análise de Componentes Principais, ou simplesmente PCA (*Principal Components Analysis*), é um método estatístico de extração de características que explica a estrutura de covariância de um conjunto de variáveis a partir da combinação linear de um número pequeno dessas variáveis. PCA é uma técnica de estatística multivariada bem conhecida e tem sido usada com sucesso em diversos problemas de reconhecimento de padrões em imagens, especialmente para redução de dimensionalidade (JOHNSON, R.A.; WICHERN, W.R, 1998).

Seja o problema em questão como exemplo para descrever a principal idéia da PCA. Em qualquer problema de reconhecimento em imagens, e particularmente em problemas que

envolvem medidas biométricas como, por exemplo, faces ou íris, uma imagem de  $n_1 \times n_2$  pixels pode ser entendida como um ponto no espaço  $n$ -dimensional denominado de espaço de imagens. As coordenadas deste ponto representam os valores de cada pixel na imagem e formam um vetor  $x^T = [x_1, x_2, \dots, x_{n_1 n_2}]$  obtido pela concatenação das linhas (ou colunas) da matriz de imagem correspondente. A Figura 29 ilustra esse procedimento em uma imagem de íris como exemplo. Sabe-se que imagens pré-processadas de padrões podem ser altamente redundantes pelo fato de que intensidades de pixels adjacentes são comumente correlacionadas. Como consequência, uma imagem de entrada com  $n_1 \times n_2$  pixels pode ser projetada em um espaço de dimensão menor sem perda significativa de informação.



$$= \begin{bmatrix} 150 & 152 & \dots & 153 \\ 154 & 153 & \dots & 155 \\ \vdots & \vdots & \vdots & \vdots \\ 254 & 255 & \dots & 252 \end{bmatrix}$$

$$x^T \equiv [150 \ 152 \ \dots \ 200 \ 205 \ 232 \ \dots \ 250 \ 248 \ 252]_{n_1 n_2}$$

Figura 29- Concatenação das linhas de uma imagem de íris para formação do vetor  $x^T$  ( $n_1 \times n_2$ )-dimensional.

Seja então uma matriz  $X$  de dados de dimensão  $N \times (n_1 \times n_2)$ , onde  $N$  representa o número de imagens e  $n_1 \times n_2$  o número de pixels em cada imagem. Esta representação considera que cada coluna da matriz  $X$  descreve os valores de cada pixel ao longo de todas as  $N$  imagens. Seja ainda essa matriz  $X$  com matriz de covariância  $S$  descrita por:

$$S = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})(x_i - \bar{x})^T, \quad (13)$$

onde  $x_i$  é o vetor imagem e  $\bar{x}$  o vetor média global das imagens, ou seja,

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i. \quad (14)$$

A matriz de covariância  $S$  pode ser decomposta espectralmente através da seguinte equação:

$$P^T S P = \Lambda, \quad (15)$$

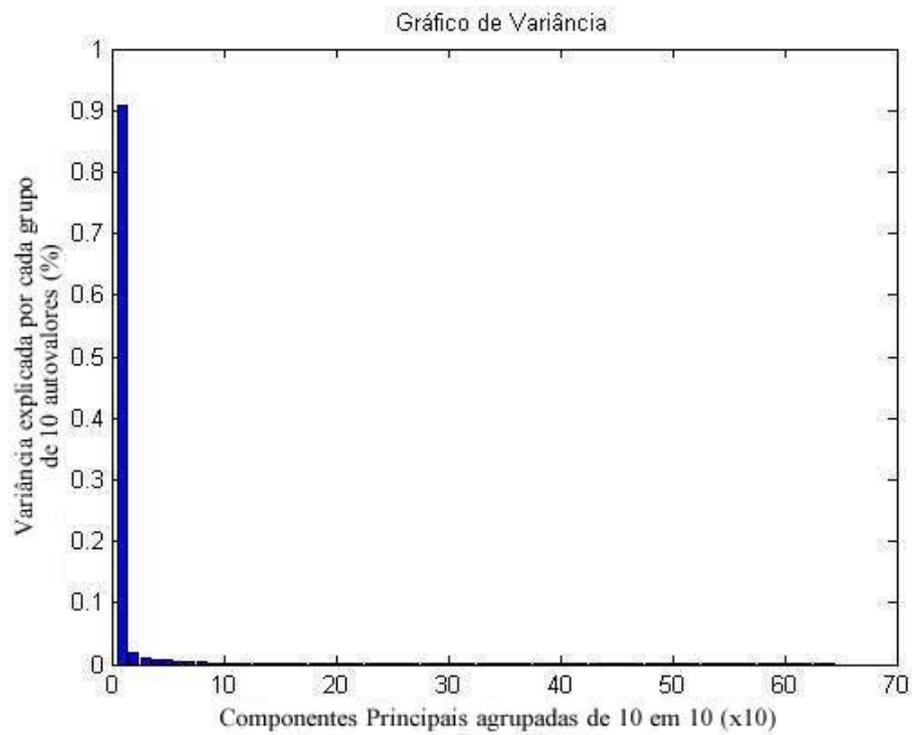
onde  $P$  e  $\Lambda$  são as matrizes de autovetores e autovalores, respectivamente, de  $S$ .

É um resultado provado na literatura (JOHNSON, R.A.; WICHERN, W.R, 1998) que o conjunto de  $l$  ( $l \leq (n1xn2)$ ) autovetores de  $S$ , que correspondem aos  $l$  autovalores máximos, minimiza o erro de reconstrução médio quadrático considerando todas as escolhas possíveis de bases ortonormais  $l$ -dimensionais. Tal conjunto de autovetores que define um novo sistema de coordenadas não-correlacionado para a matriz de dados  $X$  é conhecido como componentes principais. No contexto de reconhecimento de faces, por exemplo, essas  $P$  componentes são denominadas autofaces (TURK, M.; PENTLAND, A., 1991).

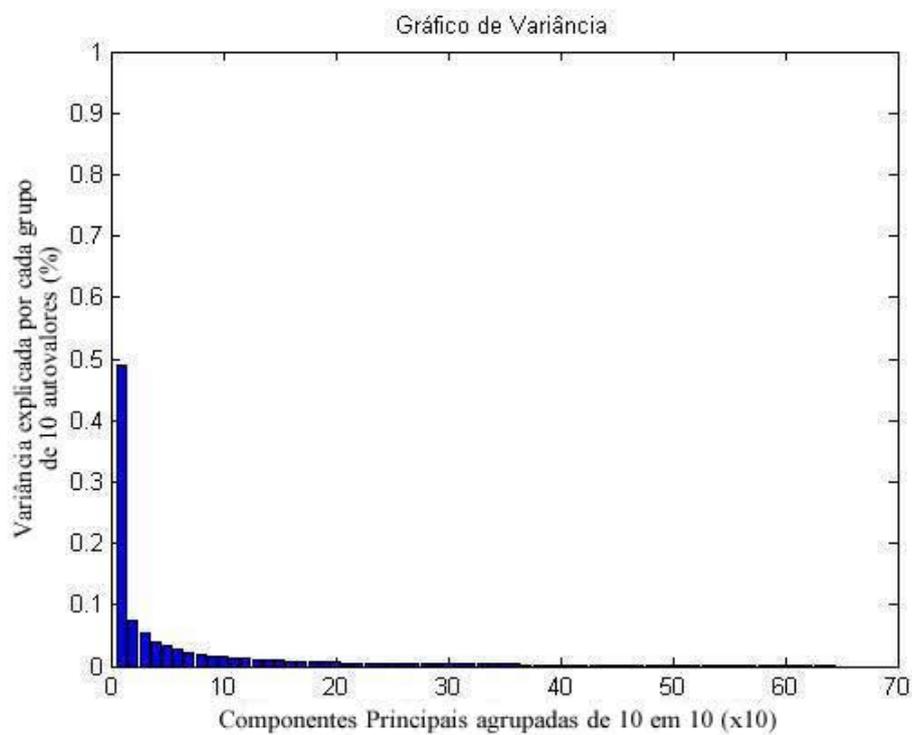
Portanto, embora  $n1xn2$  variáveis (ou pixels) sejam necessárias para reproduzir a variabilidade total (ou informação) do conjunto de imagens  $X$ , grande parte dessa variabilidade pode ser descrita por um número  $l$  menor de componentes principais. Assim, quanto menor for o número  $l$  de componentes principais capaz de representar, por exemplo, 70% ou 80% da variabilidade total das amostras, maior será a quantidade de informação redundante existente nas imagens. Por exemplo, a Figura 30 representa o agrupamento das componentes principais, de 10 em 10, de imagens de íris normalizadas e equalizadas retiradas do banco de imagens UBIRIS v1 (PROENÇA, H.; ALEXANDRE, L.A., 2005). Este cálculo pode ser obtido através da equação:

$$\text{Variancia explicada pelo autovetor}(i) = \frac{\lambda_i}{\sum_{j=1}^l \lambda_j}, \quad (16)$$

onde  $\lambda_i$  representa o autovalor da componente principal (ou autovetor)  $i$  e  $\lambda_1 \geq \lambda_2 \geq \dots \lambda_l$ . Pode-se verificar que na Figura 30a mais de 90% das informações contidas em imagens de íris normalizadas são explicadas pelas dez primeiras componentes apenas. Enquanto que na Figura 30b as dez primeiras componentes explicam apenas quase 50% das informações contidas nas imagens de íris equalizadas. Portanto, pode-se afirmar que a equalização de histograma elimina informações redundantes das imagens de íris, ou seja, as imagens equalizadas tornam-se mais discriminantes após o processo de equalização.



(a)



(b)

Figura 30 – Agrupamento das componentes principais de 10 em 10. Pode-se verificar que em (a) mais de 90% das informações contidas em imagens de íris normalizadas são explicadas pelas dez primeiras componentes apenas. Enquanto que em (b) as dez primeiras componentes explicam quase 50% apenas das informações contidas em imagens de íris equalizadas.

### 4.3 Métodos Fractais

Nesta seção serão descritos os métodos fractais estudados neste trabalho. O primeiro método é o Método *Box-Counting* (NUNES, E. O.; CONCI, A., 2001; COSTA, L.; BIANCHI, A. G. C., 2002), bastante utilizado para a medição da dimensão fractal em imagens binárias. O segundo método fractal é o *Covering Blanket* (PELI, T., 1990), utilizado para caracterização e classificação de imagens a partir de suas texturas. Por fim, o método Área de Superfície de Prisma Triangular (IFTEKHARUDDIN, K.M. et al, 2003), utilizado para extração de características fractais, é descrito.

#### 4.3.1 Método *Box-Counting*

Dentre os diversos métodos para se calcular a dimensão fractal, um dos métodos comumente utilizado para aplicações desse tipo é o método denominado *Box-Counting* (ou *Box dimension*) ou Contagem de caixas (NUNES, E. O.; CONCI, A., 2001; COSTA, L.; BIANCHI, A. G. C., 2002).

O método *Box-Counting* oferece um algoritmo simples para calcular a dimensão fractal. Este algoritmo considera uma imagem qualquer binarizada coberta por uma grade com um conjunto de quadrados simétricos, denominados células. Posteriormente, considera-se a quantidade de quadrados, representada por  $Q_\varepsilon$ , necessária para que toda a imagem seja coberta, sendo que a escala  $\varepsilon$  representa o número de vezes que a imagem será dividida, conforme ilustra a Figura 31.

Para cada grade são quantificadas as células que contém ao menos uma diminuta parte do objeto, ou seja, no caso células que contenham ao menos um pixel. Então, um gráfico é construído cujos pontos são as quantidades de células  $Q_\varepsilon$  de cada grade. O ângulo de inclinação da reta que interliga esses pontos será a dimensão fractal da imagem. O procedimento acima descrito pode ser calculado através da equação:

$$DF = \lim_{\varepsilon \rightarrow \infty} \log Q_\varepsilon(A) / \log 2^\varepsilon, \quad (17)$$

a qual realiza a contagem do número de quadrados da área  $Q_\varepsilon(A)$  de lado  $1/2^\varepsilon$  que cobrem a imagem binária  $A$  para  $\varepsilon$  escalas.

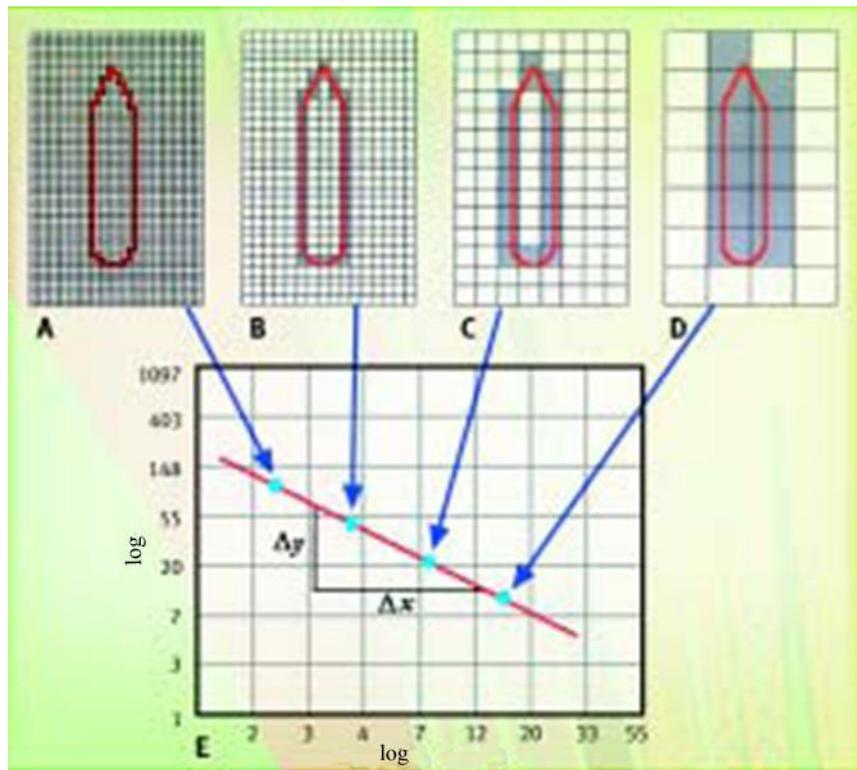


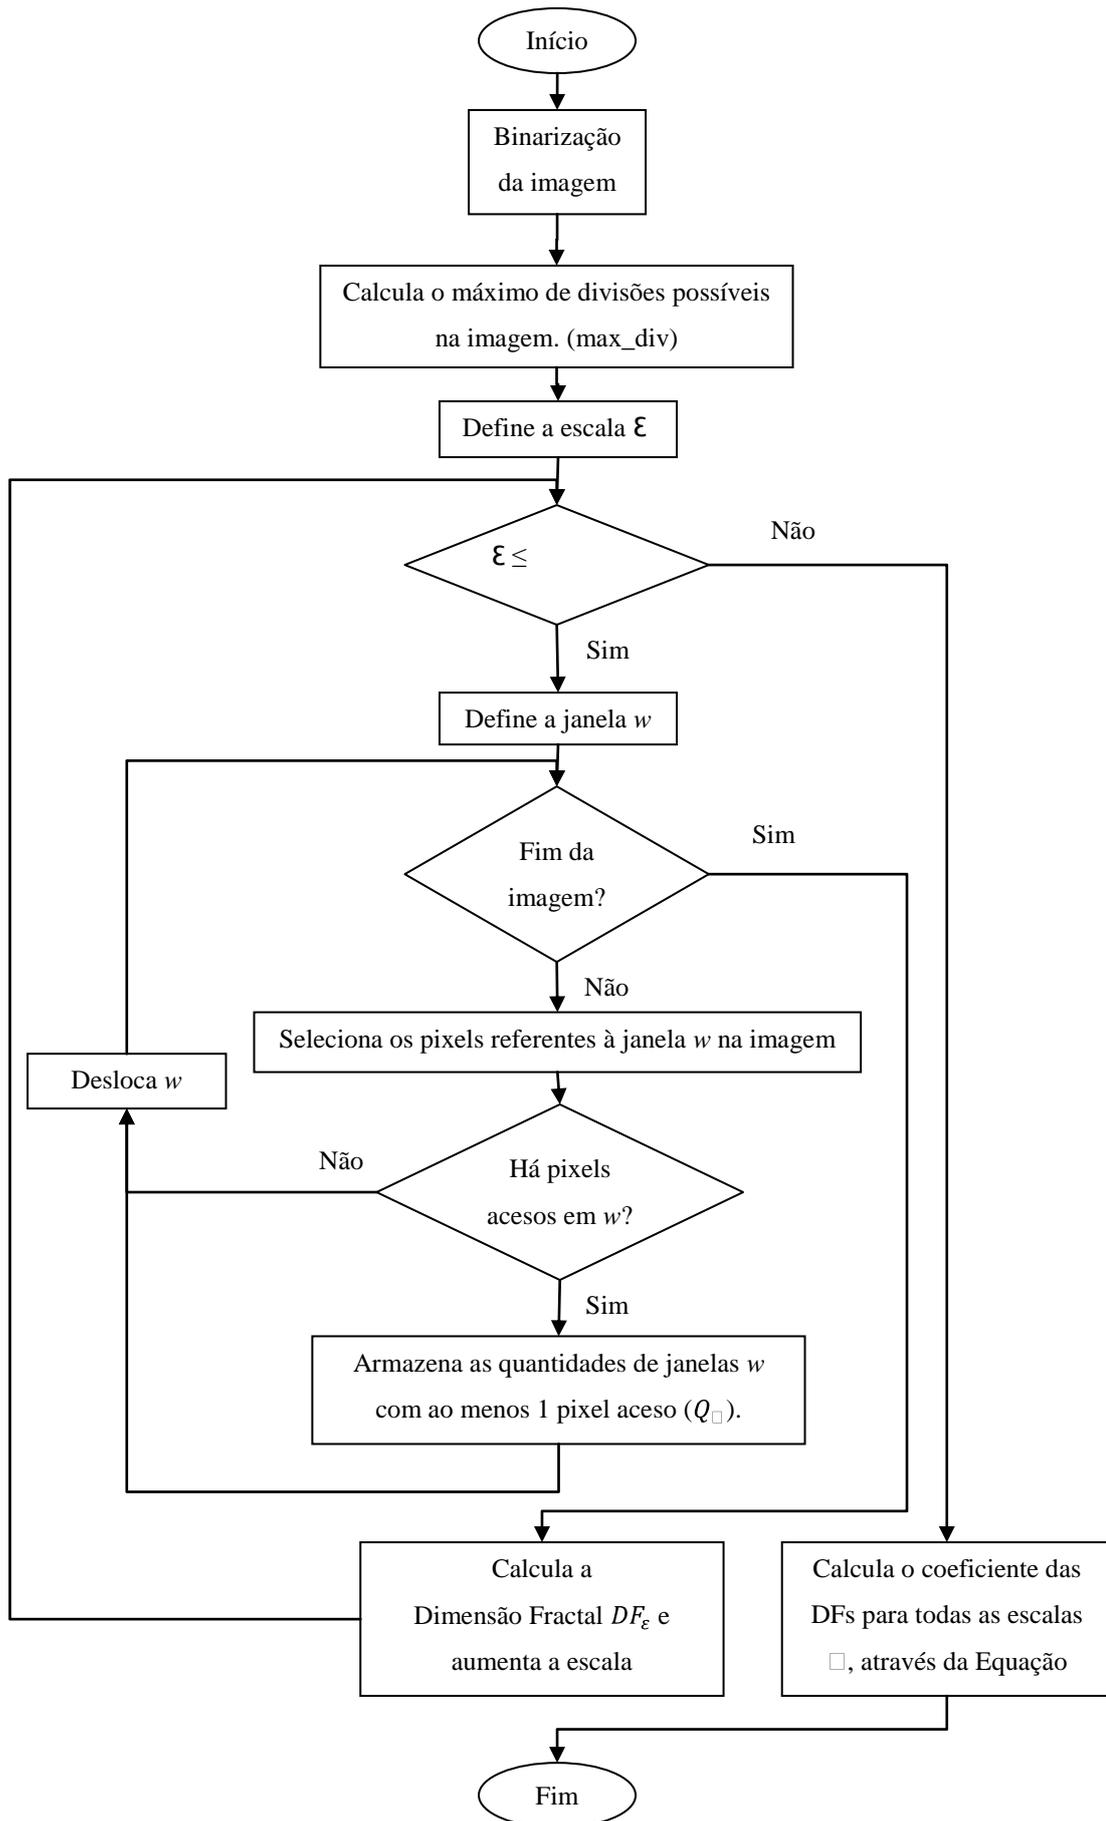
Figura 31 – A contagem dos quadrados  $Q_\epsilon$  que pertencem às grades nos itens de (A) até (D) – para cada tamanho de caixa gera-se pontos no gráfico em (E). Neste, o valor da dimensão fractal (DF) do objeto é obtido pela divisão dos lados ( $\Delta y/\Delta x$ ) do triângulo formado (Adaptado de COSTA, L.; BIANCHI, A. G. C., 2002).

Abaixo, descreve-se as principais etapas de um algoritmo para o cálculo da dimensão fractal pelo método *Box-Counting*:

#### **Algoritmo *Box-Counting***

**Entrada:** imagem em tons de cinza, escala.

**Saída:** Dimensão Fractal da imagem de entrada.



O método *Box-Counting* padrão possui uma grande limitação para descrever o comportamento das texturas das imagens uma vez que as imagens devem ser binarizadas e, conseqüentemente, no processo de binarização muitas informações contidas nas imagens são descartadas. A Figura 32 mostra esse efeito contextualizado no problema em questão.

Algumas imagens selecionadas do banco de imagens CASIA (CASIA Íris Image Database) referentes a 31 olhos diferentes, sendo 7 amostras de cada olho, foram submetidas ao método *Box-Counting* e o resultado está ilustrado no gráfico da Figura 33. Este gráfico descreve os valores mínimos, médios e máximos da dimensão fractal de imagens binarizadas de íris originalmente retiradas do banco de imagens CASIA (CASIA Íris Image Database). Pode-se observar pela aplicação do método *Box-Counting* que existe um comportamento fractal em imagens de íris, porém pelo fato de este método representar a fractalidade da imagem com apenas um número, a análise da fractalidade dessas imagens se torna insuficiente. Então, foram escolhidos métodos capazes de representar a fractalidade das imagens de íris através de uma assinatura fractal, como o método *Covering Blanket* e o método PTPSA.

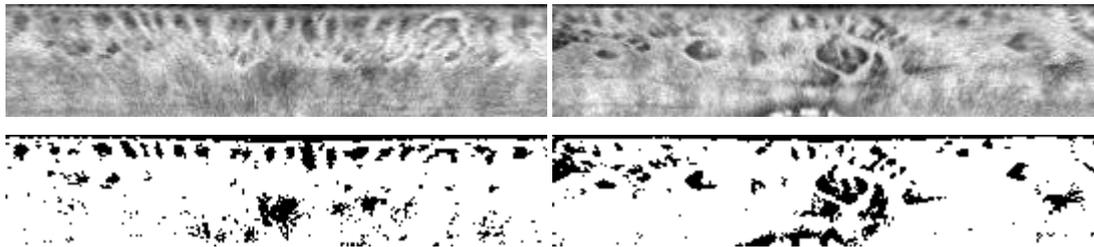


Figura 32 – Imagens normalizadas e equalizadas (superiores), e binarizadas (inferiores).

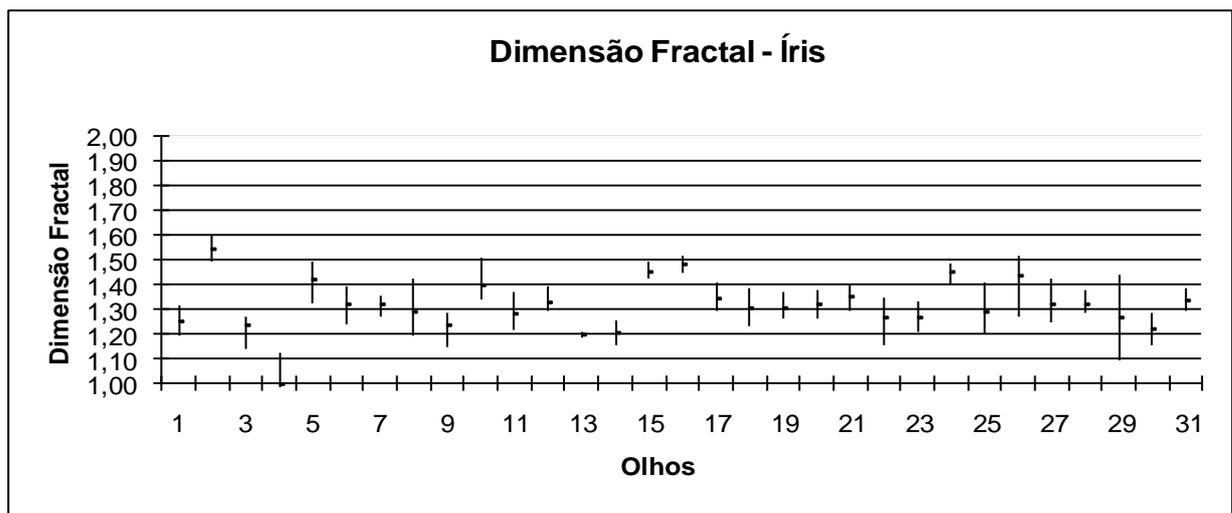


Figura 33 – Valores mínimos, médios e máximos de dimensões fractais de imagens de íris originalmente retiradas do banco de imagens CASIA (CASIA Íris Image Database).

#### 4.3.2 Método *Covering Blanket*

Um método utilizado para realizar a análise de textura em imagens através da dimensão fractal é o método denominado *Covering Blanket*, descrito em (PELI, T., 1990).

Em 1990, Peli (PELI, T., 1990) propôs este método para extrair as características fractais, denominadas assinatura fractal, de imagens naturais tais como imagens aéreas, de paisagens florestais e de nuvens, bem como de imagens de objetos artificiais tais como veículos e tanques de guerra. A partir de filtros morfológicos como, por exemplo, operações de erosão e dilatação, a extração de dimensões fractais das texturas tinha como objetivo caracterizar objetos e discriminá-los em objetos naturais (montanhas, árvores, rochas, etc.) ou artificiais (tanques de guerra).

Este método se mostrou eficiente para o problema investigado por Peli (PELI, T., 1990) porque através dele é possível explorar as medidas fractais tanto de texturas sutis como complexas para classificar as imagens ou discriminar objetos. Através deste trabalho, pode-se levar em consideração a terceira dimensionalidade das imagens, isto é, além da dimensão topológica de largura e altura das imagens são considerados, principalmente, os valores das intensidades dos pixels que as compõem.

A concepção deste método baseia-se na construção para cada pixel em tons de cinza (valores entre 0 e 255) da imagem de entrada, uma superfície superior  $U$  e outra inferior  $L$ , a partir de duas funções, definidas na Equação (18) ou através de operações de erosão e dilatação, para cada escala. A superfície superior contém os pixels cujos valores são sempre maiores e a superfície inferior contém os pixels cujos valores são sempre menores, dependendo da escala considerada. Por exemplo, para a escala zero as definições das superfícies superiores e inferiores são:

$$U(i, j, 0) = L(i, j, 0) = x(i, j),$$

sendo  $x(i, j)$  a imagem de entrada. Para as demais escalas, a definição é obtida recursivamente pelas equações:

$$U(i, j, \varepsilon + 1) = \max \left\{ U(i, j, \varepsilon) + 1, \max_{k, m \in \eta} [U(k, m, \varepsilon)] \right\} \quad (18)$$

$$L(i, j, \varepsilon + 1) = \min \left\{ L(i, j, \varepsilon) - 1, \min_{k, m \in \eta} [L(k, m, \varepsilon)] \right\},$$

onde

$$\eta = \{(k, m) | \text{distância}[(k, m), (i, j)] \leq 1\}.$$

Assim, para cada pixel  $(i, j)$  da imagem  $x$  é realizada a operação de máximo para as superfícies superiores e mínimo para as superfícies inferiores, entre os pixels vizinhos  $(k, m)$ , através do kernel  $\mu$  que considera apenas como vizinhos aqueles cuja distância entre eles seja  $\eta \leq 1$ , isto é, considera como vizinhos os pixels imediatamente ao lado nas direções vertical e horizontal:

$$\mu = \begin{matrix} & 0 & & \\ 0 & 1 & 0 & \\ & 0 & & \end{matrix}. \quad (19)$$

Considerando que quando  $\varepsilon = 0$  as camadas superior  $U$  e inferior  $L$  serão idênticas à imagem de entrada, os passos seguintes para o cálculo das camadas  $U$  e  $L$ , cujas escalas  $\varepsilon$  variam de 1 em 1, podem ser exemplificados pelos valores hipotéticos ilustrados na Figura 34.

Pode-se observar que no Passo 1, o primeiro pixel da imagem (em destaque) é comparado com os pixels a direita e abaixo, por operações de máximo e mínimo, para  $U$  e  $L$ , respectivamente. Por exemplo, o máximo entre 66, 58 e 100 será 100 e o mínimo será 58, então  $U(1,1) = 100$  e  $L(1,1) = 58$ . Para o Passo 2 são considerados os pixels a esquerda, a direita e abaixo e assim sucessivamente. Para enfatizar a troca de linha, observa-se que no Passo  $k$  são considerados os pixels acima, à direita e abaixo.

O resultado visual do *Covering Blanket* para dados 2D seria o que Peli (PELI, T., 1990) chama de superfície-área, obtida pelo cálculo da diferença de volume entre as superfícies superiores  $U$  e inferiores  $L$  dividida por  $2\varepsilon$ , para sucessivas escalas. A Figura 35 ilustra as superfícies  $U$  e  $L$  de uma imagem de íris, retirada do banco de imagens UBIRIS v1 (PROENÇA, H.; ALEXANDRE, L.A. 2005) convertidas para a dimensão 2D, calculando-se a média de cada coluna de pixel, convertendo a imagem e as superfícies em linhas.

A imagem em conjunto com as camadas superiores e inferiores referentes a uma determinada escala  $\varepsilon$  são subdivididas em janelas  $w$  de observação de tamanho  $n \times m$  e as áreas entre estas superfícies pertencentes a esta subdivisão  $w$  podem ser obtidas subtraindo-se, pixel a pixel, o ponto equivalente na borda inferior do ponto equivalente na borda superior para, em seguida, somar-se as diferenças, de acordo com a equação:

$$A_i(\varepsilon) = \frac{\sum_{i,j \in w} U(i,j,\varepsilon) - L(i,j,\varepsilon)}{2\varepsilon} = \frac{V(\varepsilon)}{2\varepsilon}, \quad (20)$$

onde  $A_i(\varepsilon)$  é a área entre as camadas  $U$  e  $L$  pertencente a subdivisão  $w$ .

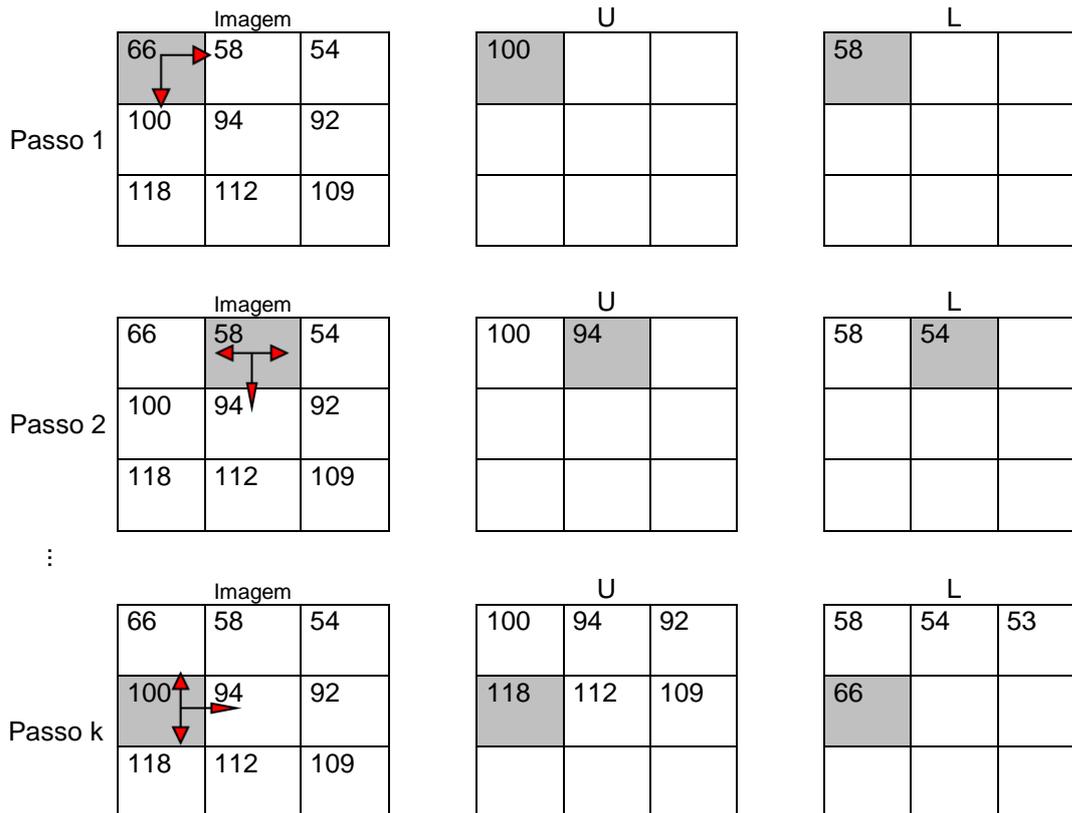


Figura 34 – Ilustração dos passos para o cálculo das camadas superior  $U$  e inferior  $L$  para escalas maiores do que zero através do kernel  $\mu$  considerando como vizinhos os pixels imediatamente ao lado nas direções vertical e horizontal.

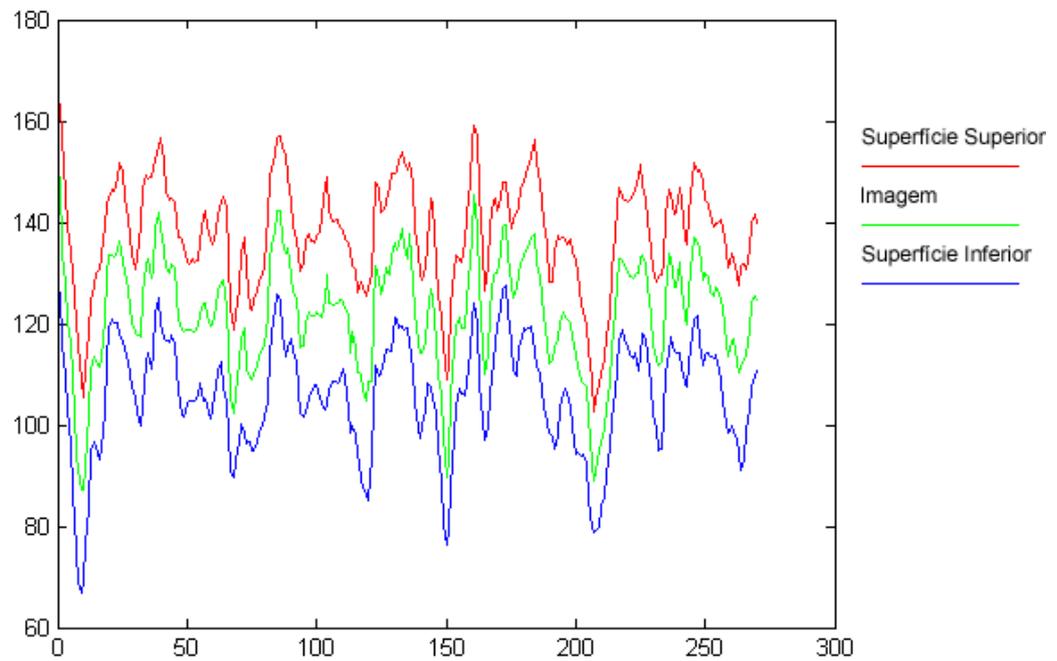
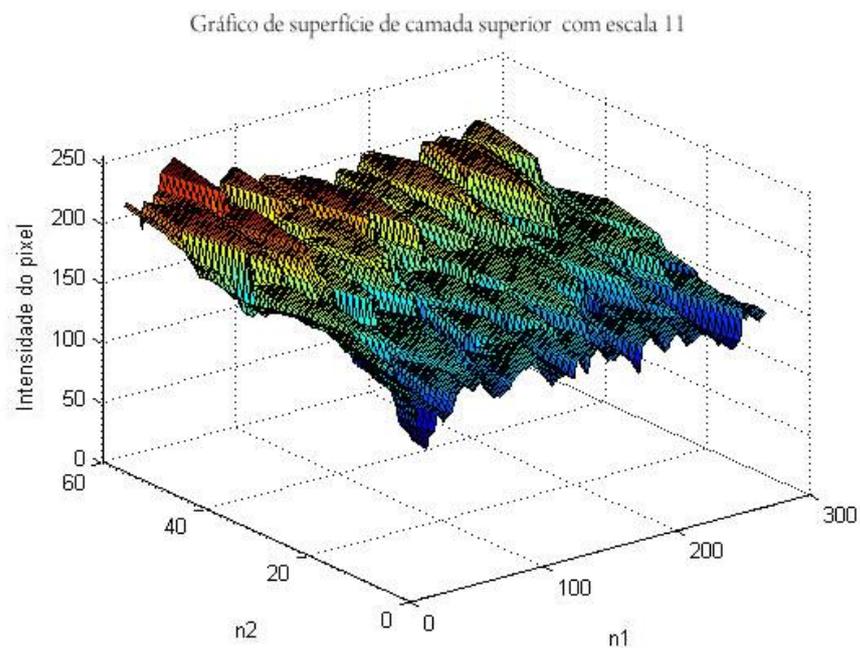


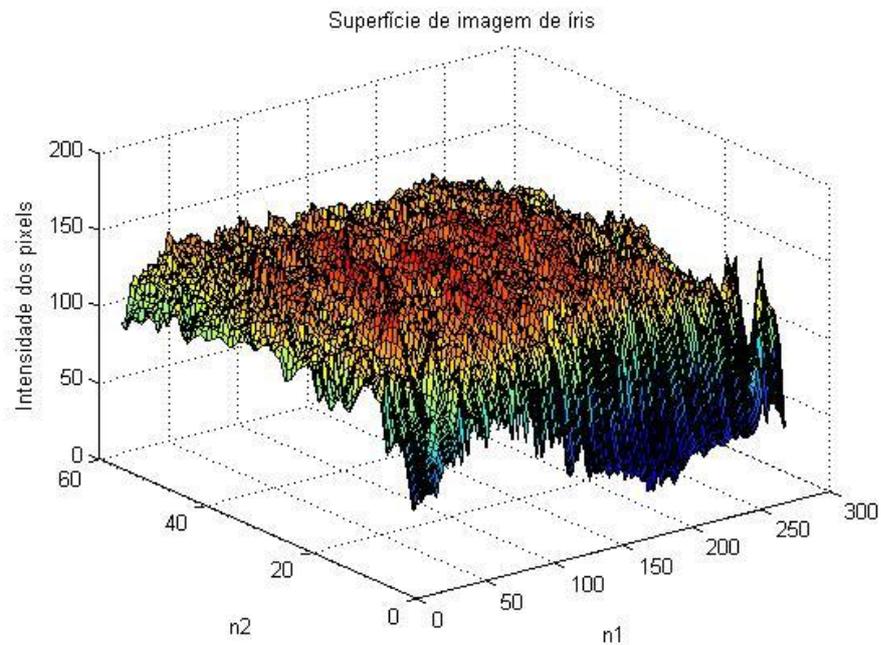
Figura 35 - Imagem de íris equalizada retirada do banco de imagens UBIRIS v1 (PROENÇA, H.; ALEXANDRE, L.A. 2005) convertidas para a dimensão 2D, calculando-se a média de cada coluna de pixel, convertendo a imagem e as superfícies em linhas.

Para as imagens que são objetos tridimensionais, ou seja, considerando os valores dos pixels como a terceira dimensão, o resultado seria toda a área ocupada entre as camadas superiores e inferiores, considerando apenas os pixels que estão dentro da subdivisão  $w$  e a estimação da dimensão fractal  $DF$  pode ser obtida pela razão entre  $\log[A_i(\varepsilon)]$  e  $\log(\varepsilon)$ . A

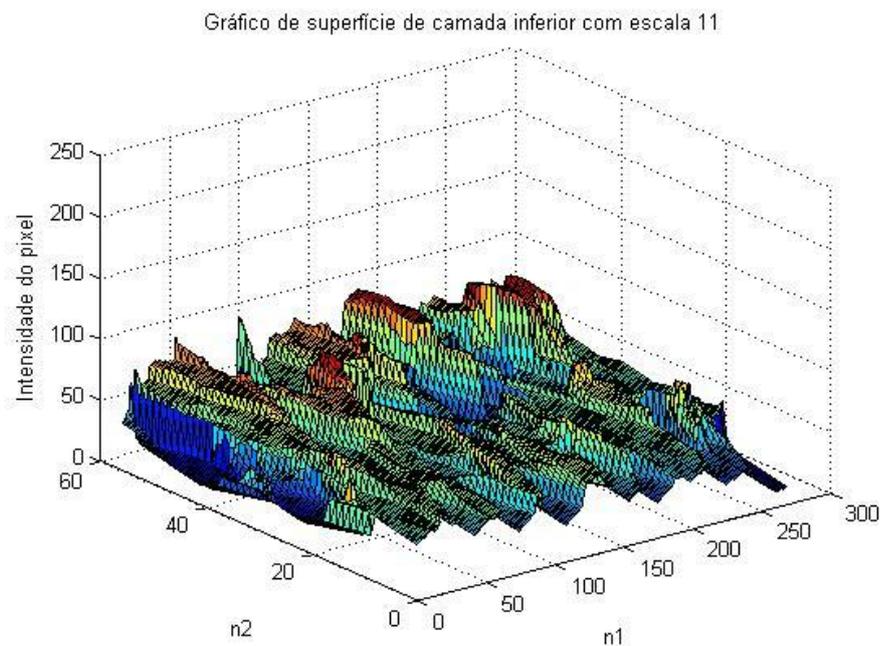


(a)

Figura 36 ilustra um exemplo deste cálculo para  $\varepsilon = 11$  e  $w = 3$ , sendo a Figura 36a a camada superior, Figura 36b a imagem de íris equalizada retirada do banco de imagens UBIRIS v1 (PROENÇA, H.; ALEXANDRE, L.A. 2005) e Figura 36c a camada inferior.



(b)



(c)

Figura 36 – (a) Camada superior com escala igual a 11, (b) imagem original e (c) camada inferior com escala igual a 11, em 3D.

Assim, diferentemente do método *Box-Counting* cujo resultado é um valor único da dimensão fractal para toda a imagem e menor ou igual à dimensão topológica, conforme descrito anteriormente, o algoritmo baseado em *Covering Blanket* tem como resultado uma matriz com as mesmas dimensões topológicas da imagem de entrada, porém, ao invés de valores de pixels entre 0 e 255 na composição, há valores entre 1 e 3 sendo estes valores as dimensões fractais locais, isto é, as dimensões fractais de cada pixel em relação aos seus vizinhos limitados pela janela  $w$  de observação.

A complexidade ou rugosidade das imagens podem variar em diferentes escalas utilizadas. Segundo (PELI, T., 1990), se imagens podem ser caracterizadas por uma auto-similaridade limitada, então a assinatura fractal pode descrever, por deslocamento e por forma, a complexidade da superfície em função da escala. Ou seja, essas assinaturas indicam que a textura de imagens de uma mesma classe (imagens de nuvens, por exemplo) resultam em assinaturas fractais similares, enquanto que a assinatura fractal difere mais para classes diferentes. Peli (PELI, T., 1990) confirmou a consistência deste comportamento da assinatura fractal avaliando imagens de nuvens de duas classes diferentes e as assinaturas fractais podem ser observadas no gráfico abaixo.

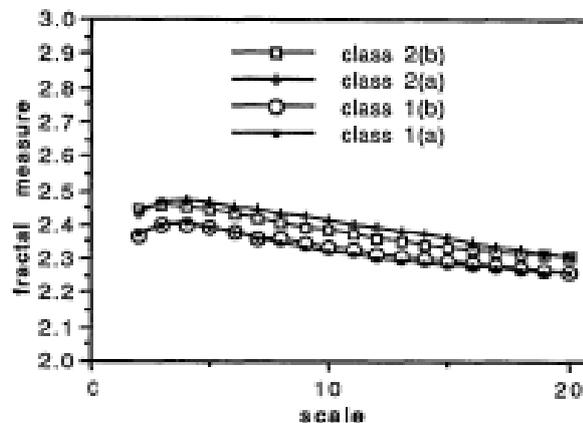


Figura 37 – Assinaturas fractais de quatro imagens de duas classes de nuvens. Adaptado de (PELI, T., 1990)

Sendo assim, o método *Covering Blanket* pode ser usado para classificar imagens a partir de suas características fractais que representam a complexidade da imagem. Ou seja, espera-se que imagens intraclasses possuam complexidade semelhante e o contrário deve acontecer com imagens extraclasses.

A capacidade de discriminação do método *Covering-blanket* também pode ser observada em imagens de paisagens naturais e de objetos artificiais, a partir de suas assinaturas fractais, isto é, quando em escalas baixas são exibidas informações similares em

imagens intraclasses e certa separação em imagens extraclasses. Em imagens naturais, como imagens aéreas ou de nuvens, as dimensões fractais possuem valores mais elevados, isto é, possuem texturas mais complexas ou rugosas. No entanto, em imagens de objetos artificiais as texturas são mais sutis ou menos complexas. Então, é possível discriminar os objetos artificiais de cenários naturais ou vice-versa utilizando um limiar de dimensão fractal em apenas uma escala. Por exemplo, na Figura 38, adaptada de (PELI, T., 1990), para cada pixel da imagem original foram suprimidos aqueles que em escala 4 atingiram uma dimensão fractal maior do que 2,4. Como resultado, pode-se observar que as porções da imagem original cuja complexidade local é maior que 2,4 foram discriminadas do restante da imagem. É possível detectar visualmente que se trata de porções da imagem cujas texturas destoam do restante da imagem, legitimando a confirmação de Peli sobre a capacidade de discriminação do método através da assinatura fractal da imagem.

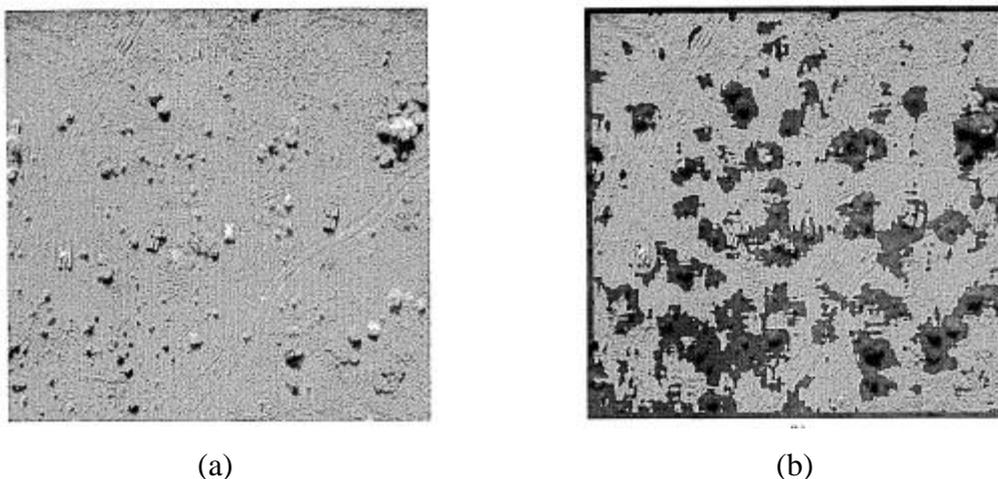


Figura 38 – Discriminação em uma única escala: (a) Imagem original e (b) destacadas as regiões cuja dimensão fractal é superior a 2,4. Adaptado de (PELI, T., 1990)

Aplicando o mesmo conceito em uma imagem de íris qualquer do banco de imagens UBIRIS v1 (PROENÇA, H.; ALEXANDRE, L.A. 2005), cujas dimensões fractais variam entre 2,02 e 2,31, definiu-se um limiar aleatório e foram mantidos apenas os pixels cuja dimensão fractal fosse superior a média 2,2. O resultado está ilustrado na Figura 39, na qual se pode observar que em imagens de íris não há distinção visual das regiões cujas complexidades são maiores, assim como ocorre na Figura 38, cujas regiões com maior complexidade são as regiões que contém objetos naturais, tais como rochas. Talvez pelo fato de na Figura 38 haver objetos de classes diferentes, enquanto que na Figura 39 a imagem retrata um único objeto, isto é, uma única classe.

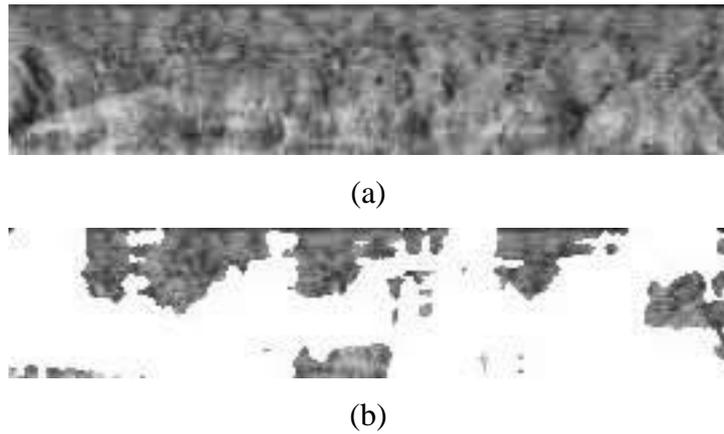


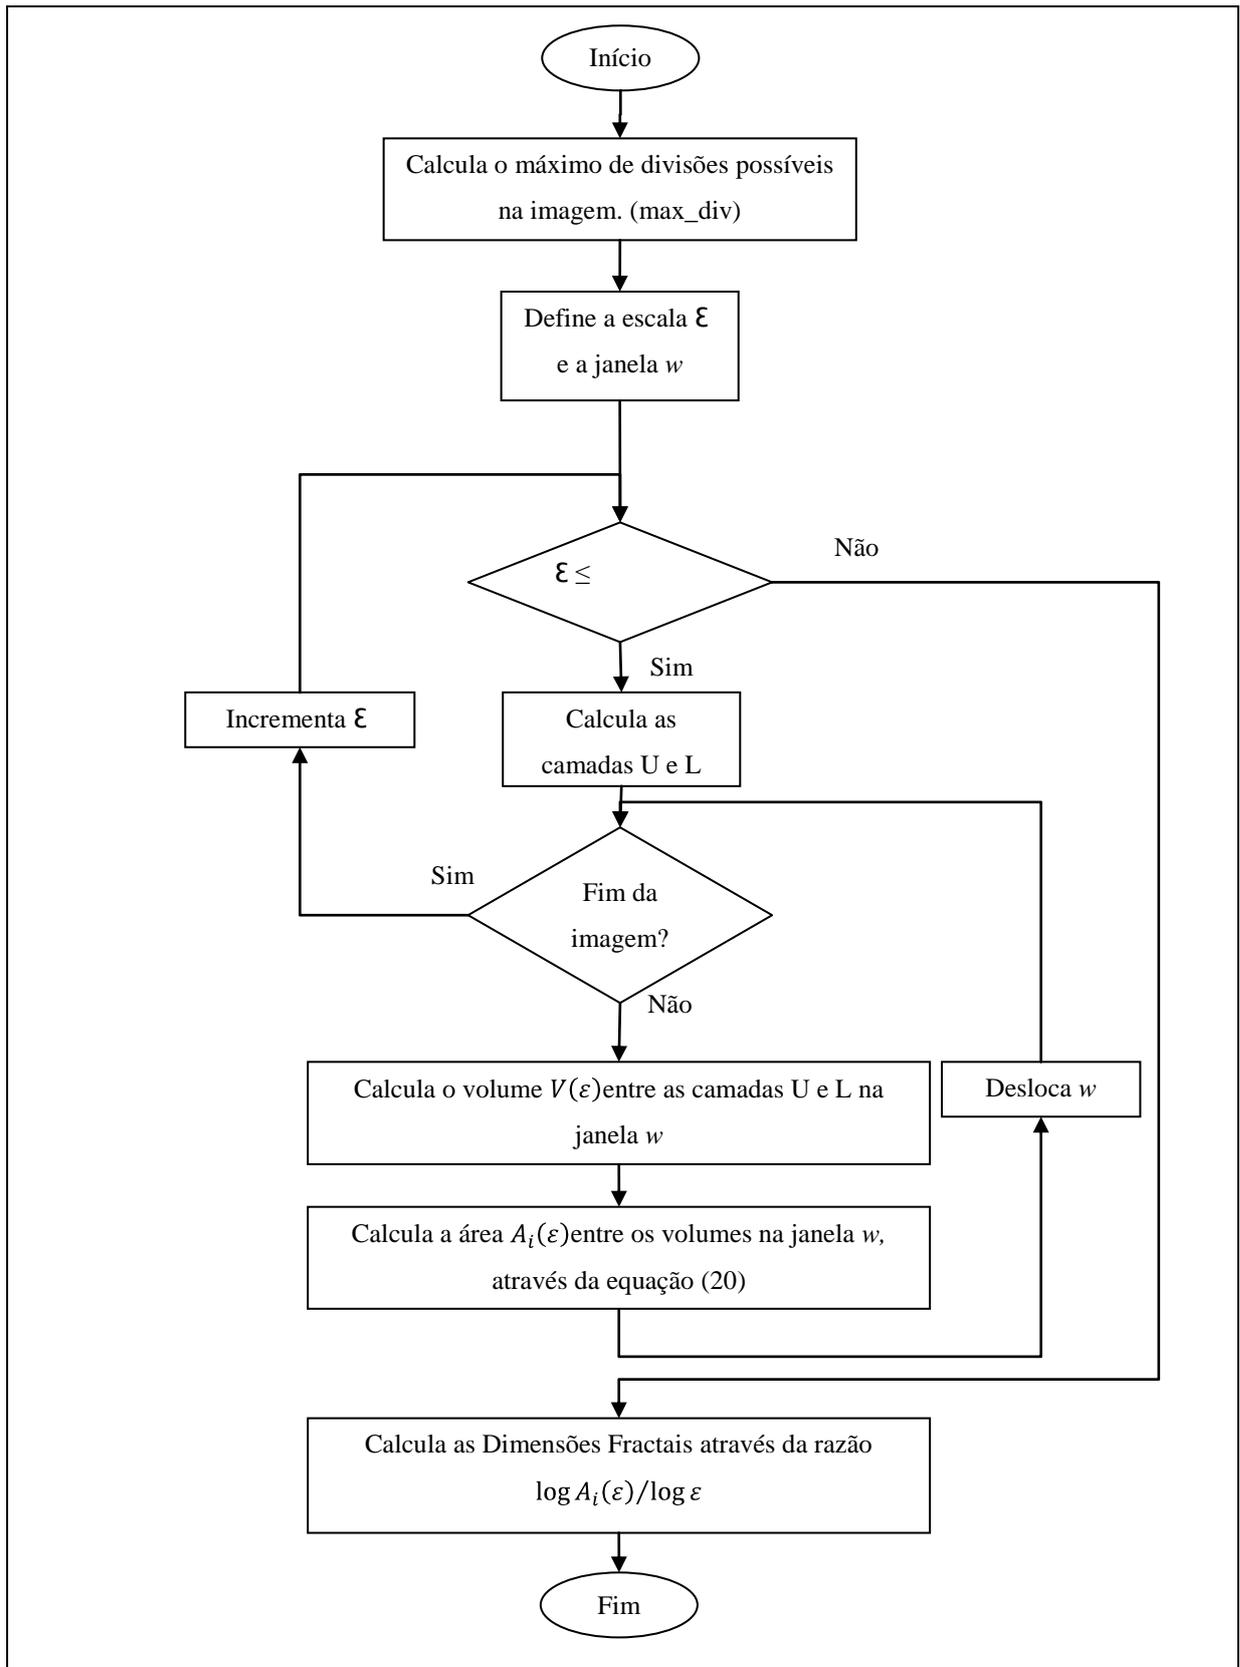
Figura 39 – Discriminação em uma única escala: (a) Imagem original e (b) destacadas as regiões cuja dimensão fractal é superior a média 2,2.

Com o intuito de evidenciar de forma sucinta uma possível forma de implementação do algoritmo de Peli (PELI, T., 1990), descreve-se abaixo os procedimentos computacionais deste método:

**Algoritmo *Covering Blanket***

**Entrada:** Imagem em tons de cinza, escala  $\varepsilon$  e janela  $w$ .

**Saída:** Matriz de dimensões fractais da imagem de entrada.



### 4.3.3 Método Área de Superfície de Prisma Triangular

O algoritmo Área de Superfície de Prisma Triangular ou (*Piecewise-Triangular-Prism-Surface-Area* - PTPSA) é utilizado para a extração de características fractais, isto é, calcula-se a dimensão fractal em imagens em tons de cinza, para caracterização de texturas e complexidade superficial das mesmas. Este método tem sido utilizado em diversos tipos de imagens como, por exemplo, imagens de Ressonância Magnética (IFTEKHARUDDIN, K.M. et al, 2003). Genericamente, o método PTPSA representa uma imagem como uma área de superfície de prismas triangulares levando em consideração as intensidades dos pixels da imagem e o tamanho da grade pré-estabelecida.

A imagem submetida ao algoritmo PTPSA é, no primeiro passo, dividida em diversas janelas  $w$  de tamanhos  $r \times r$  pré-definidos, onde  $r = 2, 3, \dots, \min(n1, n2)$ . Estas divisões geram subimagens, sendo que para cada subimagem consideram-se os valores dos pixels dos seus quatro cantos (P1, P2, P3 e P4) como alturas em uma terceira dimensão. A média dos valores destes pixels dos quatro cantos é considerada a altura do ponto central  $P_c$  desta subimagem. Então, um poliedro como o ilustrado na Figura 40 é formado. Este poliedro contém os triângulos ABE, BCE, CDE e DAE, a partir dos quais a dimensão fractal  $DF$  é calculada utilizando a equação:

$$DF = \frac{\log(A_{ADE} + A_{ABE} + A_{CDE} + A_{DAE})}{\log r}, \quad (21)$$

onde  $A$  representa a área superficial de cada triângulo.

Assim como o método *Covering Blanket*, descrito anteriormente, o algoritmo PTPSA tem como resultado uma matriz cujos valores são as dimensões fractais das sub-imagens com valores entre 2 e 6,04, pois também considera-se a imagem e a intensidade dos pixels um objeto tridimensional. Neste algoritmo não há tratamento para as bordas, ou seja, não é possível calcular a dimensão fractal para os pixels das bordas da imagem original. Estes pixels são considerados apenas quando a janela de divisão da imagem contém todos os seus pontos preenchidos. Em outras palavras, uma janela  $w$  de tamanho  $3 \times 3$ , irá permitir o cálculo da dimensão fractal apenas quando toda a janela estiver preenchida por pixels da imagem original.

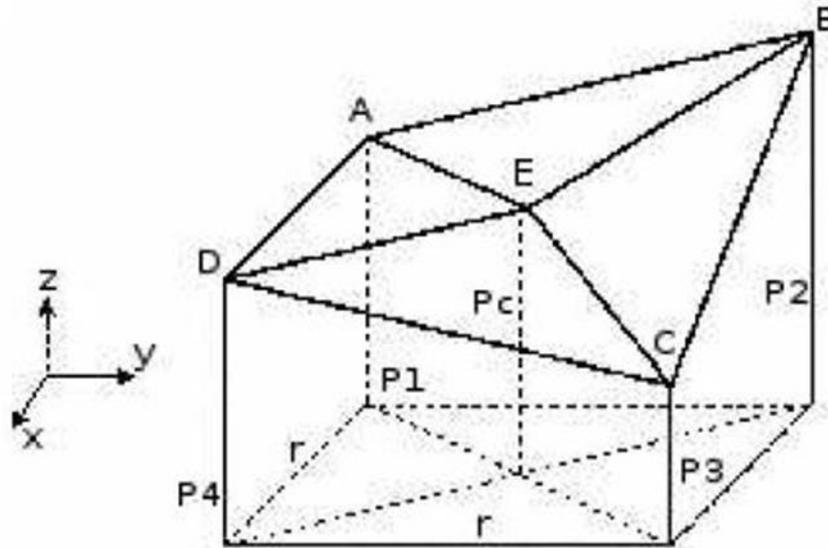


Figura 40 – Subimagem  $w$  tamanho  $r \times r$ , onde os pontos A, B, C e D representam os valores dos pixels como alturas.

Considerando uma imagem original de íris de resolução  $56 \times 270$  pixels usada neste trabalho, e uma janela para as subdivisões com tamanho  $3 \times 3$ , a matriz com as dimensões fractais resultante terá a dimensão  $54 \times 268$ , pois com este tamanho de janela a primeira e última linha, assim como a primeira e última coluna da imagem original, não podem ser consideradas para o cálculo da dimensão fractal. A Figura 41 ilustra esse exemplo, na qual se pode observar que a imagem fractal possui resolução menor que a imagem original como esperado. Portanto, quanto maior as dimensões da janela  $w$  menor será a resolução da matriz fractal resultante. Pode-se observar também que visualmente é difícil destacar algum comportamento padrão nas imagens geradas pelo método PTPSA.

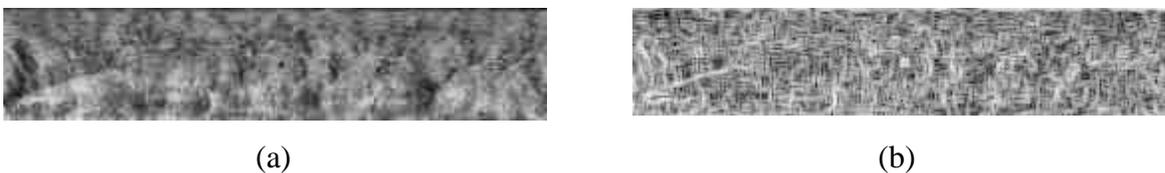
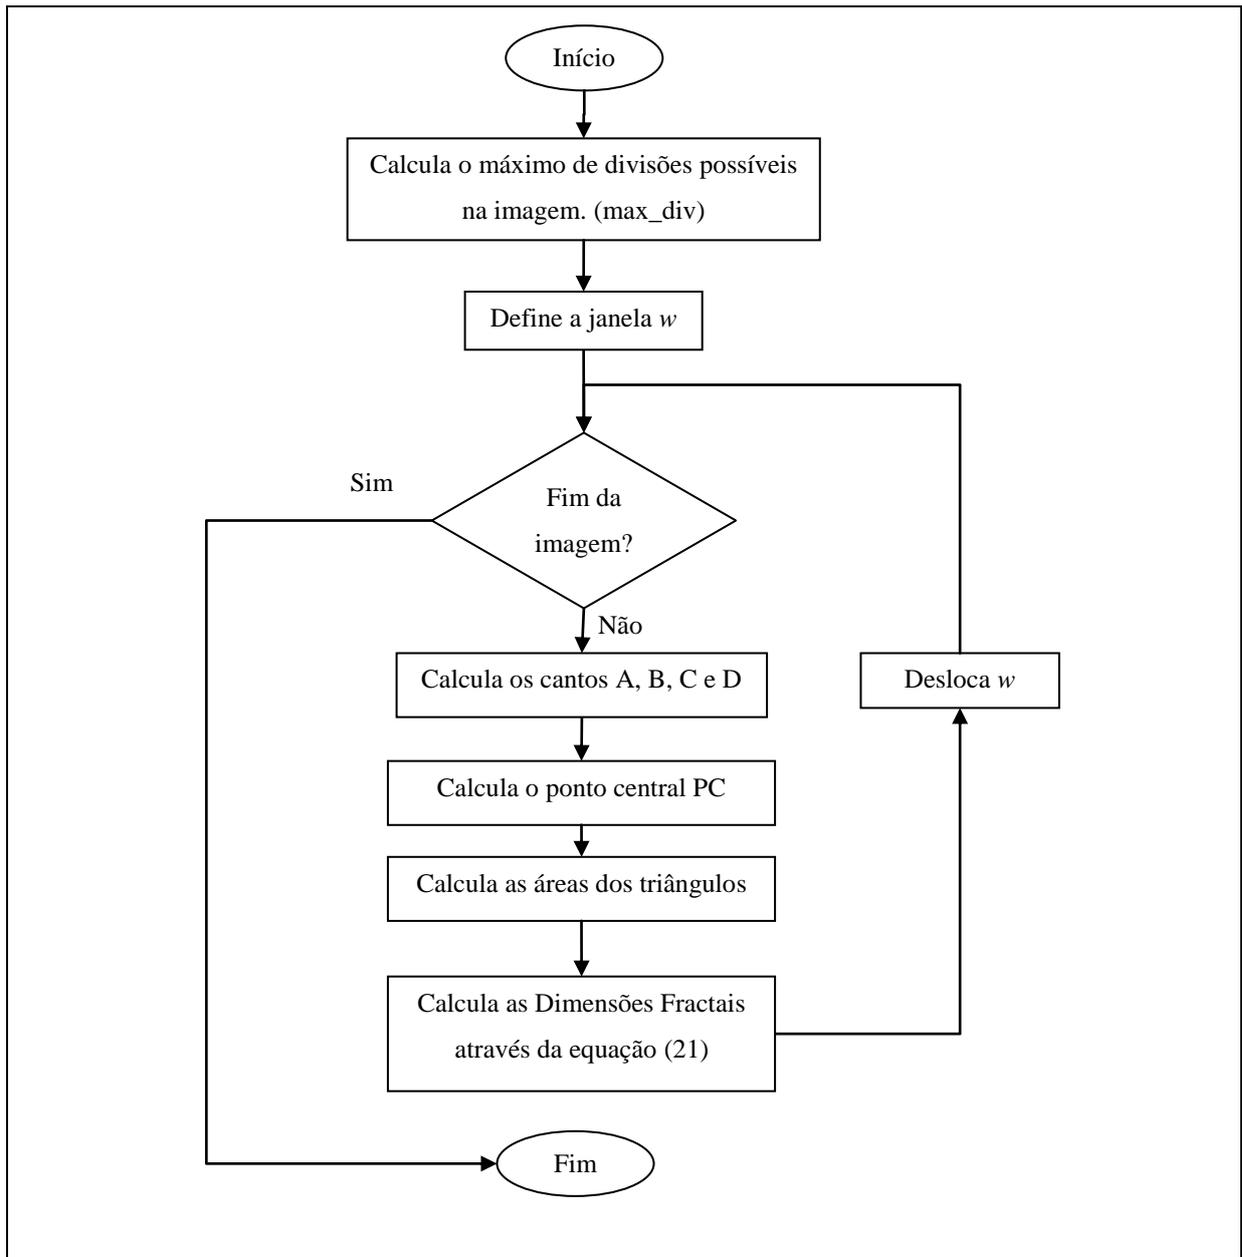


Figura 41 – (a) Imagem normalizada e equalizada e (b) imagem fractal resultante do PTPSA com janela de tamanho  $3 \times 3$ .

#### Algoritmo *PTPSA*

**Entrada:** Imagem em tons de cinza e janela  $w$ .

**Saída:** Matriz de dimensões fractais da imagem de entrada.



#### 4.4 Comentários Adicionais

Neste capítulo, descreveu-se de forma teórica e, em algumas situações, com exemplos práticos, os métodos investigados neste trabalho, principalmente as abordagens fractais para caracterização de texturas em imagens. Pode-se observar que a fractalidade em imagens pode ser calculada de diversas formas, através de procedimentos de escalas, como observado no método *Covering Blanket*, ou como figuras geométricas como os poliedros do método PTPSA. Assim, os métodos *Covering Blanket* e PTPSA realizam operações locais de subdivisão da imagem para representar a rugosidade ou auto-similaridade em um determinado número de pixels vizinhos. Estas operações permitem que cada pixel da imagem,

originalmente descrito em tons de cinza, possa ser representado pela dimensão fractal correspondente, transformando imagens em tons de cinza com valores entre 0 e 255 em imagens de dimensões fractais com valores entre 0 e 3, por exemplo. No próximo capítulo, a discriminância desses métodos será avaliada através da redução de dimensionalidade, proporcionada pelo método PCA, e através de experimentos e resultados de classificação gerados neste trabalho.

## 5 EXPERIMENTOS E RESULTADOS

Neste capítulo são descritos os experimentos realizados utilizando-se os métodos descritos no capítulo anterior, bem como os resultados correspondentes. Portanto, inicialmente foram utilizados os métodos de pré-processamento para a detecção, segmentação e normalização das imagens de íris, em seguida o método de Equalização de Histograma baseado em (MA, L., 2003) para otimização do contraste das imagens de íris normalizadas. Depois a técnica estatística multivariada chamada de Análise de Componentes Principais (JOHNSON, R.A.; WICHERN, W.R., 1998) foi aplicada para redução de dimensionalidade dos dados, análise espectral, e classificação das características descritas pelas intensidades dos pixels e extraídas pelos métodos fractais *Covering Blanket* e Área de Superfície de Prisma Triangular (PTPSA).

### 5.1 Banco de imagens UBIRIS

As imagens utilizadas nos experimentos deste trabalho foram retiradas do banco público de imagens UBIRIS v1 (PROENÇA, H.; ALEXANDRE, L.A. 2005) que é composto por 1877 imagens coletadas de 241 pessoas durante o mês de Setembro de 2004 em duas sessões distintas na Universidade da Beira Interior, em Covilhã, Portugal. A escolha deste banco de imagens se deu pelo fato dessas imagens possuírem uma maior resolução e visualmente apresentarem as íris com mais detalhes do que outros bancos disponíveis na literatura, como o CASIA (CASIA Íris Image Database), por exemplo. A Figura 42 ilustra algumas amostras de imagens de íris retiradas do banco de imagens UBIRIS v1.

As mais relevantes características foram incorporadas nas imagens como fatores de ruído, simulação de ambientes prejudicados para a aquisição de imagens, o que torna o banco robusto para avaliação de sistemas de reconhecimento de íris. Para a primeira sessão de captura de imagens os autores tentaram minimizar fatores de ruído, especialmente os relativos a reflexos, luminosidade e contraste, instalando o dispositivo de captura em uma sala escura. Já na segunda sessão de captura, fora introduzido no local de aquisição um fator de iluminação natural a fim de propiciar uma aparência heterogênea considerando os reflexos, contraste, luminosidade e problemas com o foco, e também simular um sistema de captura de imagens que realiza a aquisição com a mínima participação dos voluntários, adicionando propositalmente muitos ruídos às imagens.



Figura 42 - Amostras de imagens de íris – UBIRIS v1 (PROENÇA, H.; ALEXANDRE, L.A. 2005).

Somente as imagens da primeira sessão foram utilizadas nos experimentos pela qualidade superior à segunda sessão e ainda foram selecionadas manualmente aquelas que não apresentavam problemas que comprometeriam a análise de suas texturas, como sobreposições, reflexões sobre a própria íris e principalmente problemas com o foco. Esses artefatos não foram tratados neste trabalho. Como resultado final desta seleção foram obtidas 650 imagens formadas por 5 amostras de 130 olhos distintos.

## 5.2 Pré-processamento das imagens

As imagens retiradas do banco de imagens UBIRIS v1 (PROENÇA, H.; ALEXANDRE, L.A. 2005) são originalmente coloridas, porém foram convertidas em imagens em tons de cinza devido à limitação dos métodos fractais utilizados. Posteriormente, as imagens foram submetidas aos métodos de segmentação, normalização e equalização de histograma, como ilustrado na Figura 43, para então serem avaliadas pelos experimentos de discriminância e classificação.

Devido ao método e as condições ambientais utilizados na aquisição das imagens, pôde-se observar que em todas as imagens pertencentes ao banco UBIRIS v1 há reflexos na região da pupila. Estes artefatos fizeram com que, no processo de binarização das imagens, a pupila, ao contrário de imagens capturas por infravermelho como no caso de outros bancos de imagens tais como o CASIA, não fosse representada por uma estrutura circular e sim por uma estrutura semelhante a uma meia-lua. Então o processo de detecção da pupila, no qual são

calculadas as coordenadas centrais ( $x_c, y_c$ ), foi realizado manualmente, isto é, o mapeamento das posições dos pixels mais a direita e mais a esquerda, no eixo horizontal, e os pixels mais acima e mais abaixo, no eixo vertical da pupila, foram detectados de forma não-automática. Porém, a partir desta informação, a detecção da borda externa da íris foi realizada automaticamente utilizando a Transformação de Hough, descrita no Capítulo 3. Depois, como se observa na Figura 43, as imagens foram normalizadas de maneira que todas as íris segmentadas tivessem as mesmas dimensões, ou seja,  $56 \times 270$  pixels. Por fim, essas imagens retangulares foram equalizadas utilizando-se uma janela  $w$  de dimensões  $8 \times 8$ .

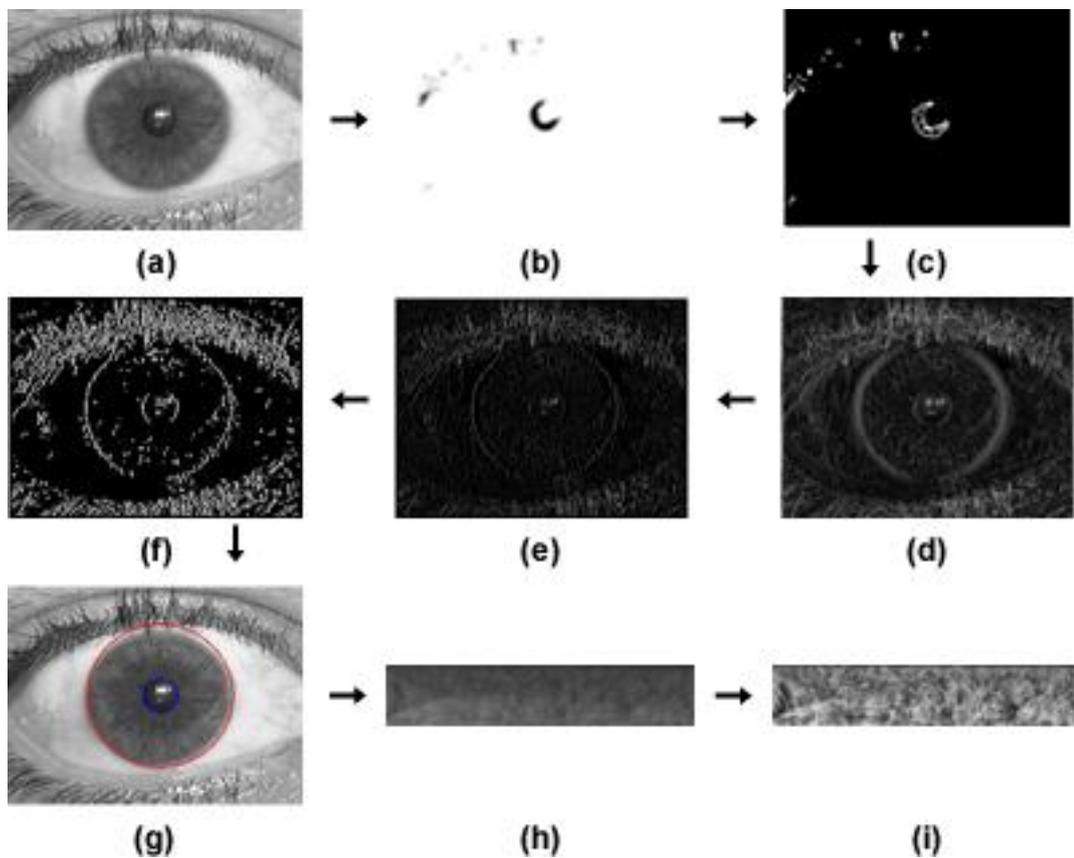


Figura 43 – Processo de pré-processamento: (a) imagem original retirada do banco de imagens UBIRIS v1; (b) Binarização da imagem; (c) Detector de bordas Canny; (d) Correção de gama; (e) Supressão não-máxima; (f) Detector de bordas Canny otimizado; (g) Pupila e íris detectadas; (h) Normalização e (i) Equalização de histograma.

### 5.3 Cálculo das dimensões fractais das imagens

Com as imagens normalizadas e equalizadas, pudera-se comparar três tipos de informação de texturas. A primeira se refere às texturas das imagens equalizadas propriamente, isto é, considerou-se as intensidades de 0 a 255 dos pixels somente. Para o

cálculo das texturas fractais, as imagens foram submetidas aos métodos *Covering Blanket* e ao método PTPSA, gerando imagens cujos valores representam as assinaturas fractais da imagem de acordo com as características específicas de cada método.

No método *Covering Blanket* foram utilizados os seguintes parâmetros: escala  $\varepsilon$  variando de 3 a 10 e tamanho da janela de observação  $w$  com valores de  $3 \times 3$ ,  $5 \times 5$  e  $7 \times 7$ . Ao contrário das imagens pré-processadas que possuem valores entre 0 e 255, as imagens resultantes da aplicação do método *Covering Blanket* possuem valores entre 0,8 e 2,6 que representam a dimensionalidade fractal local da imagem. A Figura 44 ilustra três exemplos de imagens de íris pré-processadas para três  $w$  distintas (colunas 1, 2 e 3) e escalas entre 3 e 10 (linhas 2 a 9). Já no método PTPSA o único parâmetro variável é o tamanho da janela  $w$ , para o qual foram utilizados os valores  $3 \times 3$ ,  $5 \times 5$ ,  $7 \times 7$  e  $9 \times 9$ . Os valores das imagens nesta análise ficaram entre 2,0 e 6,04, e um exemplo dessa transformação fractal pode ser visualizado na Figura 45. Os valores de dimensão fractal local abaixo de 1,0, no método *Covering Blanket*, e acima de 4,5, no método PTPSA, foram obtidos quando usada a janela de tamanho  $3 \times 3$ . Estes valores espúrios representam dimensões fisicamente não plausíveis e, portanto, as imagens geradas com este valor parâmetro, isto é, janela  $w=3 \times 3$  foram desconsideradas nos experimentos. Talvez estes valores espúrios representem a própria descontinuidade do pixel e ocorram devido ao fato de o tamanho da janela considerar uma quantidade insuficiente de pixels ou até mesmo seja causado pelo efeito da Equalização de Histograma que aumenta o contraste local.

Ao normalizar linearmente as imagens fractais geradas após a aplicação dos métodos fractais *Covering Blanket* e PTPSA em imagens em tons de cinza, como as imagens ilustradas na Figura 44 (linhas 2 a 9) e Figura 45 (linhas 2 a 5), apenas para uma análise visual, pode-se observar que nas regiões cujas dimensões fractais são mais elevadas, os pixels possuem tons de cinza mais próximos de branco e as regiões com dimensões fractais mais baixas, os pixels possuem tons de cinza mais próximos de preto. Em outras palavras, as regiões de maior complexidade fractal quando convertidas em tons de cinza tendem a ter tons de cinza mais claros e as regiões de menor complexidade tendem a ter tons de cinza mais escuros. Este comportamento visual para as imagens fractais calculadas pelo método *Covering Blanket* pode ser observado ao se comparar estas imagens fractais (Figura 44) com a imagem na Figura 46b, onde foram destacados os pixels das regiões de maior complexidade fractal, aqueles cujo o valor eram superior à média.

Outro comportamento que se pode observar para o método *Covering Blanket* é a expansão das regiões mais complexas e das regiões menos complexas a cada aumento de

escala, isto é, as regiões mais complexas tendem a se tornar a cada aumento de escala mais claras e as regiões menos complexas mais escuras. Portanto, percebe-se que quanto maior a escala, maior é o efeito de binarização da imagem e que quanto maior a janela de observação  $w$ , mais evidente se torna esse efeito.

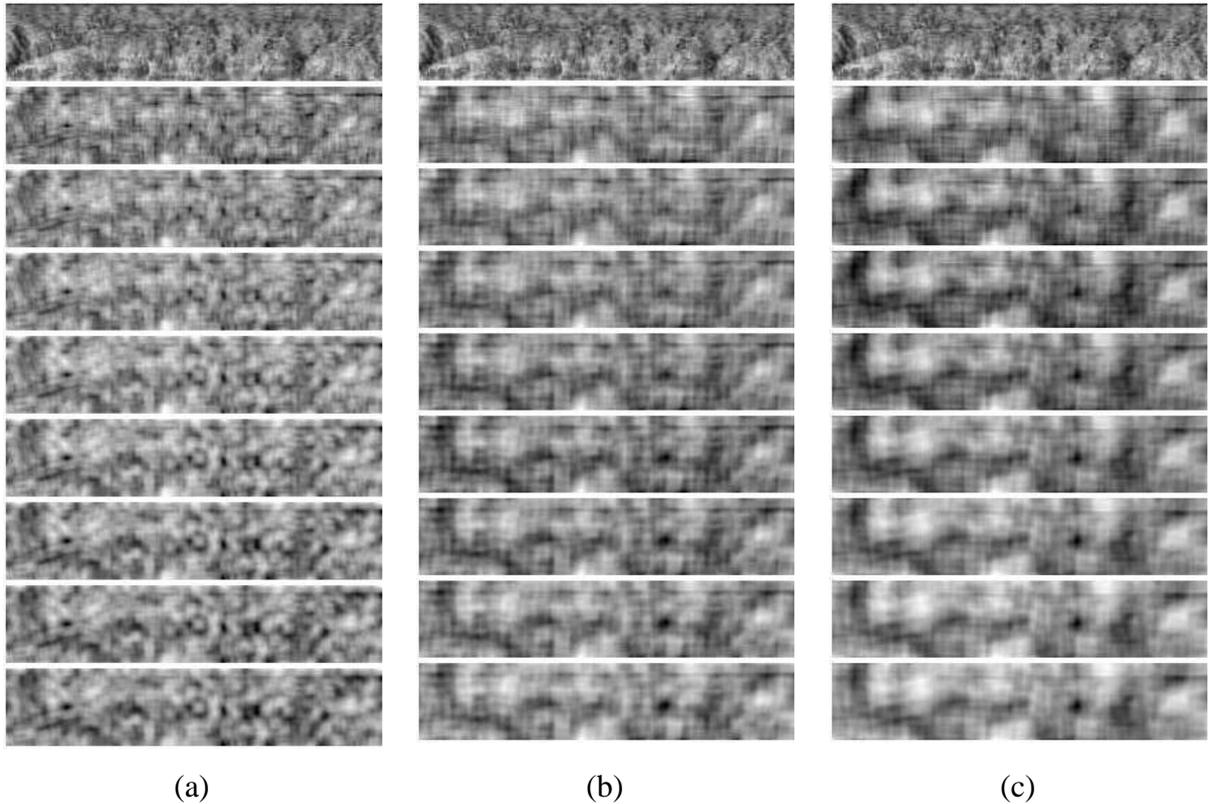


Figura 44 – Método *Covering Blanket*: (a) Imagem pré-processada (linha1, coluna1), imagens com janela  $w = 3 \times 3$  e escala  $\mathcal{E}$  de 3 a 10 (linhas 2 a 9, coluna1); (b) Imagem pré-processada (linha1, coluna2), imagens com janela  $w = 5 \times 5$  e escala  $\mathcal{E}$  de 3 a 10 (linhas 2 a 9, coluna2); (c) Imagem pré-processada (linha1, coluna3), imagens com janela  $w = 7 \times 7$  e escala  $\mathcal{E}$  de 3 a 10 (linhas 2 a 9, coluna3).

Para o método PTPSA, este comportamento também pode ser observado, conforme ilustrado na Figura 45 e Figura 46c, porém de forma mais suave, isto é, observa-se uma expansão nas regiões mais claras e mais escuras, porém não há expansões tão evidentes e acentuadas destas regiões como no método *Covering Blanket*.

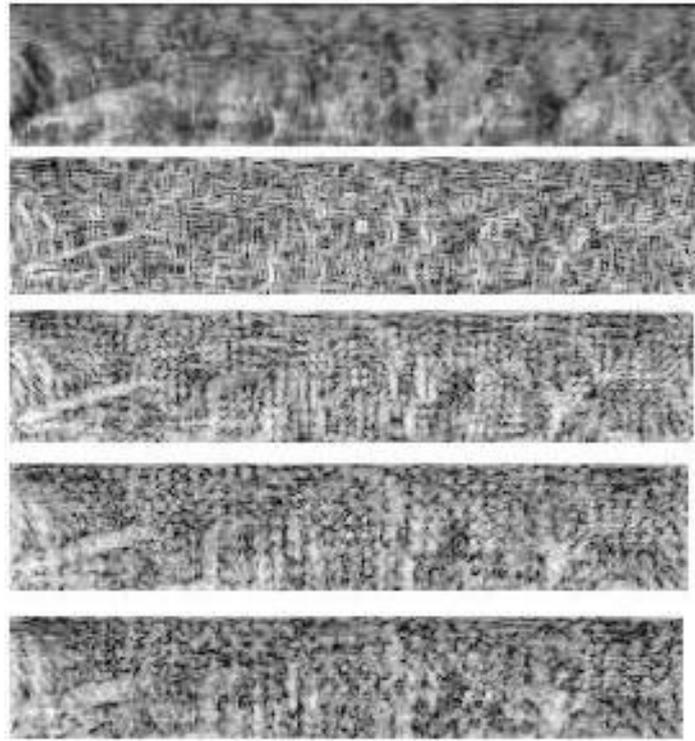


Figura 45 – Método PTPSA: Imagem pré-processada (primeira linha), imagens com janela  $w = 3 \times 3$ ,  $5 \times 5$ ,  $7 \times 7$  e  $9 \times 9$  (linhas 2, 3, 4 e 5).

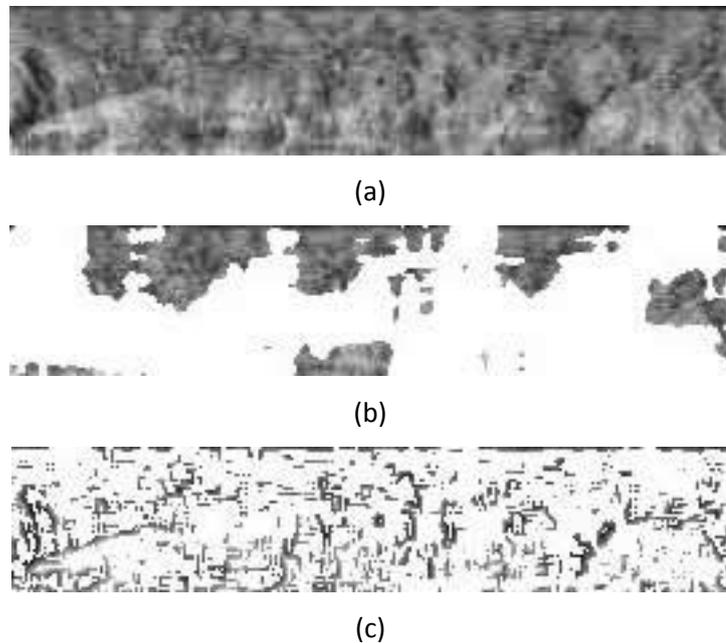


Figura 46 – Método *Covering Blanket versus* PTPSA: (a) Imagem pré-processada; (b) Imagem processada com o método *Covering Blanket* e destacados os pixels cujas dimensões fractais são maiores que 2,2; (c) Imagem processada com o método PTPSA e destacados os pixels cujas dimensões fractais são maiores que 3,5.

## 5.4 Cálculo das Componentes Principais

Após os cálculos descritos na seção anterior, as imagens fractais resultantes das aplicações dos métodos fractais (*Covering Blanket* e PTPSA) e as imagens originais equalizadas foram submetidas ao método estatístico PCA, a fim de se analisar e comparar as características discriminantes das texturas dessas imagens em um espaço espectral de dimensão reduzida.

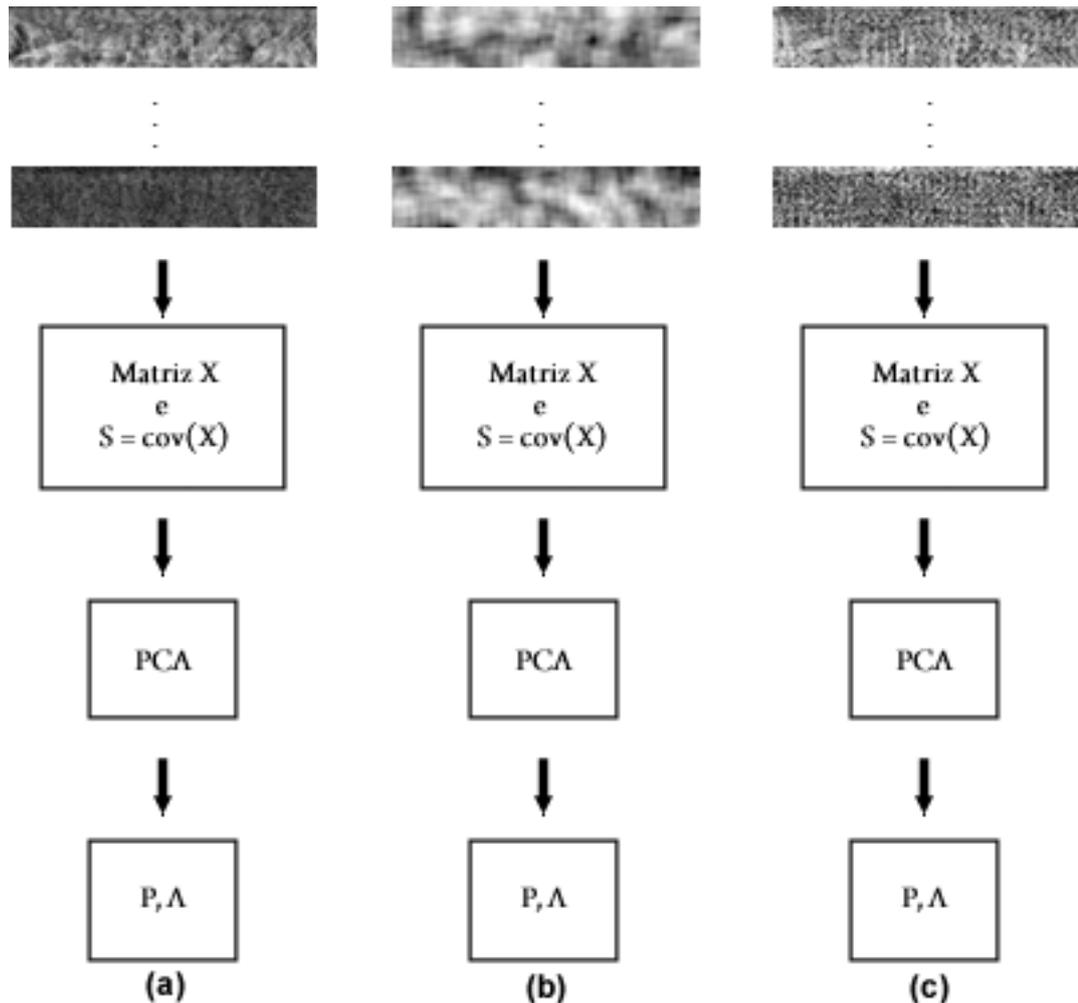


Figura 47 – Representação do fluxo utilizado para a Análise de Componentes Principais das imagens: (a) Equalizadas; (b) Calculadas pelo método *Covering Blanket*; (c) Calculadas pelo método PTPSA.

Inicialmente para cada grupo de imagens, isto é, para as imagens equalizadas, calculadas pelo método *Covering Blanket* e calculadas pelo método PTPSA, foram criadas as matrizes de dados  $X$ , sendo que para cada imagem, cuja resolução original é de  $56 \times 270$ , foram concatenadas as linhas formando um vetor de dimensões  $1 \times 15120$ . Portanto, como as amostras são compostas por 650 imagens, sendo 5 amostras de 130 sujeitos distintos, as matrizes de dados  $X$  correspondentes terão dimensões de  $650 \times 15120$ , onde a primeira coluna

representa a variação de valor do primeiro pixel para todas as imagens e assim para as demais colunas de  $X$ . Exceto para as imagens resultantes do método PTPSA, as quais terão resoluções menores devido ao não tratamento das bordas pelo método. Em seguida, foram calculadas então as matrizes de covariância  $S$ , bem como as matrizes de autovetores  $P$  e autovalores  $\Lambda$  para cada matriz de dados  $X$ , conforme se ilustra na Figura 47.

As projeções das imagens nas três componentes principais de cada textura considerada estão ilustradas na Figura 48, onde é possível observar que o espalhamento entre as imagens fractais, sejam as imagens resultantes do método *Covering Blanket* ou resultantes do método PTPSA, em comparação com as imagens em tons de cinza, reduziu drasticamente. Este efeito pode ser explicado pelo fato de que enquanto as intensidades dos pixels nas imagens equalizadas podiam variar de 0 a 255 a fractalidade nas assinaturas fractais varia entre 1,0 e 4,5. Portanto, a redução de variação possível em cada pixel implica visualmente em um espalhamento menor, o que pode significar que as imagens fractais de íris são mais semelhantes entre si do que as imagens equalizadas correspondentes. Uma ampliação dos espalhamentos das assinaturas fractais pode ser observada na Figura 49.

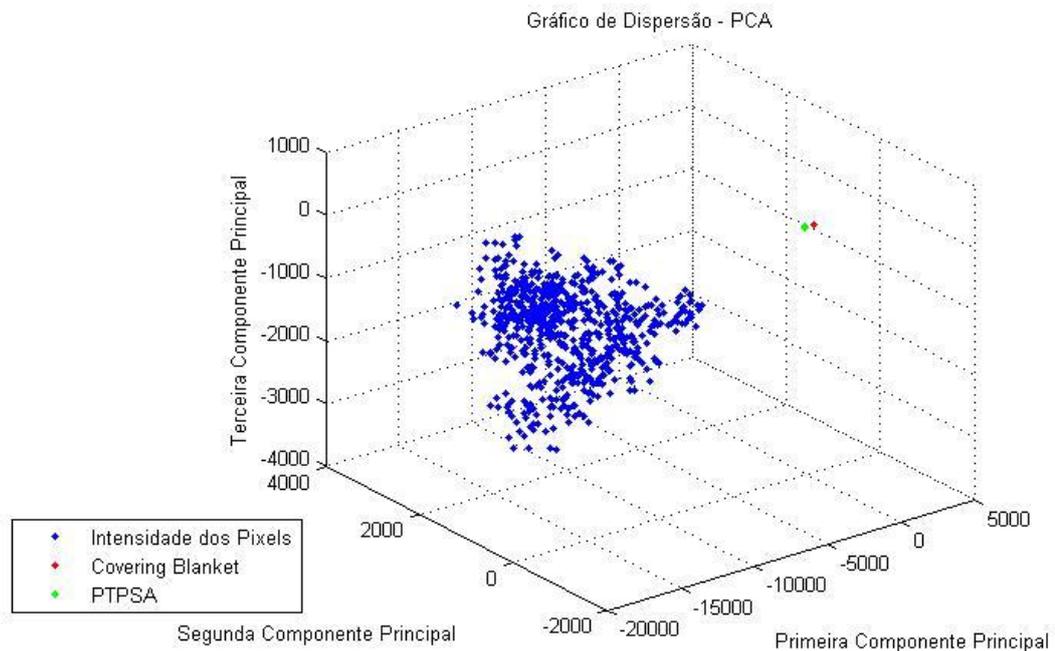


Figura 48 - Projeções nas três componentes principais de cada textura: imagens equalizadas e imagens fractais resultantes dos métodos *Covering Blanket* e PTPSA.

Porém, observando-se a Figura 50 que mostra o agrupamento das componentes principais de 10 em 10, pode-se verificar que mais de 50% da variância das informações contidas em imagens fractais resultantes do método *Covering blanket* pode ser explicada pelas 10 primeiras componentes. No entanto, para as imagens resultantes do método PTPSA esse

valor se reduz a 27% e para a intensidade dos pixels é de 48%. Assim, verifica-se que um espalhamento menor não necessariamente implica em uma redundância maior, isto é, em uma variância explicada por cada autovalor maior, pois as imagens fractais resultantes do método *Covering blanket* possuem variância semelhantes às imagens equalizadas, enquanto que os espalhamentos são bastante desproporcionais visualmente. Ao se comparar as imagens equalizadas e as imagens calculadas pelo método PTPSA a situação é semelhante quanto à diferença visual nos espalhamentos, porém bastante diferente quanto às variâncias, uma vez que para estas imagens fractais a variância explicada para a mesma quantidade de componentes principais é de 27%.

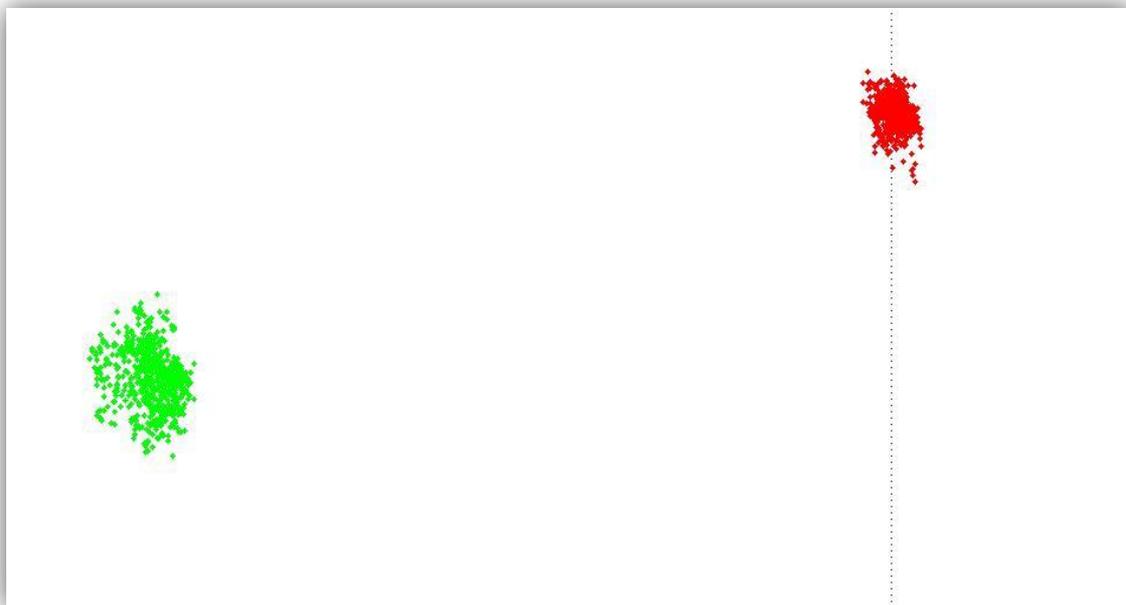


Figura 49 – Ampliação das projeções nas três componentes principais das imagens fractais resultantes dos métodos *Covering Blanket* e PTPSA.

Na verdade, variância não necessariamente implica em discriminância e, talvez, embora as imagens fractais estejam menos espalhadas, as mesmas podem estar mais bem separadas classe a classe. A fim de verificar numericamente estas questões utilizou-se o cálculo da distância de Bhattacharyya (FUKUNAGA, K., 1990), cujos resultados estão descritos na próxima seção e o método de classificação das imagens pré-processadas por distância Euclidiana.

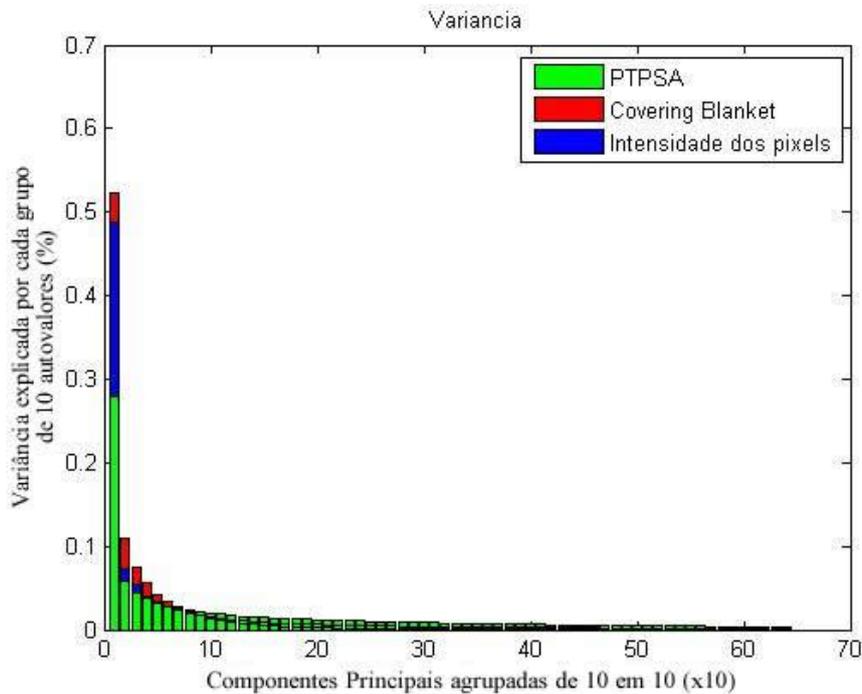


Figura 50 - Agrupamento das componentes principais de 10 em 10. Pode-se verificar que mais de 50% das informações contidas em imagens fractais resultantes do método *Covering blanket* podem ser explicadas pelas 10 primeiras componentes.

## 5.5 Cálculo da Distância de Bhattacharyya

O método denominado distância de Bhattacharyya é utilizado para medir as distâncias entre duas classes ou grupos de amostras calculando a similaridade entre as médias de cada classe e as covariâncias a partir da equação:

$$d_B(i, j) = \frac{1}{8} (\bar{x}_j - \bar{x}_i)^T \left( \frac{S_i + S_j}{2} \right)^{-1} (\bar{x}_j - \bar{x}_i) + \frac{1}{2} \ln \frac{\left| \frac{S_i + S_j}{2} \right|}{\sqrt{|S_i| |S_j|}}, \quad (22)$$

onde  $\bar{x}_i$  e  $\bar{x}_j$  e  $S_i$  e  $S_j$  são, respectivamente, as médias e as matrizes de covariância das  $g$  classes para  $i = 1, 2, \dots, g$  e  $j = 1, 2, \dots, g$ . Pela Equação (22), nota-se que  $d_B(i, j) = d_B(j, i)$ . Pode-se notar também (FUKUNAGA, K., 1990) que a distância de Bhattacharyya consiste de 2 termos, onde o primeiro termo calcula a separação através da diferença entre as médias, enquanto que o segundo termo calcula a separação através da diferença entre as covariâncias. Para calcular a distância de Bhattacharyya entre  $g$  classes, pode-se aplicar a Equação (23) para uma combinação 2 a 2 dessas classes, ou seja

$$\bar{d}_B = \frac{2}{g(g-1)} \sum_{i=2}^g \sum_{j=1}^{i-1} d_B(i, j). \quad (23)$$

Este método fora aplicado nas imagens resultantes dos métodos fractais e nas imagens equalizadas a fim de calcular a distância de Bhattacharyya entre as 130 classes de cada grupo de imagens (imagens equalizadas, *Covering Blanket* e PTPSA) e os resultados estão descritos na Tabela 2.

Intensidades dos pixels			
PCAs	$\bar{d}_B$ Médias	$\bar{d}_B$ Covariâncias	$\bar{d}_B$ Total
5	1,81	0,20	2,01
10	2,91	0,20	3,11
20	1,18	0,18	1,36
40	0,95	0,19	1,14
80	0,39	0,18	0,57
160	0,18	0,14	0,32
320	0,03	0,09	0,12
380	0,02	0,08	0,10

Covering Blanket			
PCAs	$\bar{d}_B$ Médias	$\bar{d}_B$ Covariâncias	$\bar{d}_B$ Total
5	0,64	0,14	0,78
10	0,31	0,08	0,39
20	0,27	0,11	0,38
40	0,20	0,07	0,27
80	0,09	0,08	0,17
160	0,11	0,08	0,19
320	0,04	0,06	0,11
380	0,05	0,07	0,12

PTPSA			
PCAs	$\bar{d}_B$ Médias	$\bar{d}_B$ Covariâncias	$\bar{d}_B$ Total
5	0,95	0,16	1,11
10	1,49	0,11	1,60
20	1,05	0,12	1,17
40	0,57	0,10	0,68
80	0,28	0,12	0,40
160	0,08	0,09	0,17
320	0,03	0,08	0,11
380	0,03	0,07	0,10

Tabela 2 – Médias e desvios padrão das distâncias de Bhattacharyya entre as 130 classes de texturas de íris para as imagens equalizadas (intensidade dos pixels) e resultantes dos métodos fractais *Covering Blanket* e PTPSA.

Pode-se observar que o método *Covering Blanket* é o que pior caracteriza a diferença entre classes, apresentando os menores valores para a distância de Bhattacharyya,

principalmente quando o número de componentes principais é menor ou igual a 80. Este comportamento se reflete tanto na diferença entre as médias como na diferença entre os espalhamentos (covariância) de cada classe, indicando que este método fractal é o que pior discrimina as classes de íris. Embora, o método PTPSA apresente resultados melhores de discriminação que o método *Covering Blanket*, percebe-se ainda que tanto a diferença entre as médias como a diferença entre as covariâncias, embora mais similares às imagens equalizadas, são também menores para o número de componentes principais até 180. Para todos os métodos investigados, quando o número de componentes principais aumenta acima de 160, nota-se que a distância de Bhattacharyya diminui, indicando uma separação entre as classes menos expressiva.

Portanto, pelos cálculos de distâncias de Bhattacharyya, pode-se afirmar que as intensidades dos pixels equalizadas indicam uma caracterização discriminante das imagens melhor que os métodos *Covering Blanket* e PTPSA, sem a necessidade de utilização de todas as componentes principais possíveis e, conseqüentemente, com boa redução de dimensionalidade.

## 5.6 Classificação

Para classificação, as amostras de íris foram divididas em dois grupos: treinamento e teste. Separou-se de forma aleatória 3 das 5 amostras de uma classe para o grupo de treinamento e as 2 restantes para o grupo de teste. A classificação destas amostras se deu pelo cálculo da distância Euclidiana entre a projeção PCA dos grupos de treinamento e teste, sendo que as amostras do grupo de teste serão classificadas como pertencentes a classe de íris em que esta distância Euclidiana for a menor com relação a média  $\bar{x}_i$  de cada grupo, ou seja,  $x$  pertence a classe  $i$  que minimiza

$$d_i(x) = (x - \bar{x}_i)^T(x - \bar{x}_i), \quad (24)$$

para  $i = 1, 2, \dots, g$ .

Esse processo foi repetido dez vezes. A Tabela 3 representa os índices aleatórios resultantes desta permutação para uma classe, índices estes que indicam a ordem em que as amostras seriam submetidas ao teste de classificação para todos os métodos avaliados. Por exemplo, para uma determinada classe cuja “permutação1” está descrita na Tabela 3, as imagens 3, 4 e 5 pertencem ao grupo de treinamento e as imagens 1 e 2 pertencem ao grupo de teste.

	Treino			Teste	
permutação1	3	4	5	1	2
permutação2	2	4	5	1	3
permutação3	2	3	5	1	4
permutação4	2	3	4	1	5
permutação5	1	4	5	2	3
permutação6	1	3	5	2	4
permutação7	1	3	4	2	5
permutação8	1	2	5	3	4
permutação9	1	2	4	3	5
permutação10	1	2	3	4	5

Tabela 3 – Índices de ordenação das imagens.

Para cada uma das permutações, os testes de classificação foram realizados com valores diferentes de quantidade de componentes principais. Por exemplo, no primeiro foi utilizada a “permutação1” com apenas as 10 primeiras componentes principais, tanto das amostras do grupo de treinamento quanto para as amostras do grupo de teste, e foram acrescentadas as componentes principais de 10 em 10 para cada teste de classificação até o limite de 380 componentes principais, pois verificou-se que há saturação das taxas de reconhecimento por volta desta quantidade de componentes principais. Portanto, foram realizados 38 testes de classificação para cada permutação e para cada método o que totalizou 1140 testes (38 testes x 10 permutações x 3 métodos), cujos melhores resultados de classificação de cada método estão representados nas curvas de treinamento e teste do gráfico da Figura 51. Pode-se observar que embora haja um aumento geral nas taxas de reconhecimento quando se aumenta o número de componentes principais, há também uma saturação dos métodos quando a dimensionalidade dos dados é maior do que 200. Nota-se também que nenhum dos métodos fractais com todas as variações de parâmetros testadas obteve resultado melhor na classificação do conjunto de teste do que as próprias imagens equalizadas. Embora, para os conjuntos de treinamento, os métodos fractais atingissem taxas de reconhecimento muito próximas a 100%, conforme ilustrado no gráfico da Figura 51. No entanto, as imagens equalizadas apresentaram o melhor desempenho de classificação, com taxas de reconhecimento de aproximadamente 80% com 200 componentes principais. Portanto, estes resultados indicam, assim como os cálculos das distâncias de Bhattacharyya, que as intensidades dos pixels são mais discriminantes que as assinaturas fractais dos métodos *Covering Blanket* e *PTPSA*.

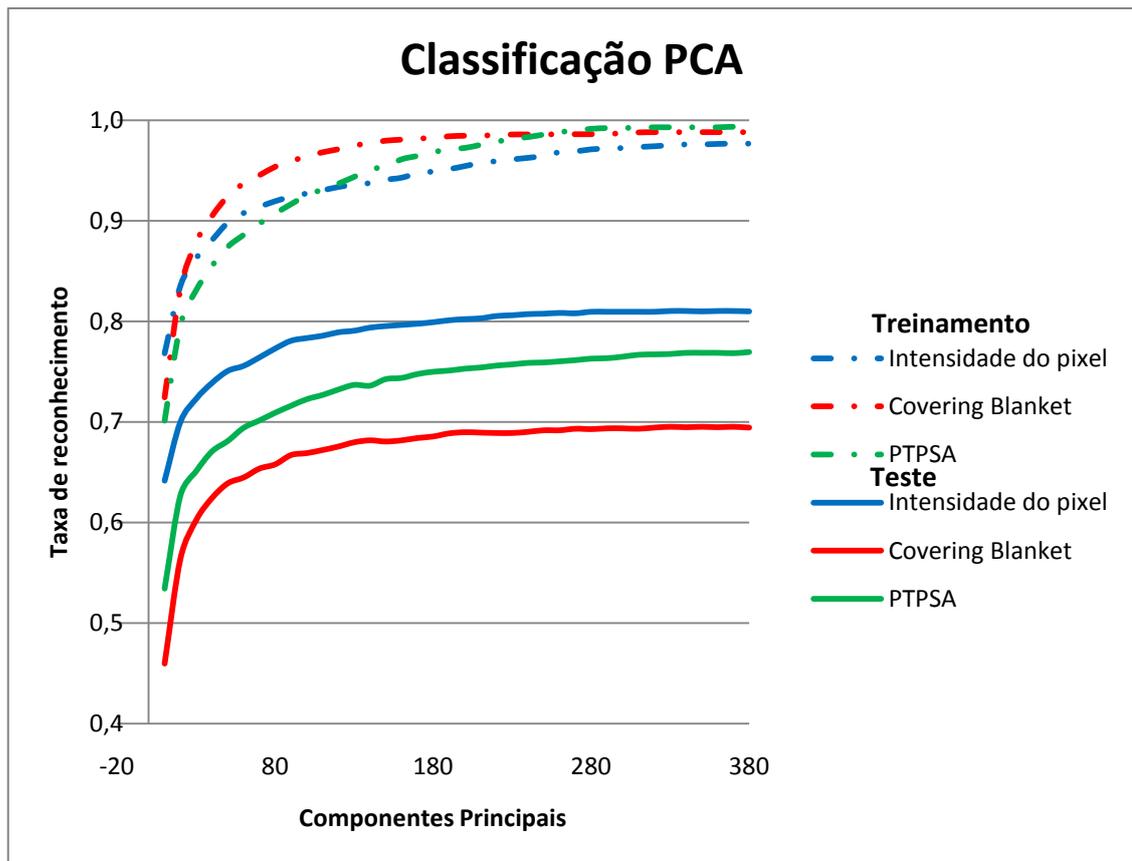


Figura 51 – Gráfico de taxas de reconhecimento dos testes com os melhores desempenhos, utilizando as componentes principais para as 130 classes de texturas de íris para as imagens equalizadas (intensidade dos pixels) e resultantes dos métodos fractais Covering Blanket com janela  $w=5 \times 5$  e escala  $\xi=5$  e PTPSA com janela  $w=9 \times 9$ .

## 6 CONCLUSÃO E TRABALHO FUTURO

Este trabalho realizou uma análise discriminante da informação fractal existente em texturas de imagens de íris representadas por tons de cinza equalizados. Três tipos de texturas de imagens de íris, normalizadas pelos procedimentos padrões dos sistemas de reconhecimento utilizados hoje em dia, foram comparados: a textura da intensidade dos pixels propriamente e outros dois tipos de texturas resultantes do cálculo de assinaturas fractais realizados pelos métodos *Covering Blanket* e PTPSA. Para esta comparação, 130 classes de imagens de íris foram analisadas, onde cada classe foi representada por 5 amostras, totalizando 650 imagens retiradas do banco de imagens UBIRIS v1, disponível academicamente e comumente citado na literatura de sistemas de reconhecimento de íris.

Antes da análise discriminante propriamente dita, calculou-se as componentes principais das imagens de íris padronizadas pelo método de normalização de J. Daugman (DAUGMAN, J. 2004), a fim de se verificar a quantidade de informação redundante existente nestes tipos de imagens. Observou-se que há uma quantidade significativa de informação redundante nestas imagens, uma vez que com somente as 10 primeiras componentes principais representou-se mais de 90% da variância total das imagens utilizadas. Então, avaliou-se o efeito da aplicação do método de Equalização de Histograma nestas imagens e constatou-se que após a equalização do contraste, as imagens tornaram-se mais distintas entre si, pois a variância explicada pelas 10 primeiras componentes diminuiu para menos de 50%, isto é, reduziu-se drasticamente a quantidade de informação redundante nessas imagens.

Após a normalização e equalização das imagens de íris, fez-se uma análise visual comparativa do espalhamento entre as imagens equalizadas e as imagens das assinaturas fractais no espaço reduzido das componentes principais. Pôde-se constatar, como se esperava, que ao se diminuir a grandeza dos valores dos pixels equalizados de 0 a 255 para dimensões fractais entre 0,8 e 6,0, diminui-se de maneira significativa o espalhamento visual entre as amostras. Para quantificar se esse efeito visual de menor espalhamento resultaria em uma maior redução de dimensionalidade promovida pela fractalidade, calculou-se a variância explicada por cada grupo de 10 componentes principais para as três texturas analisadas. Verificou-se que mais de 50% da variância das informações contidas em imagens fractais resultantes do método *Covering Blanket* pôde ser explicada pelas 10 primeiras componentes. No entanto, para as imagens resultantes do método PTPSA esse valor se reduziu a 27% e para a intensidade equalizada dos pixels foi de 48%. Portanto, constatou-se que um espalhamento menor devido à fractalidade não implicou em uma redundância maior das imagens para

ambos métodos fractais e, conseqüentemente, em uma redução de dimensionalidade mais eficiente para essa representação das imagens em comparação com a representação comumente utilizada hoje em dia para reconhecimento de íris.

Com o intuito de verificar se então as assinaturas fractais poderiam talvez aumentar o poder discriminante das imagens, calculou-se a separação e a taxa de classificação média das amostras de íris no espaço de componentes principais para diferentes grupos de treinamento e de teste. Utilizando a distância de Bhattacharyya e o classificador de distância euclidiana, notou-se que as intensidades dos pixels equalizados indicam também uma melhor caracterização discriminante das imagens se comparadas com os métodos fractais *Covering Blanket* e PTPSA, sem a necessidade de utilização de todas as componentes principais possíveis e, conseqüentemente, com boa redução de dimensionalidade. Portanto, os resultados deste trabalho mostram que a fractalidade das imagens de íris, embora quantificável por métodos fractais distintos, não implica necessariamente em uma maior redução possível de dimensionalidade das imagens devido a auto-similaridade existente e nem em uma extração de características mais discriminante que os métodos atuais propostos, por exemplo, por J. Daugman (DAUGMAN, J. 2007).

Estes resultados mostram que a extração fractal, embora possa ser caracterizada em imagens não-artificiais, não necessariamente é um método eficiente para discriminar objetos de mesma natureza. Em outras palavras, em situações onde se deseja caracterizar diferenças entre objetos tais como tanques e arvores, ou estruturas cerebrais distintas, a auto-similaridade fractal inerente aos objetos pode evidenciar esses princípios naturais distintos de forma eficiente. No entanto, imagens de íris, que tem o mesmo princípio de formação e representam o mesmo objeto na Natureza podem ter a sua auto-similaridade mais eficientemente explorada se entendidas como objetos que contém diversas regiões similares que se repetem em diferentes escalas e, portanto, ao invés de serem representadas como imagens de alta resolução, podem ser representadas por formas singulares que se repetem iterativamente através do conceito de fractalidade. Portanto, como trabalho futuro deseja-se verificar se a auto-similaridade existente nas imagens de íris analisadas neste trabalho pode ser utilizada para uma melhor compressão, ao invés de separação, desses dados biométricos.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ALEGRO, M.C. **Segmentação de Tumores do Encéfalo em Imagens por Ressonância Magnética Baseada em Informações Texturais**, Dissertação de Mestrado, São Paulo, 2009
- BALLARD, D.; BROWN, C. **Computer Vision**, Prentice-Hall, 1982, Chap. 4.
- BARNESLEY, M. **Fractals Everywhere**, Academic Press, 2 ed., pp. 248, San Diego, 1989.
- BOLES, W., W. **A Human Identification Technique Using Images of the Íris and Wavelet Transform**. IEEE Transactions on signal processing, Vol. 46, No. 4, April 1998.
- CANNY, J. F. **A Computational Approach to Edge Detection**, IEEE Trans. on Pattern Analysis and Machine Intelligence, vol. 8, pp. 679-698, 1986.
- CARVALHO, M.C.C.S.; SILVA, A.A.; BOCCIA, D.C.M.S; RIBEIRO, J.F.P.; BOGGIO, S.A. **Fractais: Uma breve introdução**, 1986
- CASIA Íris Image Database (version 1.0): National Laboratory of Pattern Recognition (NLPR), Institute of Automation (IA), Chinese Academy of Sciences (CAS), <http://www.sinobiometrics.com>.
- CHAUDHURI, B. B.; SARKAR, N. **Texture Segmentation Using Fractal Dimension**, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 17, no. 1, pp. 72-77, Jan. 1995, doi:10.1109/34.368149
- CONCI, A.; AQUINO, F.R. **Fractal Coding Based On Image Local Fractal Dimension**, Comput. AppMA, L.th. ,vol.24, no.1, Petrópolis Jan./Apr. 2005
- COOPER, J. [Online]. Disponível em: <http://www.fractal-recursions.com/> acessado em 20/10/2007.
- COSTA, L.; BIANCHI, A. G. C. **REVISTA CIÊNCIA HOJE**, Vol. 31, nº 183, pp 44, 2002.
- DAUGMAN, J, **Demodulation by Complex-Valued Wavelets for Stochastic Pattern Recognition**. Int'l J. Wavelets, Multiresolution and Information Processing, vol. 1, no. 1 , pp. 1-17, 2003.
- DAUGMAN, J, **High confidence visual recognition of persons by a test of statistical independence**, IEEE Trans. Pattern Analy Machine Intell., vol. 15, pp. 1148.1161, Nov. 1993.
- DAUGMAN, J. **How Íris Recognition Works**, IEEE Transaction on Circuit and System for Video Technology, vol. 14, no. 1, January 2004.
- DAUGMAN, J. **New methods in íris recognition**. IEEE Trans. Systems, Man, Cybernetics B 37(5), pp 1167-1175, 2007
- DAUGMAN, J. **Statistical Richness of Visual Phase Information: Update on Recognizing Persons by Iris Patterns**. Int'l J. Computer Vision , v.45, n.1, pp. 25-38, 2001.
- DAUGMAN, J. **Uncertainty relation for resolution in space, spatial frequency, and orientation optimized by two dimensional visual cortical filters**, Journal of the Optical Society of America A, vol. 2, no 7, pp. 1160-1169, July 1985.
- ERICKSON, M. **Eye Anatomy**. [Online]. Disponível em: <http://www.stlukeseye.com/Anatomy.asp> acessado em 04/09/2006.
- FISHER, Y. **Fractal Compression: Theory and Application to Digital Images**, Springer Verlag, 1994
- FUKUNAGA, K. **Introduction to Statistical Pattern Recognition**. 2 ed. Academic Press, 1990
- GONZALEZ, R.; WOODS, R. **Digital Image Processing**, Addison-Wesley Publishing Company, 1992.
- GU, H. Y. ET AL; ZHUANG, Y. T.; PAN, Y. H., **An íris recognition method based on multi-orientation features and Non-symmetrical SVM**, Journal of Zhejiang University Science, Fevereiro, 2005.

- IFTEKHARUDDIN, K.M.; JIA, W.; MARSH, R., **Fractal Analysis of tumor in brain mr images**. Machine Vision and Applications, pp.352-362, 2003
- JOHNSON, R.A.; WICHERN, D.W. **Applied multivariate statistical analysis**. 4. ed. Englewood Cliffs: Prentice Hall, 816p, 1998.
- KITANI, E. C.; THOMAZ, C. E. **Análise de Discriminantes Lineares para Modelagem e Reconstrução de Imagens de Face**. In proceedings of the 6th Encontro Nacional de Inteligência Artificial ENIA'07, pp. 962-971, Rio de Janeiro, Brazil, July 2007
- KRONFELD, P. **Gross anatomy and embryology of the eye**. In: The Eye, H. Davson, Ed. Academic Press: London, 1962.
- LEONARDO DA VINCI (1452-1519)
- LOPES, R.; BETROUNI, N., **Fractal and Multifractal Analysis: A review, Medical Image Analysis**, pp.634-649,2009
- MA, L. **Efficient Iris Recognition by Characterizing Key Local Variations**,. IEEE Transaction on Image Processing, vol. 13, no. 6, June 2004.
- MA, L., TAN, T., **Personal Identification Based on Iris Texture Analysis**.. IEEE Transaction on Pattern Analysis and Machine Intelligence, vol. 25, no. 12, December 2003.
- MANDELBROT, B.B.; FREEMAN, W.H. & Co, **Fractals: Form, Chance and Dimension**, 1977
- MANDELBROT, B.B.; FREEMAN, W.H. & Co, **The Fractal Geometry of Nature**, 1982
- MATEY, J.R.; BROUSSARD, R.; KENNEL, L. **Iris image segmentation and sub-optimal images**, Image and Vision Computing, Vol.28, Issue 2, February 2010, Pages 215-222, Segmentation of Visible Wavelength Iris Images Captured At-a-distance and On-the-move, 2010
- MITCHELL, K., **The Fractal Art Manifesto**, [Online]. Disponível em: <http://www.geocities.com/artefractal/> acessado em 15/11/2007
- MURTY, P.S.R.C.; REDDY, E.S.; BABU, I.R.. **Iris Recognition System Using Fractal Dimensions of Haar Patterns**, International Journal of Signal Processing, Image Processing and Pattern Recognition, vol.2, No.3,September 2009
- NASCIMENTO, R.; FEITOSA, R. **Sistema de Identificação Humana baseada na estrutura da íris**, PUC-RJ, Setembro 2005
- NUNES, E. O.; CONCI, A. **Determinação da Dimensão Fractal de Conjunto de Pontos à Imagens de Satélites**, Anais do 1º Congresso Temático de Aplicações de Dinâmica e Controle (APPLICON) da Sociedade Brasileira de Matemática Aplicada e Computacional (SBMAC), São Carlos, Anais, 2001.
- PEITGEN, H.; JÜRGENS, H.; SAUPE, D. **Chaos and Fractals: New Frontiers of Science**, Springer-Verlag, 1992
- PELI, T. **Multiscale fractal theory and object characterization**, J. Opt. Soc. Am. A 7, 1101-1112, 1990
- PENTLAND, A. P. **Fractal-Based Description of Natural Scenes**. IEEE Transactions on Pattern Analysis and Machine. Intelligence, vol. 6, n. 6, pp. 661-674, 1984.
- PROENÇA, H.; ALEXANDRE, L.A. **UBIRIS: A noisy iris image database**, vol. 1, pp. 970-977, Proceed. of ICIAP 2005 - Intern. Confer. on Image Analysis and Processing
- RUIZ, J. C.; [Online]. Disponível em: <http://www.personal.us.es/jcordero/LUZ/images/ilustrac/Ojopupila.jpg> acessado em 15/11/2007.
- TOENNIES, K.; BEHRENS, F.; AUERNHAMMER, M. **Feasibility of Hough-Transform-Based on Iris Localization for Real time Application**, Dept. Computer Science, University Magdeburg, Germany 2002
- TURK, M.; PENTLAND, A. **Eigenfaces for Recognition**, Journal of Cognitive Neuroscience, vol. 3, pp. 71-86, 1991.

WILDES, R. P., R. P. **Iris Recognition: An Emerging Biometric Technology**, Proceedings of the IEEE, vol. 85, no. 9, 9, pp 1348-1363, 1997.