

UNIVERSIDADE FEDERAL DO AMAZONAS
FACULDADE DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

REPRESENTAÇÃO E CLASSIFICAÇÃO DE TEXTURAS DA ÍRIS
BASEADO NA ANÁLISE DISCRIMINANTE DE FISHER
BI-DIMENSIONAL

EDUARDO TIMÓTEO DE ASSUNÇÃO

MANAUS
2011

UNIVERSIDADE FEDERAL DO AMAZONAS
FACULDADE DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

EDUARDO TIMÓTEO DE ASSUNÇÃO

REPRESENTAÇÃO E CLASSIFICAÇÃO DE TEXTURAS DA ÍRIS
BASEADO NA ANÁLISE DISCRIMINANTE DE FISHER
BI-DIMENSIONAL

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade do Amazonas, como requisito parcial para a obtenção do título de Mestre em Engenharia Elétrica, área de concentração Controle e Automação de Sistemas.

Orientador: Prof. Dr. José Raimundo Gomes Pereira

Co-orientadora: Profa. Dra. Marly Guimarães Fernandes Costa

MANAUS
2011

Ficha Catalográfica
(Catalogação realizada pela Biblioteca Central da UFAM)

A581r	<p>Assunção, Eduardo Timóteo de</p> <p>Representação e classificação de texturas da íris baseado na análise discriminante de Fisher bi-dimensional / Eduardo Timóteo de Assunção. - Manaus: UFAM, 2011. 69 f.: il. color.</p> <p>Dissertação (Mestrado em Engenharia Elétrica, área de concentração Controle e Automação de Sistemas) — Universidade Federal do Amazonas, 2011.</p> <p>Orientador: Prof. Dr. José Raimundo Gomes Pereira Co-orientadora: Prof^a. Dra. Marly Guimarães Fernandes Costa</p> <p>1. Reconhecimento de padrões 2. Biometria 3. Tecnologia da Informação I. Pereira, José Raimundo Gomes (Orient.) II. Costa, Marly Guimarães Fernandes (Co-orient.) III. Universidade Federal do Amazonas IV. Título</p> <p>CDU 004.932(043.3)</p>
-------	---

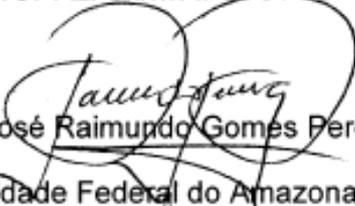
EDUARDO TIMÓTEO DE ASSUNÇÃO

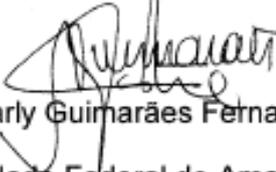
**REPRESENTAÇÃO E CLASSIFICAÇÃO DE TEXTURAS DA ÍRIS
BASEADO NA ANÁLISE DISCRIMINANTE DE FISHER BI-
DIMENCIONAL**

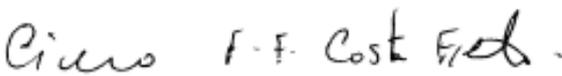
Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica na área de concentração Controle e Automação de Sistemas.

Aprovado em 24 de Março de 2011.

BANCA EXAMINADORA


Prof. Dr. José Raimundo Gomes Pereira
Universidade Federal do Amazonas


Profa. Dra. Marly Guimarães Fernandes Costa
Universidade Federal do Amazonas


Prof. Dr. Cícero Ferreira Fernandes Costa Filho
Universidade Federal do Amazonas


Profa. Dra. Eulanda Miranda dos Santos
Universidade Federal do Amazonas

Aos meus filhos Marcos Paulo e
Maria Helena, minha esposa
Lúcia Farias e meus pais
Timóteo e Lídia.

AGRADECIMENTOS

“Digno és, Jeová, sim, nosso Deus, de receber a glória, e a honra, e o poder, porque criaste todas as coisas e porque elas existiram e foram criadas por tua vontade.” (Revelação 4:11)

A minha esposa Lúcia Farias, minha filha Maria Helena e meu filho Marcos Paulo pela compreensão do tempo que tive de dedicar as atividades do curso;

Ao meu orientador Prof. Dr. José R. G. Pereira pelos incentivos, tempo dedicado em minha instrução, paciência e pela amizade desenvolvida durante o curso;

A minha coorientadora Profa. Dra. Marly G. F. Costa pelas palavras animadoras, incentivos e ajuda prática nos momentos difíceis que passei durante o curso;

Ao prof. Dr. João Edgar Chaves Filho pelos incentivos, companhia e valiosas informações transmitidas, desde a graduação até o presente momento, que tanto me ajudaram em minha vida profissional;

Aos professores do PPGEE-UFAM, em especial o prof. Cícero F. F. Costa Filho pelos conhecimentos transmitidos não só a mim, mas a todos os alunos do programa;

Aos colegas Luciano Lima e Cláudio Pinheiro pela ajuda e suporte fornecidos durante o curso;

À Universidade Federal do Amazonas e ao Centro de Tecnologia Eletrônica e da Informação – CETELI - pela concessão de toda infraestrutura para a realização desse trabalho;

A CAPES pela concessão da bolsa de estudo.

RESUMO

Os recentes avanços da tecnologia da informação e os crescentes requisitos de segurança têm levado ao rápido desenvolvimento de técnicas inteligentes de autenticação de pessoas baseado em reconhecimento biométrico. Nesse trabalho empregam-se imagens da íris da base de dados UBIRIS como medidas biométricas no cenário de verificação de indivíduos. A literatura exhibe uma grande variedade de métodos de extração de características aplicados no processo de reconhecimento de imagens de íris, entre os quais, os métodos baseados em subespaço. O objetivo da análise em subespaço é encontrar uma base de vetores que reduza a dimensão do espaço e, em alguns deles, que também otimize a separação das classes. Dos métodos baseados em subespaço, os mais conhecidos são Análise de Componentes Principais (PCA), Análise Discriminante de Fisher (FDA) e Análise de Componentes Independentes (ICA). Nesse trabalho empregam-se as extensões do método FDA, denominados $(2D)^2FDA$ e DiaFDA+2FDA, na etapa de extração de características. Na etapa de classificação foi empregado o classificador “vizinho mais próximo” com a métrica da distância Euclidiana. Os resultados mostraram que os métodos têm um bom desempenho, com destaque para o grande poder de compressão. Os métodos chegaram a reduzir uma matriz de dimensão 200×92 para 5×5 , alcançando uma área sobre a curva ROC (AUC) de 0,99.

Palavras chave: reconhecimento de padrões, biometria, redução de dimensão, extração de características.

ABSTRACT

The recent advances of information technology and the growing security requirements have led to the fast development of intelligent person authentication techniques based on biometric recognition. In this work iris images, from UBIRIS data base, are applied as biometric measurements in the verification scenery. The literature shows a large variety of feature extraction methods applied to the iris images recognition process. In this work we apply two methods based on subspace. The aim of subspace methods is to find feature vectors which reduces the space dimension while also optimizes the class separation. Some of the most known subspace methods are Principal Components Analysis (PCA), Liner Discriminant Analysis (LDA), and Independent Component Analysis (ICA). In this work we employ two extensions of FDA, i.e., $(2D)^2 FDA$ and DiaLDA+2FDA for feature extraction. During the classification phase it was applied the nearest neighbor classifier with the Euclidean distance. The results showed that the methods have a good performance, with emphasis on dimension reduction. The methods compress a 200×92 matrix dimension in a 5×5 matrix, with an AUC of 0.99.

Key words: pattern recognition, biometric, dimension reduction, feature extraction.

LISTA DE FIGURAS

Figura 3.1: Ilustração da obtenção de informações de uma imagem	22
Figura 3.2 : Método de pré-processamento quando $m \leq n$	31
Figura 3.3 : Método de pré-processamento quando $m > n$	31
Figura 3.4 :Efeito do pré-processamento aplicado a imagem de face	31
Figura 3.5 : Curva ROC de um classificador.	35
Figura 3.6 : Ilustração da AUC e EER	36
Figura 3.7: Contorno interno e externo da íris	36
Figura 3.8: Obtenção dos pontos que formarão o vetor de características	37
Figura 3.9: Arquitetura da rede neural artificial empregada no processo de classificação da pupila	38
Figura 3.10: (a) imagem ocular; (b) imagem gerada pela saída do classificador	38
Figura 3.11: Imagem da pupila após o pré-processamento	39
Figura 3.12: Ilustração do contorno interno da íris	39
Figura 3.13: Imagem gerada pela saída do classificador da região da íris	40
Figura 3.14: Resultado do pós-processamento da imagem de saída do classificador da região da íris	40
Figura 3.15: Ilustração do contorno externo da íris	40
Figura 3.16: (a) Imagem com os contornos interno e externo, (b) Iris segmentada	41
Figura 3.17: Diagrama do mapeamento no processo de normalização da região da íris	41
Figura 3.18: (a) Imagem segmentada da íris, (b) Imagem normalizada da íris	42
Figura 4.1: Processo de obtenção da ROI da imagem segmentada da íris	44
Figura 4.2 :Processo de obtenção da matriz de característica	45
Figura 5.1: Curva ROC – método (2D) ² FDA - projeção em 5 autovetores da Seção 1 do UBIRIS	47
Figura 5.2: Curva ROC – método (2D) ² FDA - projeção em 7 autovetores da Seção 1 do UBIRIS	48
Figura 5.3: Curva ROC - método (2D) ² FDA - projeção em 10 autovetores da Seção 1 do UBIRIS	48
Figura 5.4: Curva ROC - método (2D) ² FDA - projeção em 15 autovetores da Seção 1 do UBIRIS	48
Figura 5.5: Curva ROC - método (2D) ² FDA - projeção em 5 autovetores da Seção 2 do UBIRIS	49
Figura 5.6: Curva ROC - método (2D) ² FDA - projeção em 7 autovetores da Seção 2 do UBIRIS	49
Figura 5.7: Curva ROC - método (2D) ² FDA - projeção em 10 autovetores da Seção 2 do UBIRIS	49
Figura 5.8: Curva ROC - método (2D) ² FDA - projeção em 15 autovetores da Seção 2 do UBIRIS	50
Figura 5.9: Curva ROC - método DiaLA+2DFDA - projeção em 5 autovetores da Seção 1 do UBIRIS	50
Figura 5.10: Curva ROC - método DiaFDA+2DFDA - projeção em 7 autovetores da Seção 1 do UBIRIS	50
Figura 5.11: Curva ROC - método DiaFDA+2DFDA - projeção em 10 autovetores da Seção 1 do UBIRIS	51
Figura 5.12: Curva ROC - método DiaFDA+2DFDA - projeção em 5 autovetores da Seção 2 do UBIRIS	51

Figura 5.13: Curva ROC - método DiaFDA+2DFDA - projeção em 7 autovetores da Seção 2 do UBIRIS	51
Figura 5.14: Curva ROC - método DiaFDA+2DFDA - projeção em 10 autovetores da Seção 2 do UBIRIS	52
Figura 5.15: Curva ROC - método DiaFDA+2DFDA - projeção em 15 autovetores da Seção 2 do UBIRIS	52
Figura 5.16 :Exemplo de imagens da Seção 1 da base UBIRIS com alto grau de ruído empregadas nos experimentos	56

LISTA DE TABELAS

Tabela 4.1: Total de imagens utilizadas na validação do método de reconhecimento implementado	44
Tabela 5.1 : Valores obtidos de EER e AUC	53
Tabela 5.2 : Tabela comparativa de resultados de trabalhos relacionados	54

SUMÁRIO

1	INTRODUÇÃO	12
1.1	OBJETIVO GERAL	14
1.2	OBJETIVOS ESPECÍFICOS	14
1.3	ORGANIZAÇÃO	14
2	REVISÃO BIBLIOGRÁFICA	16
2.1	INTRODUÇÃO	16
2.2	PESQUISA BIBLIOGRÁFICA	16
3	FUNDAMENTAÇÃO TEÓRICA	22
3.1	INTRODUÇÃO	22
3.2	VETOR DE CARACTERÍSTICAS	22
3.3	ANÁLISE DE COMPONENTES PRINCIPAIS E EXTENSÕES	23
3.3.1	ANÁLISE DE COMPONENTES PRINCIPAIS (PCA)	23
3.3.2	ANÁLISE DE COMPONENTES PRINCIPAIS BI-DIMENSIONAL (2DPCA)	25
3.3.3	2DPCA BI-DIRECIONAL	26
3.4	ANÁLISE DISCRIMINANTE DE FISHER E EXTENSÕES	27
3.4.1	ANÁLISE DISCRIMINANTE DE FISHER (FDA)	27
3.4.2	ANÁLISE DISCRIMINANTE DE FISHER BI-DIMENSIONAL (2DFDA)	28
3.4.3	2DFDA BI-DIRECIONAL	29
3.4.4	ANÁLISE DISCRIMINANTE DE FISHER DIAGONAL (DiaFDA)	30
3.4.5	EXTRAÇÃO DE CARACTERÍSTICAS COM DiaFDA+2DFDA	32
3.5	SISTEMAS BIOMÉTRICOS	32
3.5.1	SISTEMAS DE VERIFICAÇÃO E DE IDENTIFICAÇÃO	32
3.5.2	MEDIDAS DE PRECISÃO	33
3.5.3	CURVA ROC	34
3.6	SEGMENTAÇÃO DA ÍRIS	36
3.6.1	DETECÇÃO DO CONTORNO INTERNO DA ÍRIS	37
3.6.2	DETECÇÃO DO CONTORNO EXTERNO DA ÍRIS	39
3.6.3	NORMALIZAÇÃO DA ÍRIS	41
4	MATERIAIS E MÉTODOS	43
4.1	INTRODUÇÃO	43
4.2	BASE UBIRIS	43
4.3	OBTENÇÃO DAS IMAGENS DE TEXTURA DA ÍRIS	43
4.4	EXTRAÇÃO DE CARACTERÍSTICAS	44
4.5	EXECUÇÃO DOS EXPERIMENTOS	45
5	RESULTADOS E DISCUSSÕES	47
5.1	INTRODUÇÃO	47
5.2	ANÁLISE ROC: CURVA ROC	47
5.2.1	MÉTODO (2D) ² FDA - SEÇÃO 1 DA BASE UBIRIS	47

5.2.2	MÉTODO (2D) ² FDA - SEÇÃO 2 DA BASE UBIRIS	49
5.2.3	MÉTODO DiaFDA +2DFDA – SEÇÃO 1 DA BASE UBIRIS	50
5.2.4	MÉTODO DiaFDA +2DFDA – SEÇÃO 2 DA BASE UBIRIS	51
5.3	ANÁLISE ROC: EER - AUC	53
5.4	DISCUSSÃO DOS RESULTADOS	53
6	CONCLUSÃO	57
	REFERÊNCIAS	59
	APÊNDICE	62

1 INTRODUÇÃO

Os recentes avanços da tecnologia da informação e os crescentes requisitos de segurança têm levado ao rápido desenvolvimento de técnicas de autenticação pessoal inteligente empregando reconhecimento biométrico, tais como, baseado em orelha, face, geometria da mão e dedos, íris, impressão digital e da mão, retina, assinatura, voz entre outros (JAIN *et al*, 2004). A íris humana é uma parte interna do olho que se localiza entre a córnea e as lentes, tem uma complexa estrutura com muitas características, como fendas, sardas, criptas e radiações. Essas características visíveis, geralmente chamadas de textura da íris, são únicas para cada pessoa, mesmo para gêmeos idênticos (JAIN *et al*, 2004).

O processo de reconhecimento da íris se resume basicamente em três partes: (1) o pré-processamento da imagem, que tem a finalidade de localizar e normalizar a região da íris, (2) a extração de características, cuja finalidade é codificar a imagem da íris e (3) a classificação, que tem como finalidade classificar o código gerado associando-o a um determinado indivíduo. A literatura exhibe uma grande variedade de métodos de extração de características aplicados no processo de reconhecimento de imagens de íris (BOWYER *et al*, 2008), dentre eles os métodos baseados em subespaço. Métodos de subespaço são também os mais empregados no processo de reconhecimento de face (RAO *et al*, 2010).

Um subespaço é um subconjunto de um espaço maior, que contém as propriedades deste. O objetivo da análise em subespaço é encontrar uma base de vetores que reduza a dimensão do espaço e, em alguns casos, que também otimize a separação das observações relativas às classes.

Geralmente, imagens são de dimensão elevada. Por exemplo, se uma imagem de 100×100 pixels for concatenada em um vetor, sua dimensão será $m = 10000$. A manipulação de imagens de dimensão elevada representa uma dificuldade adicional no processo de reconhecimento e eleva o custo computacional. Se representarmos o conjunto de dados das imagens em um subespaço \mathcal{R}^q , onde $q \ll m$, os problemas citados podem ser reduzidos significativamente. Alguns dos métodos de subespaço mais conhecidos são Análise de Componentes Principais (PCA), Análise Discriminante de Fisher (FDA) e Análise de Componentes Independentes (ICA) (RAO *et al*, 2010). Existem outros métodos baseados em

subespaço que são aplicados no processo de reconhecimento, que são variações dos métodos citados, entre os quais temos: Análise de Componentes Principais Bi-dimensional (2DPCA), que em YANG *et al* (2004) é aplicado à face e em ATTARCHI *et al* (2008) é aplicado a íris; Análise Discriminante Linear Bi-dimensional (2DFDA), que em YANG *et al* (2005) é aplicado à face e em CHEN *et al* (2009) é aplicado a íris; Análise de Componentes Principais Diagonal (DiaPCA), que é aplicado à face em ZHANG *et al* (2006).

Em NOUSHATH *et al* (2006), o método DiaFDA+2DFDA, que consiste em pré-processar as imagens antes de aplicar o método 2DFDA, é empregado no processo de reconhecimento de face, onde os resultados mostraram que o método implementado apresentou um desempenho melhor do que o método original.

A busca por bons descritores (*features*) para imagens de íris é um processo contínuo na comunidade científica. Não foi encontrada na literatura a aplicação do método DiaFDA+2DFDA no processo de extração de características de imagens de íris, este fato motivou a investigação da aplicação deste método em imagens de íris, com o objetivo de avaliar os resultados no que diz respeito ao desempenho de reconhecimento e tamanho da matriz de características. Dessa forma, esta dissertação apresenta o processo de reconhecimento de indivíduos através da Iris utilizando um processo de extração de características baseado em subespaço utilizando-se o método DiaFDA+2DFDA.

1.1 OBJETIVO GERAL

O objetivo principal dessa dissertação é apresentar os resultados da pesquisa realizada sobre métodos de extração de características de imagens segmentadas e normalizadas de íris empregadas em verificação de indivíduos.

1.2 OBJETIVOS ESPECÍFICOS

Avaliar comparativamente o desempenho de alguns métodos de extração de características, baseado em subespaço, em imagens segmentadas de íris visando o reconhecimento de indivíduos (no cenário de verificação), tendo como base o método Análise Discriminante Linear Bi-dimensional (2DFDA) e suas extensões: Bi-direcional 2DFDA ($(2D)^2 LDA$) e Análise Discriminante Linear Diagonal (DiaFDA+2DFDA).

1.3 ORGANIZAÇÃO

Essa dissertação de mestrado está dividida nos seguintes capítulos:

- Introdução (Capítulo 1);
- Revisão Bibliográfica (Capítulo 2);
- Fundamentação Teórica (Capítulo 3)
- Materiais e Métodos (Capítulo 4);
- Resultados e Discussões (Capítulo 5);
- Conclusão (Capítulo 6);
- Referência Bibliográfica;
- Apêndice;

No Capítulo 2 são apresentados os resumos dos principais artigos selecionados durante a pesquisa bibliográfica realizada visando compreender as abordagens mais recentes e promissoras para a extração de características de imagens para fins de reconhecimento biométrico. Além de artigos que abordam a biometria da íris, também foram selecionados artigos que abordam a biometria da mão e face, entre outros, com o objetivo de verificar

possíveis extensões dos métodos apresentados para aplicações em extração de características para a descrição da textura da Iris

O Capítulo 3 descreve os conceitos e a fundamentação matemática empregados no desenvolvimento da dissertação. No decorrer do capítulo são demonstrados os fundamentos da etapa de extração de características, baseado em subespaço, empregados nos experimentos. Também aborda alguns conceitos de biometria e o processo de segmentação e normalização da íris.

No Capítulo 4 é apresentada a descrição da base de imagens de íris empregado no estudo comparativo, a descrição dos experimentos realizados e as métricas de comparação.

No Capítulo 5 são apresentados os resultados dos experimentos por intermédio dos gráficos da curva ROC, área sobre a curva ROC e taxa de erro equivalente. Ainda nesse capítulo são apresentadas as discussões dos resultados.

No capítulo 6 é apresentada a conclusão do trabalho onde são expostas as comparações com outros trabalhos relacionados.

2 REVISÃO BIBLIOGRÁFICA

2.1 INTRODUÇÃO

Neste capítulo descrevem-se os principais artigos selecionados durante a pesquisa bibliográfica realizada visando compreender as abordagens mais recentes e promissoras para a extração de características de imagens para fins de biometria. Além de artigos que abordam a biometria da íris, também foram selecionados artigos que abordam a biometria da mão e face, com o objetivo de verificar possíveis extensões dos métodos apresentados para aplicações em extração de características para a descrição da textura da Iris. Por ser o interesse principal, foram selecionados os artigos que apresentam propostas de extração de características baseadas na Análise Discriminante de Fisher (FDA) e Análise de Componentes Principais (PCA).

A principal base de dados empregada na revisão bibliográfica foi a IEEE (*Institute of Electrical and Electronics Engineers*) e a *Science Direct*. A seguir apresenta-se o resumo dos artigos selecionados.

2.2 PESQUISA BIBLIOGRÁFICA

Em Yang *et al* (2004) os autores desenvolveram o método denominado análise de componentes principais bi-dimensional (2DPCA). No referido trabalho o método 2DPCA é empregado na extração de características aplicado ao reconhecimento de imagens de face. Ao contrário do método convencional de extração de características através da análise de componentes principais (PCA), os autores empregam as matrizes de imagens bidimensionais (2D) diretamente no processo de obtenção da matriz de dispersão, evitando assim a necessidade de transformação da matriz de imagem em um vetor unidimensional (1D). O algoritmo é similar ao PCA convencional, cujo objetivo é encontrar vetores de projeção ótimos, que compõem a matriz de projeção $\mathbf{W}=[\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_d]$. Os vetores são obtidos determinando-se os autovetores associados aos d maiores autovalores da matriz de dispersão

total $\mathbf{G} = \frac{1}{M} \sum_{k=1}^M (\mathbf{A}_k - \bar{\mathbf{A}})^T (\mathbf{A}_k - \bar{\mathbf{A}})$, onde M é o número de imagens de treinamento, \mathbf{A}_k é a matriz de imagem ($k = 1, 2, \dots, M$) de dimensão $m \times n$, $\bar{\mathbf{A}}$ é a imagem média das. Após a obtenção da matriz de projeção \mathbf{W} , a imagem original \mathbf{A}_k é projetada para, então se obter uma nova representação da imagem $\mathbf{B}_k = \mathbf{A}_k \mathbf{W}$ de dimensão $m \times d$, com $d < n$. O método realiza uma redução de dimensão na direção horizontal de \mathbf{A}_k . Os autores aplicaram o método desenvolvido em três bases de dados (ORL, AR e Yale) para avaliar o método 2DPCA. As bases de dados ORL (ORL, 2002) foi criada pela *AT&T Laboratories Cambridge*; a AR (AR, 1998) pela *Ohio State University*; e a Yale (Yale, 2001) foi desenvolvida pela *Yale University*. Na etapa de classificação foi empregado o classificador do vizinho mais próximo (*nearest neighbor classifier*) com a métrica da distância Euclidiana. Comparações foram feitas com os métodos FDA, análise de componentes independentes (ICA) e estimadores por Kernel-PCA. Dentre as vantagens do método 2DPCA em relação aos outros métodos comparados, citam-se o tempo de processamento e a taxa de reconhecimento, embora o método 2DPCA necessite de mais coeficientes para representar a imagem, o que implica na necessidade de mais memória para armazenamento das imagens. Os autores sugerem a aplicação do PCA após o método 2DPCA como forma de resolver este problema. O Quadro 2.1 apresenta o resultado da comparação entre os métodos com relação à precisão de reconhecimento com 5 imagens de treinamento na base de dados ORL.

Quadro 2.1 : Resultados do método 2DPCA no reconhecimento de faces em Yang *et al.* (2004)

Método	Precisão
FDA	94,5%
ICA	85,0%
Kernel-PCA	94,0%
2DPCA	96,0%

Em Li e Yuan (2005) os autores propuseram um método de extração de características denominado análise discriminante de *Fisher* bi-dimensional (2DFDA) e aplicaram o método em reconhecimento de faces na base de dados ORL. O método é similar ao FDA convencional, mas ao invés de transformar a matriz de imagem em um vetor unidimensional (1D), os autores empregam as matrizes bidimensionais (2D) diretamente no processo de

obtenção da matriz de dispersão dentro da classe $\mathbf{S}_W = \frac{1}{M} \sum_{i=1}^C \sum_{k \in C_i} (\mathbf{A}_k - \bar{\mathbf{A}}_i)^T (\mathbf{A}_k - \bar{\mathbf{A}}_i)$ e da matriz de dispersão entre classes $\mathbf{S}_B = \frac{1}{M} \sum_{i=1}^C N_i (\bar{\mathbf{A}}_i - \bar{\mathbf{A}})^T (\bar{\mathbf{A}}_i - \bar{\mathbf{A}})$, onde M é o número de imagens de treinamento, C o número de classes de imagens, N_i o número de imagens da classe C_i , \mathbf{A}_k é a matriz de imagem ($k=1,2,\dots,M$), de dimensão $m \times n$, $\bar{\mathbf{A}}$ é a imagem média de todas as imagens e $\bar{\mathbf{A}}_i$ a imagem média da classe i .

Similar ao método convencional FDA, o método 2DFDA procura encontrar um conjunto de vetores de projeção que tanto reduza a dimensão do espaço de imagens como também maximize a separação (discriminação) entre as classes de imagens. Estes vetores compõem a matriz de projeção $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_d]$ e são obtidos determinando-se os autovetores associados aos d maiores autovalores da matriz $\mathbf{S}_W^{-1} \mathbf{S}_B$. Após se obter a matriz de projeção, a imagem original \mathbf{A}_k , de dimensão $m \times n$, é projetada na matriz \mathbf{X} para se obter uma nova representação da imagem, $\mathbf{B}_k = \mathbf{A}_k \mathbf{X}$ de dimensão $m \times d$ com $d < n$. O método realiza redução na direção horizontal de \mathbf{A}_k . Na etapa de classificação, os autores empregaram o algoritmo do vizinho mais próximo, com a métrica da distância Euclidiana, para classificação das imagens. São feitas comparações com os métodos: PCA, 2DPCA e FDA. Segundo os autores o método proposto (2DFDA) obteve a maior taxa de reconhecimento comparado com os demais métodos. O 2DFDA alcançou 94,0%, contra 92,5% do 2DPCA.

Em Zhang e Zhou (2005) os autores apresentam uma extensão do método 2DPCA, que realiza redução nas direções horizontal e vertical da imagem original. Os autores denominaram o método proposto de bi-direcional 2DPCA, também conhecido por $(2D)^2 PCA$, o qual consiste em encontrar duas matrizes de projeções, definidas por $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_d]$ e $\mathbf{Z} = [\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_q]$. A matriz \mathbf{X} é obtida através do método 2DPCA e \mathbf{Z} pelo método denominado pelos autores de *alternative 2DPCA*, que atua na direção vertical da matriz original. O método *alternative 2DPCA* é implementado a partir da construção da matriz de dispersão total, definida como $\mathbf{G}_v = \frac{1}{M} \sum_{k=1}^M (\mathbf{A}_k - \bar{\mathbf{A}})(\mathbf{A}_k - \bar{\mathbf{A}})^T$. Em seguida são determinados os autovetores de \mathbf{G}_v como no 2DPCA. Sendo \mathbf{X} , de dimensão $n \times d$ e \mathbf{Z} , de dimensão

$m \times q$, a matriz de característica \mathbf{C}_k , de dimensão $q \times d$, é obtida projetando-se a imagem \mathbf{A}_k nas matrizes \mathbf{X} e \mathbf{Z} simultaneamente, isto é, $\mathbf{C}_k = \mathbf{Z}^T \mathbf{A}_k \mathbf{X}$.

Na etapa de classificação os autores empregaram o algoritmo do vizinho mais próximo, com a métrica da distância Euclidiana. Os resultados experimentais do emprego do método utilizando as bases de dados de imagens ORL e FERET mostraram que $(2D)^2 PCA$ e 2DFDA apresentaram o mesmo desempenho de reconhecimento. Porém o método $(2D)^2 PCA$ produziu a matriz de característica de tamanho menor.

Em Noushatha *et al* (2006) os autores apresentam uma extensão do método 2DFDA denominado de $(2D)^2 FDA$. O 2DFDA realiza a redução da matriz original apenas na direção horizontal 1, enquanto que o $(2D)^2 FDA$ realiza a redução da matriz original nas direções horizontal e vertical. Com isso, a imagem projetada (matriz de característica) por este método é de dimensão muito menor do que a matriz de característica projetada pelo 2DFDA. O método consiste em encontrar duas matrizes de projeção, definidas por $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_d]$ e $\mathbf{Z} = [\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_q]$. A matriz \mathbf{X} é obtida através do método 2DFDA e \mathbf{Z} pelo método denominado pelos autores de *alternative* 2DFDA que atua na direção vertical da matriz original. O método *alternative* 2DFDA é implementado construindo-se a matriz de dispersão dentro da classe definida como $\mathbf{S}_W = \frac{1}{M} \sum_{i=1}^C \sum_{k \in C_i} (\mathbf{A}_k - \bar{\mathbf{A}}_i)(\mathbf{A}_k - \bar{\mathbf{A}}_i)^T$ e a matriz de dispersão entre classes é definida como $\mathbf{S}_B = \frac{1}{M} \sum_{i=1}^C N_i (\bar{\mathbf{A}}_i - \bar{\mathbf{A}})(\bar{\mathbf{A}}_i - \bar{\mathbf{A}})^T$. Sendo \mathbf{X} de dimensão $n \times d$ e \mathbf{Z} de dimensão $m \times q$, a matriz de característica \mathbf{C}_k , de dimensão $q \times d$ é obtida projetando-se a imagem \mathbf{A}_k nas matrizes \mathbf{X} e \mathbf{Z} simultaneamente, ou seja, $\mathbf{C}_k = \mathbf{Z}^T \mathbf{A}_k \mathbf{X}$. Na etapa de classificação os autores empregam o algoritmo do vizinho mais próximo, com a métrica da distância Euclidiana. Os experimentos foram realizados nas bases de dados de imagens de face ORL e Yale. Os autores comparam o método proposto $(2D)^2 FDA$ com os métodos 2DFDA, 2DPCA e $(2D)^2 PCA$. Os resultados mostram que o desempenho do método proposto é similar aos métodos comparados com relação à taxa de reconhecimento, mas com relação ao tamanho da matriz de característica, o método proposto superou os métodos 2DFDA e 2DPCA, sendo similar ao método $(2D)^2 PCA$.

Em Zhang *et al* (2006) os autores empregam o método 2DPCA desenvolvido por Yang *et al* (2004) como base para desenvolver um método denominado de análise de componentes principais diagonal (DiaPCA) e empregando-o para reconhecimento de faces. O método consiste em primeiro pré-processar as imagens originais \mathbf{A}_k , de dimensão $m \times n$, transformando-a em suas correspondentes imagens diagonal \mathbf{D}_k , empregando um procedimento que será descrito no Capítulo 3. Em seguida a essa diagonalização, os autores aplicaram o método 2DPCA tendo como entrada as imagens \mathbf{D}_k . Os autores ainda fizeram uma combinação dos métodos DiaPCA+2DPCA, que consiste em encontrar duas matrizes de projeção, $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_d]$ e $\mathbf{Z} = [\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_q]$, onde \mathbf{X} é obtida empregando o método DiaPCA e \mathbf{Z} o método 2DPCA, que consiste em determinar os autovetores associados aos q maiores autovalores da matriz de dispersão $\mathbf{G} = \frac{1}{M} \sum_{K=1}^M (\mathbf{A}_k - \bar{\mathbf{A}})(\mathbf{A}_k - \bar{\mathbf{A}})^T$. De posse das duas matrizes de projeção \mathbf{X} e \mathbf{Z} fizeram então a projeção das imagens originais obtendo a matriz de característica $\mathbf{C}_k = \mathbf{Z}^T \mathbf{A}_k \mathbf{X}$. A base de dados de face FERET é empregado nos experimentos para avaliar os métodos DiaPCA, DiaPCA+2DPCA e PCA. O classificador de vizinho mais próximo é utilizado para classificação empregando como métrica a distância Euclidiana. No Quadro 2.2 são apresentados os resultados dos testes.

Quadro 2.2 : Resultados dos métodos comparados para reconhecimento de faces em Zhang et al (2006)

Método	Precisão
PCA	85,5%
2PCA	85,5%
DiaPCA	90,5%
DiaPCA+2DPCA	91,5%

Em Nousath *et al* (2006) os autores empregam o método DiaPCA apresentado em Zhang *et al* (2006) como base para desenvolver o método denominado de Análise discriminante linear de Fisher diagonal (DiaFDA). O método consiste em primeiro pré-processar as imagens originais \mathbf{A}_k , de dimensão $m \times n$, para obter suas imagens diagonais \mathbf{D}_k correspondente, de mesma dimensão, conforme o procedimento proposto em Zhang *et al* (2006). Em seguida aplicam o método 2DFDA, tendo como entrada as imagens pré-processadas \mathbf{D}_k . Os autores ainda fizeram uma combinação dos métodos DiaFDA+2DFDA, que consiste em encontrar

duas matrizes de projeção, $\mathbf{X}=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_d]$ e $\mathbf{Z}=[\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_q]$. Onde, \mathbf{X} é obtida empregando o método DiaFLD e \mathbf{Z} o método 2DFDA. De posse das duas matrizes de projeções \mathbf{X} e \mathbf{Z} são feitas as projeções das imagens originais, isto é, $\mathbf{C}_k = \mathbf{Z}^T \mathbf{A}_k \mathbf{X}$. As bases de dados de face ORL e Yale são empregados nos experimentos para avaliar o método proposto. O classificador pelo vizinho mais próximo, com a métrica da distância Euclidiana, é empregado na etapa de classificação. Os resultados experimentais mostraram que o método proposto (DiaFDA+2DFDA), em alguns casos, superou os métodos DiaFDA, 2DPCA, $(2D)^2 PCA$, 2DFDA e $(2D)^2 FDA$.

Em Wang e Ruan (2006) os autores empregam os métodos apresentados em 2DPCA e 2DFDA no reconhecimento de imagens de mão (*palmprint*). Primeiro, os autores empregam o método 2DPCA, tendo como entrada as imagens de treinamento \mathbf{A}_k , para obter a matriz de projeção $\mathbf{X}=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_d]$ e a matriz de característica $\mathbf{B}_k = \mathbf{A}_k \mathbf{X}$. Em seguida, aplica-se o método 2DFDA tendo com entrada as matrizes de característica \mathbf{B}_k , obtendo-se a matriz de projeção $\mathbf{Z}=[\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_q]$ e a matriz de característica $\mathbf{C}_k = \mathbf{Z}^T \mathbf{B}_k$. Os autores executam os experimentos na base de dados da Universidade de *Beijing Jiaotong*. O Quadro 2.3 mostra os resultados obtidos.

Quadro 2.3: Resultados dos métodos no reconhecimento de mão em Wang e Ruan (2006)

Método	Precisão
PCA	85,6%
FDA	80,5%
2DPCA	99,0%
2DFDA	99,1%

Em Attarchi *et al* (2008) os autores empregam o método *complex inversion mapping* e *best-fitting line* na etapa de segmentação da íris e para a normalização das imagens os autores empregaram modelo desenvolvido em Daugman (1993). Na etapa de extração de características empregam o filtro 1D-Gabor e em seguida utilizam o método 2DPCA para fins de redução de dimensão. Na etapa de classificação os autores empregam o método do vizinho mais próximo como classificador com a métrica Euclidiana. Os autores aplicaram o método proposto na base de dados de imagens de olhos CASIA. Os resultados experimentais

mostraram que, empregando projeção em 16 autovetores, no modo de identificação a taxa de reconhecimento correto foi de 99,32%, enquanto que no modo de verificação a taxa de erro equivalente (EER) foi de 0,68%.

Em Chen *et al.* (2009) os autores apresentam o trabalho de reconhecimento de íris no qual, após o pré-processamento, incluindo a segmentação e a normalização, os autores empregam um método de extração de características dividido em duas etapas. Na primeira etapa os autores empregam o método 2DPCA para compactar as imagens originais e, empregando um coeficiente de similaridade, extraem um subconjunto de imagens, $\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_k$, de dimensão $m \times n$, do conjunto original de treinamento. Na segunda etapa, os autores aplicam o que denominam de 2DPCA com o conceito de classe embutido. Este segundo procedimento consiste em encontrar duas matrizes de projeção, $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_d]$ e $\mathbf{Z} = [\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_q]$. A matriz \mathbf{X} é obtida determinando os autovetores associados aos d

maiores autovalores da matriz $\mathbf{G} = \frac{1}{c} \sum_{i=1}^c (\bar{\mathbf{A}}^{(i)} - \bar{\mathbf{A}})^T (\bar{\mathbf{A}}^{(i)} - \bar{\mathbf{A}})$, onde $\bar{\mathbf{A}}^{(i)}$ é a média das

imagens de treinamento da classe i , $\bar{\mathbf{A}}$ é a média das imagens de treinamento e c é o número de classes. Após a obtenção da matriz de projeção \mathbf{X} , a imagem original \mathbf{A}_k é projetada para se obter uma nova representação da imagem, \mathbf{B}_k , ou seja, $\mathbf{B}_k = \mathbf{A}_k \mathbf{X}$ de dimensão $m \times d$, com $d < n$. A matriz \mathbf{Z} é obtida determinando-se os autovetores correspondentes aos p

maiores autovalores da matriz $\mathbf{H} = \frac{1}{c} \sum_{i=1}^c (\bar{\mathbf{B}}^{(i)} - \bar{\mathbf{B}})(\bar{\mathbf{B}}^{(i)} - \bar{\mathbf{B}})^T$, onde $\bar{\mathbf{B}}^{(i)}$ é a média das

imagens classe i e $\bar{\mathbf{B}}$ é a média das imagens projetadas \mathbf{B}_k . A matriz de característica \mathbf{C}_k , de dimensão $d \times q$ é obtida projetando-se a imagem \mathbf{A}_k nas matrizes \mathbf{X} e \mathbf{Z} simultaneamente, ou seja, $\mathbf{C}_k = \mathbf{Z}^T \mathbf{A}_k \mathbf{X}$. Na etapa de classificação, os autores empregam o classificador do vizinho mais próximo com a métrica da distância Euclidiana. Os autores aplicaram o método proposto na base de dados de imagens de íris UBIRIS (UBIRIS, 2009) e comparam o desempenho com os métodos 2DFDA e 2DPCA. O Quadro 2.4 apresenta um resumo dos resultados obtidos.

Quadro 2.4 : Resultados dos métodos no reconhecimento de íris em Wen e Chuan (2009)

Método	EER (%)
2DFDA	0,95
2DPCA	0,78
Método Proposto por Chen <i>et al.</i> (2009)	0,74

EER: taxa de erro equivalente

3 FUNDAMENTAÇÃO TEÓRICA

3.1 INTRODUÇÃO

Neste capítulo descrevemos os conceitos e a fundamentação matemática empregados no desenvolvimento dissertação. Conforme já mencionado, o método implementado é baseado em subespaço tendo como base o método FDA. Também, o método PCA é abordado neste capítulo, devido ao grau de relacionamento que existe entre esses métodos, seja de ordem matemática ou conceitual.

3.2 VETOR DE CARACTERÍSTICAS

A aplicação da biometria utilizando imagens de face, íris, impressão digital, mão, entre outras, tem como princípio a obtenção de informações das intensidades dos pixels da imagem conforme ilustrado na Figura 3.1. Em geral, para uma matriz \mathbf{A} de dimensão $m \times n$ é formado um vetor \mathbf{a} de dimensão $mn \times 1$, ou seja, $\mathbf{a} = [a_{11}, a_{12}, \dots, a_{mn}]^T$, onde a_{ij} é o valor correspondente ao i -ésimo pixel. Tomando como exemplo imagens de íris, cada a_{ij} pode ser modelado como uma variável aleatória, pois suas observações em diferentes imagens apresentarão variações em seus valores, mesmo que as imagens sejam de um único indivíduo. Desta forma, \mathbf{a} é modelado como um vetor aleatório. Embora a abordagem considerada neste trabalho não empregue nenhum modelo probabilístico específico para a distribuição de \mathbf{a} , medidas estatísticas, como a média, a variância, a covariância, a correlação, entre outras são as bases dos métodos empregados.

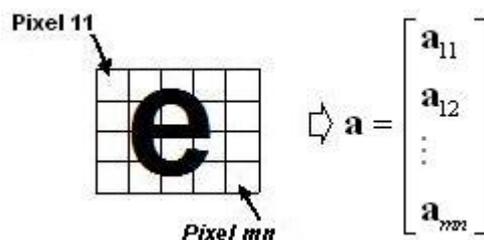


Figura 3.1: Ilustração da obtenção de informações de uma imagem

Pelo exposto, cada imagem é representada por um vetor em um espaço de dimensão $M = m \times n$ chamado de vetor de característica ou padrão. Um aspecto desejável em reconhecimento de padrões é que as características dos padrões não sejam redundantes, pois características redundantes não contribuem para discriminar padrões diferentes (THEODORIDIS E KOUTROUMBAS, 2003). Para que os padrões não tenham características redundantes, a covariância deve ser nula entre os vetores que compõem a base do espaço de imagem (CAMPOS, 2001).

3.3 ANÁLISE DE COMPONENTES PRINCIPAIS E EXTENSÕES

Análise de Componentes Principais (PCA - “*Principal Component Analysis*”) é um método de análise não paramétrico de extrair informações relevantes de conjuntos de dados. De uma forma geral, PCA é empregado para encontrar aspectos de dados que são importantes no reconhecimento de padrões (MARANA *et al*, 2001).

3.3.1 ANÁLISE DE COMPONENTES PRINCIPAIS (PCA)

Conforme mencionado anteriormente, uma propriedade desejável das características é serem mutuamente não correlacionadas, ou seja, deve haver covariância nula entre as características para evitar informações redundantes. Um modo de se verificar esta condição é avaliar a matriz de covariância dos padrões.

Considere um padrão de treinamento, representado pelo vetor \mathbf{a} , de dimensão mn . A matriz de covariância \mathbf{S} é calculada a partir dos N vetores de treinamento $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_N]$ como segue:

$$\mathbf{S} = \frac{1}{N} \sum_{k=1}^N (\mathbf{a}_k - \bar{\mathbf{a}})(\mathbf{a}_k - \bar{\mathbf{a}})^T \quad (3.1)$$

onde $\bar{\mathbf{a}}$ é a matriz cujas colunas contêm os vetores médios de \mathbf{A} , dada por

$$\bar{\mathbf{a}} = \frac{1}{N} \sum_{k=1}^N \mathbf{a}_k \quad (3.2)$$

Da definição (3.1), a matriz de covariâncias tem a seguinte forma

$$\mathbf{S} = \begin{bmatrix} c_{11} & \cdots & c_{1M} \\ & \ddots & \\ c_{M1} & \cdots & c_{MM} \end{bmatrix}, \quad (3.3)$$

e tem a propriedade de ser simétrica ($c_{ij} = c_{ji}$). Seus elementos na diagonal principal (c_{ii}) são as variâncias individuais das características e os elementos fora dessa diagonal ($c_{ij}, i \neq j$) as covariâncias entre características. Desta forma, para que as características sejam não correlacionadas (não redundantes), os elementos fora da diagonal principal devem ser nulos.

Dado um conjunto de treinamento \mathbf{A} , o algoritmo PCA encontra um transformador linear \mathbf{X} de forma a representar \mathbf{A} em outro espaço cuja matriz de covariância seja diagonal, ou seja:

$$\mathbf{Y} = \mathbf{X}^T \mathbf{A} \quad (3.4)$$

Neste problema de transformação linear, a solução é obtida com a matriz \mathbf{X} formada pelos autovetores da matriz de covariâncias \mathbf{S} (Equação 3.1). Este procedimento pode ser empregado com a finalidade de redução de dimensão, considerando na transformação somente os q autovetores $[\mathbf{u}_1, \mathbf{u}_2 \dots \mathbf{u}_q]$ associados aos q maiores autovalores $\lambda_1, \lambda_2 \dots \lambda_q$, onde esta notação considera os autovalores ordenados em ordem decrescente, isto é, $\lambda_i \geq \lambda_{i+1}$. (veja DUDA *et al*, 2001). Assim, para a redução de dimensão, a matriz de transformação é da forma

$$\mathbf{X} = [\mathbf{u}_1, \mathbf{u}_2 \dots \mathbf{u}_q] \quad (3.5)$$

Ressalta-se também que, uma vez que a matriz de covariância é real e simétrica, seus autovetores são ortonormais. Esta propriedade implica que os elementos que formam \mathbf{Y} são não correlacionados (CAMPOS, 2001).

Os q autovetores formam a base do novo subespaço que contem \mathbf{Y} , onde o autovalor λ_i define a carga de informação que seu autovetor associado \mathbf{u}_i carrega. Sendo que, quanto maior o valor de λ_i , maior a quantidade de informações contida no autovetor \mathbf{u}_i . Dado que $[\mathbf{u}_1, \mathbf{u}_2 \dots \mathbf{u}_q]$ formam a base de \mathbf{Y} , esses vetores carregam as principais informações do conjunto de treinamento \mathbf{A} . Esta propriedade define o nome do método como sendo análise de componentes principais (PCA). Dado tal afirmação, surge uma pergunta: Qual a quantidade de autovetores necessários para formar a matriz \mathbf{x} ? A resposta está na quantidade

de informações dos dados originais que se deseja transportar para o novo subespaço. Esta quantidade pode ser definida em termos de uma proporção da variância total dada por

$$\frac{\lambda_1 + \lambda_2 + \dots + \lambda_q}{\lambda_1 + \lambda_2 + \dots + \lambda_n} \quad (3.6)$$

e a estratégia consiste em escolher q autovetores, correspondentes aos q maiores autovalores, de forma que a quantidade de informações contida na base seja igual ou maior que uma proporção de informação g especificada.

3.3.2 ANÁLISE DE COMPONENTES PRINCIPAIS BI-DIMENSIONAL (2DPCA)

Na implementação do método PCA convencional a matriz de imagem (2D) é transformada em um vetor de imagem (1D), isso resultado geralmente em um vetor com espaço de dimensão elevada, onde o cálculo preciso da matriz de covariâncias das imagens de treinamento é difícil devido ao seu tamanho elevado e o relativo pequeno número de imagens de treinamento (YANG *et al*, 2004). A análise de componentes principais bi-dimensional (2DPCA), proposta em YANG *et al* (2004), ao contrário do PCA convencional, não transforma a imagem 2D em um vetor 1D, no método implementado a matriz de covariâncias é construída diretamente das matrizes das imagens de treinamento. Como resultado, a matriz de covariâncias é bem menor do que a matriz de covariância gerada pelo método PCA convencional.

Seja \mathbf{A}_i a i -ésima matriz das imagens de treinamento, de dimensão $m \times n$, $\bar{\mathbf{A}}$ a média de todas as imagens de treinamento e N é o número de imagens de treinamento. No método 2DPCA, empregando diretamente as imagens de treinamento, a matriz de covariâncias \mathbf{G}_H é obtida como segue (correlação das linhas):

$$\mathbf{G}_H = \frac{1}{N} \sum_{i=1}^N (\mathbf{A}_i - \bar{\mathbf{A}})^T (\mathbf{A}_i - \bar{\mathbf{A}}) \quad (3.7)$$

Assim como no PCA convencional, a matriz \mathbf{X} que faz a transformação linear (vetores de projeção) é formada pelos autovetores correspondentes aos q maiores autovalores da matriz de covariância \mathbf{G}_H , isto é:

$$\mathbf{X} = [\mathbf{u}_1, \mathbf{u}_2 \dots \mathbf{u}_q]. \quad (3.8)$$

Projetando-se uma imagem \mathbf{A} em \mathbf{X} obtêm-se sua matriz de características reduzida

$$\mathbf{Y} = \mathbf{A}\mathbf{X} \quad (3.9)$$

Na Equação (3.9) a dimensão da matriz de projeção \mathbf{X} é nxq e, portanto, a dimensão da matriz de característica \mathbf{Y} é mxq , com $q < n$.

3.3.3 2DPCA BI-DIRECIONAL

Como pode ser visto da Equação (3.9), o método 2DPCA realiza a redução de dimensão na direção horizontal da matriz original. O método bi-direcional 2DPCA, também conhecido como $(2D)^2PCA$, proposto em Zhang e Zhou (2005), tem por objetivo fazer reduções na direção horizontal e vertical. Desta forma, será obtida uma matriz de características gerada pelo método $(2D)^2PCA$ com a dimensão muito menor que a gerada pelo método 2DPCA.

O método $(2D)^2PCA$ consiste em encontrar duas matrizes de projeções: $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_q]$ e $\mathbf{Z} = [\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_d]$. A matriz \mathbf{X} é obtida através do método 2DPCA e realizando a redução de dimensão na direção horizontal. A matriz \mathbf{Z} é obtida pelo método denominado pelos autores de “*alternative 2DPCA*”, cuja implementação toma por base a determinação da matriz de covariância da forma (correlação das colunas)

$$\mathbf{G}_V = \frac{1}{N} \sum_{i=1}^N (\mathbf{A}_i - \bar{\mathbf{A}})(\mathbf{A}_i - \bar{\mathbf{A}})^T. \quad (3.10)$$

Em seguida são determinados os autovetores da matriz \mathbf{G}_V , os quais são empregados como projeção da imagem original, efetuando a redução de dimensão na direção vertical. Como pode ser verificado em (3.10), a matriz \mathbf{G}_V é de dimensão mxm . Sendo \mathbf{X} de dimensão nxd

e \mathbf{Z} de dimensão $mx d$. A matriz de características \mathbf{C}_k , de dimensão $dx q$, é obtida projetando-se a imagem \mathbf{A}_k nas matrizes \mathbf{X} e \mathbf{Z} simultaneamente, ou seja,

$$\mathbf{C}_k = \mathbf{Z}^T \mathbf{A}_k \mathbf{X} \quad (3.11)$$

3.4 ANÁLISE DISCRIMINANTE DE FISHER E EXTENSÕES

O método PCA não leva em conta o conceito de classes, ou seja, não garante que as características extraídas pelo método proporcionam boa discriminação entre as classes. Extrair características com pouco poder de discriminação das classes, pode levar a baixo desempenho de um classificador.

3.4.1 ANÁLISE DISCRIMINANTE DE FISHER (FDA)

A Análise Discriminante de *Fisher* (FDA - *Fisher Discriminant Analysis*), também denominada na literatura simplesmente de Análise Discriminante Linear (FDA - *Linear Discriminant Analysis*), visa extrair as características mais importantes, para fins de redução de dimensão, e acentuar o afastamento das classes. Em resumo, a projeção com FDA reduz a dimensão do espaço, aumenta as distâncias entre classes e reduz as distâncias entre amostras dentro das classes. Para este fim, FDA utiliza amostras de treinamento, dispostas em vetores, para construir a matriz de dispersão dentro da classe \mathbf{S}_w , dada por

$$\mathbf{S}_w = \sum_{i=1}^c \sum_{j=1}^{N_i} (\mathbf{a}_j^i - \bar{\mathbf{a}}_i)(\mathbf{a}_j^i - \bar{\mathbf{a}}_i)^T \quad (3.12)$$

onde \mathbf{a}_j^i é o j -ésimo vetor de treinamento (elemento) da classe i , $\bar{\mathbf{a}}_i$ é a média dos elementos da classe i , c é o número total de classes e N_i é o número de elementos da classe i . O método também determina a matriz de dispersão entre as classes \mathbf{S}_b , dada por

$$\mathbf{S}_b = \sum_{i=1}^c N_i (\bar{\mathbf{a}}_i - \bar{\mathbf{a}})(\bar{\mathbf{a}}_i - \bar{\mathbf{a}})^T \quad (3.13)$$

onde $\bar{\mathbf{a}}$ é a média global das amostras de treinamento.

O objetivo do método é obter uma matriz de projeção \mathbf{X} que maximize a dispersão entre as classes. Uma medida escalar da matriz de dispersão é o seu determinante. Utilizando esta medida, o método emprega o critério de *Fisher* que consiste em maximizar a função dado por

$$j(\mathbf{X}) = \frac{|\mathbf{S}_b|}{|\mathbf{S}_w|} = \frac{|\mathbf{X}^T \mathbf{S}_b \mathbf{X}|}{|\mathbf{X}^T \mathbf{S}_w \mathbf{X}|}. \quad (3.14)$$

A solução para o problema é obtida tomando a matriz \mathbf{X} formada pelos autovetores da matriz $\mathbf{S}_w^{-1} \mathbf{S}_b$. Em virtude do posto da matriz \mathbf{S}_b ser igual ou menor que $c-1$, o número máximo de autovetores não nulos de $\mathbf{S}_w^{-1} \mathbf{S}_b$ é $c-1$ (veja DUDA *et al*, 2001). Desta forma, a matriz de característica \mathbf{Y} é obtida empregando \mathbf{X} como matriz de projeção para uma imagem \mathbf{A} , ou seja,

$$\mathbf{Y} = \mathbf{X}^T \mathbf{A}, \quad (3.15)$$

onde a matriz de projeção $\mathbf{X} = [\mathbf{u}_1, \mathbf{u}_2 \dots \mathbf{u}_q]$ é composta dos q autovetores correspondentes aos q maiores autovalores $\lambda_1, \lambda_2 \dots \lambda_q$ não nulos da matriz $\mathbf{S}_w^{-1} \mathbf{S}_b$.

3.4.2 ANÁLISE DISCRIMINANTE DE FISHER BI-DIMENSIONAL (2DFDA)

Por analogia ao que já foi mencionado com relação aos objetivos do método FDA, o 2DFDA também tem por objetivo reduzir a dimensão do espaço da imagem original otimizando a separação das classes. O método foi proposto em Li e Yuan (2005), o qual computa os autovetores diretamente da matriz de dispersão sem a necessidade de converter a matriz de imagem em um vetor. Devido ao tamanho da matriz de dispersão ser igual ao tamanho da imagem, o qual é muito menor comparado com o tamanho da matriz de dispersão do FDA convencional, 2DFDA computa a matriz de dispersão mais precisamente e encontra os respectivos autovetores com mais eficiência. O método 2DFDA essencialmente opera na direção horizontal da imagem.

A partir de agora se faz a descrição do método. Sejam c o número de classes de padrões, N o total de amostras de treinamento, N_i o número de amostras da classe i , $\mathbf{A}_j^{(i)}$ a j -ésima imagem da classe i de dimensão $m \times n$, $\bar{\mathbf{A}}_j^{(i)}$ a média das imagens da classe i , e $\bar{\mathbf{A}}$ a média total das imagens de treinamento. Empregando as matrizes de imagens de treinamento, a matriz de dispersão entre classes \mathbf{S}_B e a matriz de dispersão dentro da classe \mathbf{S}_W são dadas, respectivamente, por

$$\mathbf{S}_B = \frac{1}{N} \sum_{i=1}^c N_i (\bar{\mathbf{A}}_i - \bar{\mathbf{A}})^T (\bar{\mathbf{A}}_i - \bar{\mathbf{A}}) \quad (3.16)$$

e

$$\mathbf{S}_W = \frac{1}{N} \sum_{i=1}^c \sum_{j=1}^{N_i} (\mathbf{A}_j^{(i)} - \bar{\mathbf{A}}^{(i)})^T (\mathbf{A}_j^{(i)} - \bar{\mathbf{A}}^{(i)}) \quad (3.17)$$

Como uma extensão do FDA, a aplicação do critério generalizado de *Fisher* visa obter uma matriz de projeção \mathbf{H} que maximize

$$J(\mathbf{H}) = \frac{\mathbf{H}^T \mathbf{S}_B \mathbf{H}}{\mathbf{H}^T \mathbf{S}_W \mathbf{H}} \quad (3.18)$$

A solução de (3.18) é a matriz de projeção $\mathbf{H} = [\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_q]$ formada pelos autovetores da matriz $\mathbf{S}_W^{-1} \mathbf{S}_B$, correspondentes aos seus q maiores autovalores, ou seja, os autovetores dominantes.

No método 2DFDA, fazendo $\mathbf{B} = \mathbf{A}\mathbf{H}$, obtém-se \mathbf{B} de dimensão $m \times q$, com $q < n$, o qual é empregado para descrever a imagem \mathbf{A} na etapa de classificação.

3.4.3 2DFDA BI-DIRECIONAL

Conforme já mencionado, o método 2DFDA realiza redução de dimensão na direção horizontal da matriz original. O método *bi-direcional* 2DFDA, também conhecido como $(2D)^2$ FDA, proposto em Nousath *et al* (2006), tem por objetivo a redução na direção

horizontal e vertical. Desta forma, será obtida uma matriz de características gerada pelo método $(2D)^2FDA$ com a dimensão muito menor que a gerada pelo método 2DFDA.

O método $(2D)^2FDA$ consiste em encontrar duas matrizes de projeção, $\mathbf{X}=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_d]$ e $\mathbf{Z}=[\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_q]$. A matriz \mathbf{X} é obtida através do método 2DFDA e realizando a redução de dimensão na direção horizontal. A matriz \mathbf{Z} é obtida pelo método denominado pelos autores de “*alternative 2DFDA*”, cuja implementação toma por base a determinação da matriz de dispersão entre classes e a matriz de dispersão dentro da classe, respectivamente como segue:

$$\mathbf{S}_B = \frac{1}{N} \sum_{i=1}^c N_i (\bar{\mathbf{A}}_i - \bar{\mathbf{A}})(\bar{\mathbf{A}}_i - \bar{\mathbf{A}})^T \quad (3.19)$$

$$\mathbf{S}_W = \frac{1}{N} \sum_{i=1}^c \sum_{j=1}^{N_i} (\mathbf{A}_j^{(i)} - \bar{\mathbf{A}}^{(i)})(\mathbf{A}_j^{(i)} - \bar{\mathbf{A}}^{(i)})^T. \quad (3.20)$$

Em seguida são determinados os autovetores da matriz $\mathbf{S}_W^{-1}\mathbf{S}_B$, o qual são empregados como projeção da imagem original, efetuada a redução de dimensão na direção vertical. A matriz $\mathbf{S}_W^{-1}\mathbf{S}_B$ é de dimensão $m \times m$. Sendo \mathbf{X} de dimensão $n \times d$ e \mathbf{Z} de dimensão $m \times q$. A matriz de características \mathbf{C}_k , de dimensão $d \times q$, é obtida projetando-se a imagem \mathbf{A}_k nas matrizes \mathbf{X} e \mathbf{Z} simultaneamente, ou seja,

$$\mathbf{C}_k = \mathbf{Z}^T \mathbf{A}_k \mathbf{X} \quad (3.21)$$

3.4.4 ANÁLISE DISCRIMINANTE DE FISHER DIAGONAL (DiaFDA)

A idéia do método DiaFDA é pré-processar a imagem original \mathbf{A} de dimensão $m \times n$ obtendo-se uma matriz \mathbf{D} de mesma dimensão, que integra informações de linhas e colunas de \mathbf{A} , de maneira a descrever conjuntamente as variações das informações entre linhas e colunas (NOUSHATH *et al*, 2006). A Figura 3.2 e Figura 3.3 ilustram os procedimentos para os casos de $m \leq n$ e $m > n$, respectivamente:

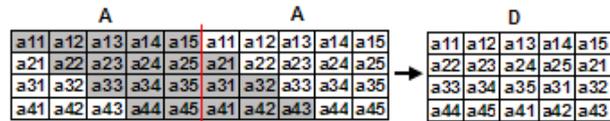


Figura 3.2 : Método de pré-processamento quando $m \leq n$

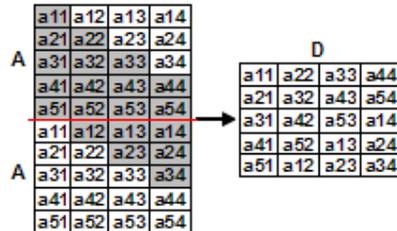


Figura 3.3 : Método de pré-processamento quando $m > n$

A Figura 3.4 ilustra o efeito do pré-processamento aplicado a imagem de face.



Figura 3.4 :Efeito do pré-processamento aplicado a imagem de face
 FONTE: Falah *et al* (2006)

O método 2DFDA é aplicado na matriz \mathbf{D} , obtendo-se a matriz de projeção $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_q]$ de dimensão $n \times q$. A matriz de características \mathbf{E} , de dimensão $m \times q$ é obtida projetando-se \mathbf{D} em \mathbf{E} , ou seja,

$$\mathbf{E} = \mathbf{D}\mathbf{W} \quad (3.22)$$

3.4.5 EXTRAÇÃO DE CARACTERÍSTICAS COM DiaFDA+2DFDA

Neste método, após a obtenção da matriz de projeção $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_q]$ pelo método DiaFDA descrita na subseção anterior, determina-se uma segunda matriz de projeção $\mathbf{V} = [\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_p]$, de dimensão $m \times p$, através da aplicação do método *alternativo* 2DFDA. O resultado final do método DiaFDA+2DFDA, é a obtenção da matriz de característica \mathbf{Y} , de dimensão $q \times p$, a qual é obtida projetando a imagem original \mathbf{A} nas duas matrizes de projeção \mathbf{W} e \mathbf{V} simultaneamente, isto é

$$\mathbf{Y} = \mathbf{V}^T \mathbf{A} \mathbf{W} \quad (3.23)$$

3.5 SISTEMAS BIOMÉTRICOS

Um sistema biométrico consiste em reconhecer automaticamente um indivíduo baseado em suas características físicas ou comportamentais. Na maioria das aplicações, o sistema captura dados biométricos de um indivíduo, extrai um conjunto de características desses dados e compara com um conjunto de amostras em uma base de dados.

3.5.1 SISTEMAS DE VERIFICAÇÃO E DE IDENTIFICAÇÃO

Sistemas biométricos podem ser empregados em dois tipos de aplicações: verificação e identificação (BOWYER *et al*, 2008). No cenário de verificação, uma pessoa afirma uma identidade particular e o sistema biométrico aceita ou rejeita a afirmação. A verificação é feita comparando a amostra adquirida no momento da afirmação com uma amostra previamente cadastrada. Se as duas amostras, segundo algum critério, combinam suficientemente, a identidade afirmada é aceita como verdadeira, caso contrário, a afirmação é rejeitada. Logo, existem quatro tipos de ocorrências possíveis: a correta aceitação (CA) ocorre quando o sistema aceita uma afirmação e a afirmação é verdadeira; uma falsa aceitação (FA) ocorre quando o sistema aceita uma afirmação de identidade, mas a afirmação é falsa; uma correta rejeição (CR) ocorre quando o sistema rejeita uma afirmação de identidade e a afirmação é falsa; uma falsa rejeição (FR) ocorre quando o sistema rejeita uma afirmação de identidade, mas a afirmação é verdadeira. O modo de verificação gera uma comparação um para um, ou

seja, compara a identidade afirmada com a identidade na base de dados (CASTELANO, 2006).

No modo identificação, uma amostra biométrica é adquirida sem nenhuma afirmação de identidade. O objetivo é associar a amostra desconhecida a de alguém conhecido e previamente cadastrado na base de dados. O trabalho desenvolvido nesta dissertação limita-se ao cenário de verificação.

3.5.2 MEDIDAS DE PRECISÃO

Uma tarefa importante no reconhecimento de padrões é a classificação. Dado um conjunto de amostras que pertençam a diferentes classes, queremos construir um classificador cujo objetivo é classificar as amostras às classes corretas. Quando se constrói um classificador, geralmente assume-se que o conjunto de amostras de teste não é conhecido, mas existe outro conjunto de dados previamente conhecido que pode ser usado para se extrair o conhecimento. A fase de construção do classificador é chamada de *treinamento* ou *aprendizado* e o conjunto de dados empregado nesta fase é chamado de conjunto (ou amostras) de treinamento ou aprendizado. Geralmente é difícil, ou quase impossível, construir um classificador perfeito, que classifique corretamente todas as amostras do conjunto de teste. Assim, escolhe-se um classificador ótimo, no sentido de que tenha o melhor desempenho no problema a ser resolvido. A literatura especializada apresenta vários tipos de classificadores, entre eles os probabilísticos e as redes neurais artificiais (DUDA *et al*, 2001).

Quando se está trabalhando com problemas de classificação com apenas duas classes, pode-se sempre rotular uma classe como positiva e outra como classe negativa, desta forma, o conjunto de teste consiste das amostras P (positivas) e N (negativas). No caso de sistemas biométricos os termos são, respectivamente, genuíno e impostor. O classificador atribui uma classe a cada amostra de teste, mas estas atribuições podem apresentar erros. Para avaliar os resultados da classificação, conta-se o número de verdadeiro positivo (TP), verdadeiro negativo (TN), falso positivo (FP) (na verdade negativo, mas classificado como positivo) e falso negativo (FN) (na verdade positivo, mas classificado como negativo). Assim, P e N são dados como segue

$$P = TP + FN \quad (3.24)$$

$$N = TN + FP \quad (3.25)$$

As equações a seguir definem duas medidas de desempenho de classificadores:

$$TP_{rate} = \frac{TP}{P} \quad (3.26)$$

e

$$FP_{rate} = \frac{FP}{N} \quad (3.27)$$

portanto, temos que TP_{rate} é a taxa de verdadeiro positivo e FP_{rate} a taxa de falso positivo.

Um classificador atribui um escore para cada amostra. Tal classificador é uma função $f : X \rightarrow [0,1]$ que mapeia cada amostra x a um número real $f(x)$. Normalmente, um limiar t é escolhido, no qual as amostras onde $f(x) \geq t$ são consideradas positivas e do contrário são consideradas negativas. Isso significa que, cada par de classificadores e o limiar t definem um classificador binário. Medidas como as definidas em (3.26) e (3.27) podem ser empregadas em classificadores, associadas a um limiar t . Variando-se t consegue-se uma família de classificadores binários que podem ser avaliados com relação a atender um critério especificado baseado em medidas de desempenho.

3.5.3 CURVA ROC

Suponha que se tenha desenvolvido um classificador que será utilizado em um sistema de alarme. Geralmente se está interessado na quantidade de alarmes causados por eventos positivos (alarme verdadeiro) e quantidade de alarmes causados por eventos negativos (alarme falso). A razão entre eventos positivos e negativos pode variar no tempo, então se deseja medir a qualidade do sistema de alarme independente desta razão. Nesse caso a curva ROC (*receiver operating characteristic*) é a ferramenta correta a ser empregada (VUK e CURK, 2006). Em um problema com duas classes, o objetivo é maximizar TP_{rate} e minimizar FP_{rate} . O gráfico da curva ROC consiste em um diagrama bidimensional cujas coordenadas (x,y) são definidas por:

$$x = FP_{rate}(t), \quad y = TP_{rate}(t) \quad (3.28)$$

Cada classificador binário, para um dado conjunto de teste, é representado por um ponto (ponto (FP_{rate}, TP_{rate}) no gráfico. Variando o limiar t do classificador probabilístico, consegue-

se um conjunto de classificadores, representados por um conjunto de pontos no gráfico. A curva ROC é independente da razão $P : N$ e é confiável para comparar classificadores. A Figura 3.5 ilustra a curva ROC.

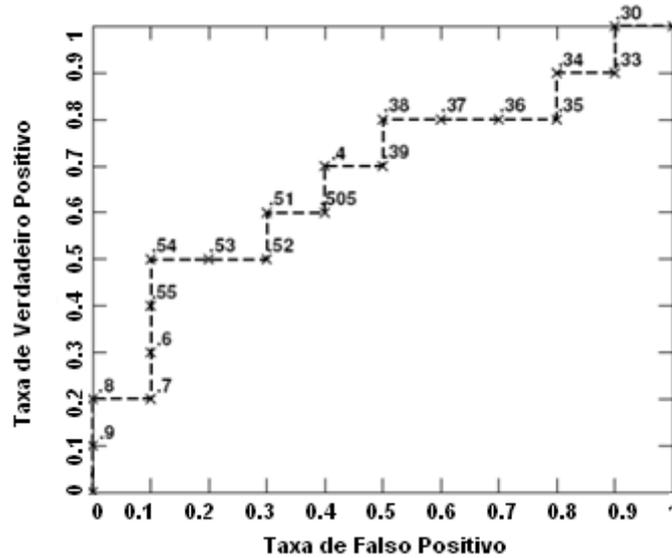


Figura 3.5 : Curva ROC de um classificador.

A Área Sobre a Curva ROC (AUC) e a Taxa de Erro Equivalente (EER) são duas medidas de desempenho derivadas da curva ROC que são utilizadas para comparar o desempenho de diferentes classificadores. A AUC é calculada de acordo com a fórmula seguinte:

$$AUC = \int_b^a \frac{TP}{P} d \frac{FP}{N} \quad (3.29)$$

Um classificador randômico (por exemplo, a classificação de lançamento de uma moeda) tem AUC igual a 0,5, enquanto um classificador perfeito tem AUC igual a 1. A EER representa o ponto onde TP_{rate} e FP_{rate} são iguais, e um bom sistema deve manter um alto valor de TP_{rate} e um baixo valor de FP_{rate} . A Figura 3.6 ilustra a AUC e a EER.

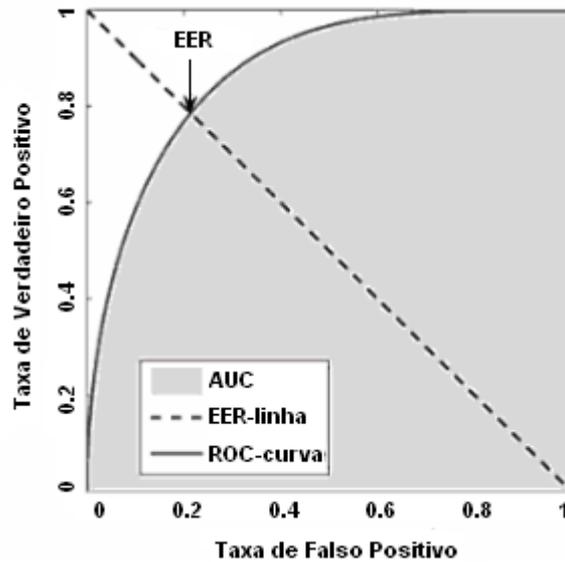


Figura 3.6 : Ilustração da AUC e EER

3.6 SEGMENTAÇÃO DA ÍRIS

As imagens da íris empregadas nos experimentos desta dissertação são imagens segmentadas e normalizadas pelo método desenvolvido por Lima *et al* (2008 e 2009). Esta seção do Capítulo 3 tem por objetivo descrever tal método, sendo o texto e as figuras seguintes uma adaptação dessas referências.

O processo de segmentação tem o objetivo de isolar uma ou mais regiões de interesse em uma imagem. A metodologia empregada para segmentar a íris consiste em encontrar seu contorno interno e externo, conforme ilustrado na Figura 3.7

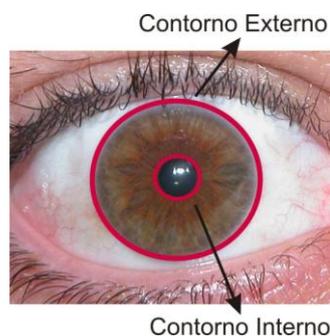


Figura 3.7: Contorno interno e externo da íris
 FONTE: Lima *et al* (2008 e 2009)

O contorno interno delimita a região íris/pupila e é obtido a partir da segmentação (isolamento) da pupila. O contorno externo delimita a região íris/esclera e é obtido com a segmentação da íris. Esses processos de segmentação são implementados com técnica de

reconhecimento de padrões em duas etapas, utilizando duas redes neurais artificiais para classificar os pixels da imagem ocular como sendo da pupila ou da íris. Uma vez obtido os contornos, a região da íris pode ser segmentada (isolada) da imagem.

3.6.1 DETECÇÃO DO CONTORNO INTERNO DA ÍRIS

Como já mencionado, o método emprega técnica de reconhecimento de padrões para classificar regiões da pupila e da íris da imagem ocular. Para a obtenção do contorno interno, emprega-se a região da pupila como referência, o processo inicia-se com a obtenção do vetor de característica que será empregado como entrada da rede neural, o qual é treinada com o algoritmo *backpropagation* com o objetivo de classificar pixels como sendo ou não da pupila.

Para a obtenção do vetor de característica, é utilizado o sistema de cor HSI, em que a representação da cor é feita pela tonalidade, saturação e intensidade. A estratégia é selecionar um conjunto de pontos (pixels) pertencente à pupila e outro conjunto fora da região da pupila, em que as componentes HSI de cada ponto são empregadas como entrada da rede neural.

A Figura 3.8 ilustra o processo de obtenção dos pontos que formarão o vetor de característica.

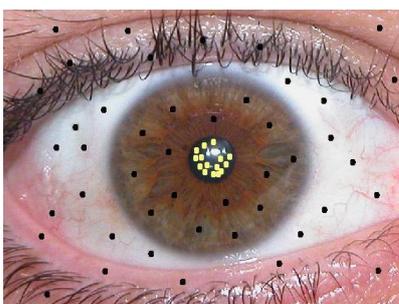


Figura 3.8: Obtenção dos pontos que formarão o vetor de características
FONTE: Lima *et al* (2008 e 2009)

A Figura 3.9 apresenta a arquitetura da rede neural empregada no processo de classificação da região da pupila.

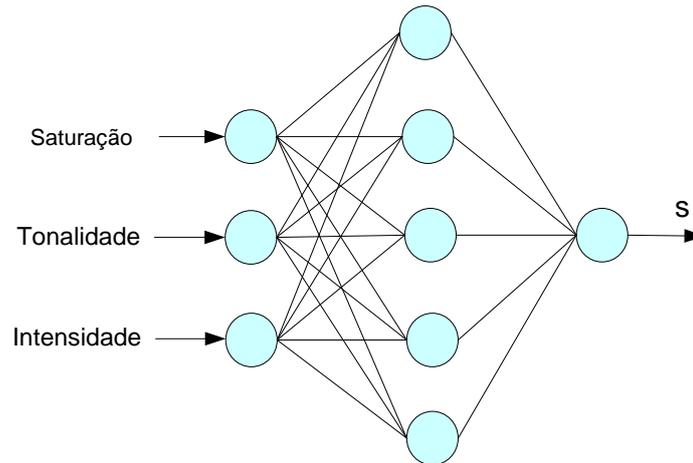


Figura 3.9: Arquitetura da rede neural artificial empregada no processo de classificação da pupila
 FONTE: Lima *et al* (2008 e 2009)

Após a o treinamento da rede neural, os pixels da imagem ocular Figura 3.10(a) são percorridos um a um e, a saída do classificador gera uma imagem como a ilustrada na Figura 3.10(b).

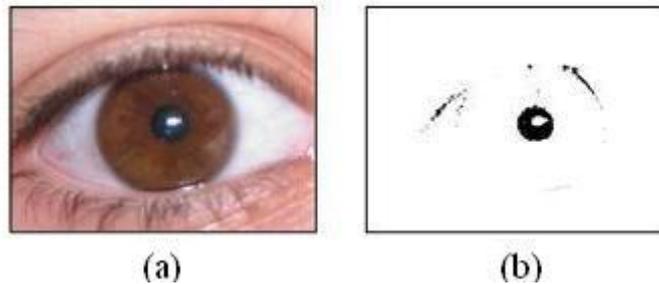


Figura 3.10: (a) imagem ocular; (b) imagem gerada pela saída do classificador
 FONTE: Lima *et al* (2008 e 2009)

Como pode ser observado na Figura 3.10(b), existem ruídos na imagem. Um pós-processamento (filtragem e preenchimento de região) é implementado para eliminação dos ruídos.

Após o pós-processamento a imagem da pupila tende a ficar como ilustrado na Figura 3.11.

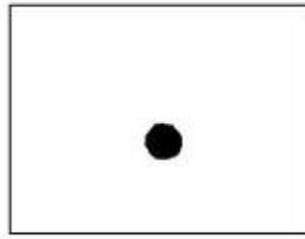


Figura 3.11: Imagem da pupila após o pré-processamento
FONTE: Lima *et al* (2008 e 2009)

Por fim, uma máscara circular é empregada para obtenção do raio e das coordenadas do centro da pupila, no qual são empregados para gerar todo o contorno da pupila.

A Figura 3.12 ilustra o contorno da pupila com centro e raio determinado pelo processo descrito. Este contorno será empregado mais adiante no processo de segmentação final da íris.

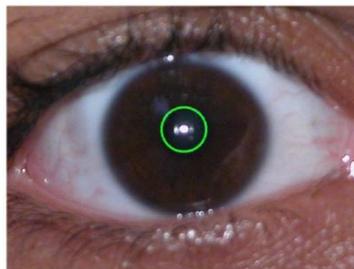


Figura 3.12: Ilustração do contorno interno da íris
FONTE: Lima *et al* (2008 e 2009)

3.6.2 DETECÇÃO DO CONTORNO EXTERNO DA ÍRIS

O processo de detecção do contorno externo da íris emprega a mesma metodologia utilizada no processo de obtenção do contorno da pupila, ou seja, emprega-se o mesmo conjunto de vetores de características e uma rede neural artificial, com a mesma arquitetura, para classificação da região da íris. A Figura 3.13 ilustra a imagem gerada pela saída do classificador. Um pós-processamento foi empregado para o preenchimento da área branca no interior da íris.

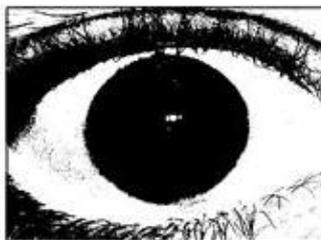


Figura 3.13: Imagem gerada pela saída do classificador da região da íris
 FONTE: Lima *et al* (2008 e 2009)

A Figura 3.14 mostra o resultado obtido após o pós-processamento.



Figura 3.14: Resultado do pós-processamento da imagem de saída do classificador da região da íris
 FONTE: Lima *et al* (2008 e 2009)

O raio do contorno externo da íris é obtido tendo como referência a coordenada do centro da pupila já obtida anteriormente, onde, partindo-se desta coordenada, caminha-se em direção a borda da íris até detectá-la. Este processo é repetido 31 vezes entre os ângulos de 15° e -15° e, 31 vezes entre os ângulos de 165° e 195° . O raio empregado para gerar o contorno da íris é a média dos raios 62 raios obtidos. A Figura 3.15 ilustra o contorno externo da íris.

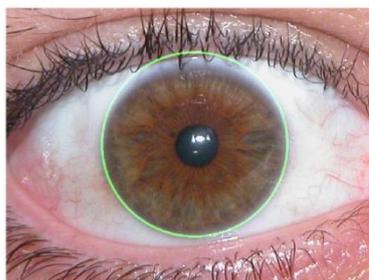


Figura 3.15: Ilustração do contorno externo da íris
 FONTE: Lima *et al* (2008 e 2009)

Mediante a obtenção dos contornos interno e externo da íris (Figura 3.16(a)), a segmentação da íris é finalmente executada (Figura 3.16(b)).

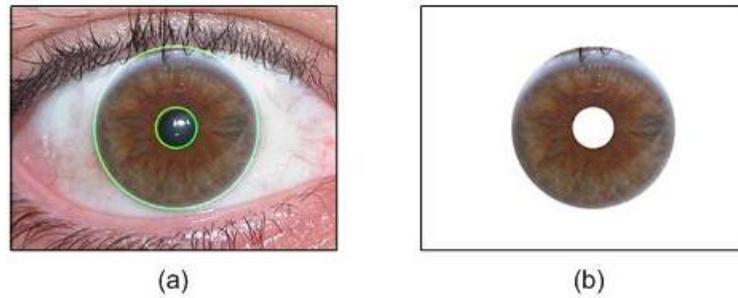


Figura 3.16: (a) Imagem com os contornos interno e externo, (b) Iris segmentada
 FONTE: Adaptado de Lima *et al* (2008 e 2009)

3.6.3 NORMALIZAÇÃO DA ÍRIS

Após a obtenção da imagem segmentada da íris, a mesma é submetida a um processo de normalização ou padronização, de modo que a região da íris de qualquer indivíduo tenha as mesmas dimensões, viabilizando a comparação entre imagens de diferentes indivíduos ou de mesmo indivíduo adquiridas em condições diversas.

No processo de normalização, a região anular correspondente à região da íris é mapeada em uma região retangular, ou seja, convertem-se as coordenadas polares em coordenadas retangulares. A Figura 3.17 ilustra esse processo. Cada *pixel* na área da região anular caracteriza-se por um par de coordenadas polares (θ , r). Cada *pixel* na área retangular é caracterizado por um par de coordenadas (x , y).

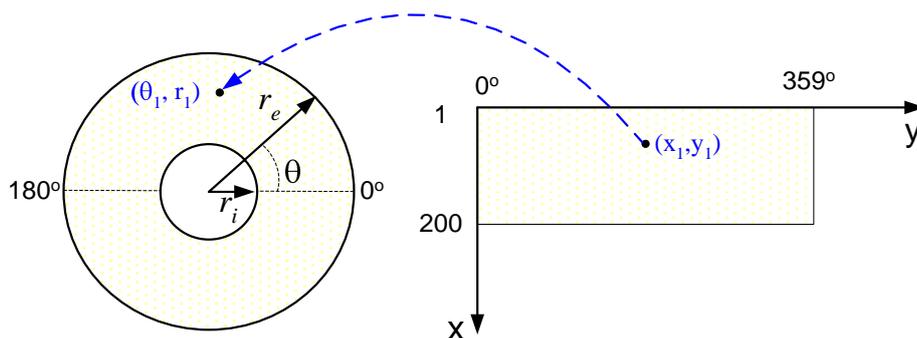


Figura 3.17: Diagrama do mapeamento no processo de normalização da região da íris
 FONTE: Lima *et al* (2008 e 2009)

Na Figura 3.18 ilustra-se o resultado da aplicação do método de padronização.



Figura 3.18: (a) Imagem segmentada da íris, (b) Imagem normalizada da íris
FONTE: Lima *et al* (2008 e 2009)

4 MATERIAIS E MÉTODOS

4.1 INTRODUÇÃO

Este capítulo apresenta a descrição da base de imagens de íris empregado no estudo comparativo, a descrição dos experimentos realizados e as métricas de comparação.

4.2 BASE UBIRIS

A base de dados de imagens UBIRIS foi criada pela *University of Beira Interior* (Portugal). A base UBIRIS.v1 é composto de 1877 imagens coletadas de 241 pessoas durante o mês de setembro de 2004 e é dividido em duas Seções distintas. Sua principal característica é incorporar imagens com diversos fatores de ruídos. Isso permite avaliar a robustez dos métodos de reconhecimento da Íris.

Na Seção um da base UBIRIS, os autores tentam minimizar os fatores de ruídos, especialmente os relacionados com reflexão, luminosidade e contraste com a utilização de aparatos no ambiente de captura das imagens. Na Seção dois, o ambiente é modificado com o objetivo de introduzir fatores naturais de luminosidade. Isso propicia o aparecimento de imagens heterogêneas com respeito à reflexão, contraste, luminosidade e problemas de foco. A base de imagens está disponível em três formatos, são eles: 800×600 - 24 bit color, 200×150 - 24 bit color e 200×150 - Grayscale. O formato utilizado neste trabalho é o 800×600 - 24 bit color.

4.3 OBTENÇÃO DAS IMAGENS DE TEXTURA DA ÍRIS

Para o desenvolvimento deste trabalho utilizam-se imagens pré-processadas pelo método desenvolvido em Lima *et al* (2008), conforme explanado no Capítulo 3, das imagens oculares da base UBIRIS.v1.

Com o objetivo de minimizar as interferências contidas na imagem segmentada e normalizada da íris pelos cílios e pálpebras, retiram-se da imagem as regiões onde são mais

prováveis tais interferências, obtendo-se assim o que se chama de região de interesse (ROI). A ROI é formada pelas colunas de 1 a 15, 165 a 210, 330 a 360 da imagem normalizada, sendo uma imagem de resolução 200×92 pixels. Após a obtenção da ROI, a mesma é convertida em imagem de intensidade. A Figura 4.1 ilustra o processo de obtenção da ROI.

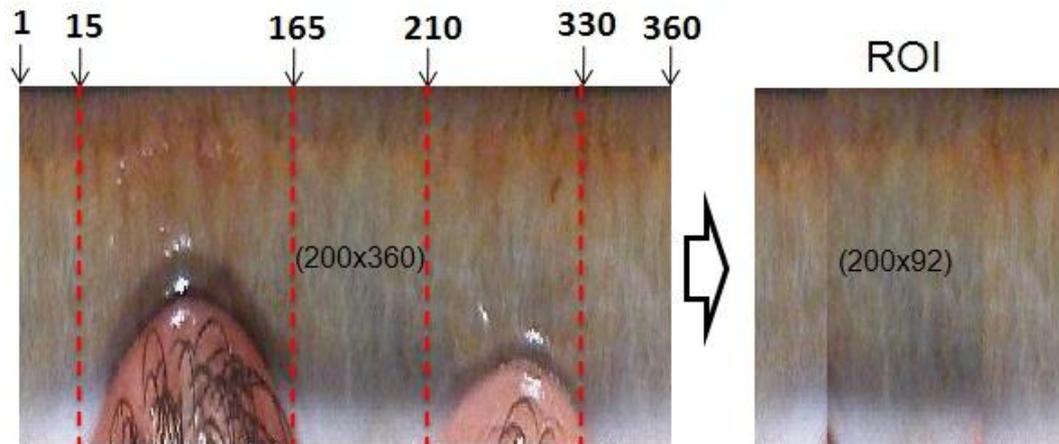


Figura 4.1: Processo de obtenção da ROI da imagem segmentada da íris

Algumas das imagens da base não foram empregadas no estudo, em virtude de oclusão total dos olhos, por exemplo. A Tabela 4.1 mostra informações do total de imagens utilizadas na validação do método implementado.

Tabela 4.1: Total de imagens utilizadas na validação do método de reconhecimento implementado

Seção	Imagens por indivíduos	Total de imagens utilizadas	Percentual de imagens utilizadas
1	6 indivíduos com 4 imagens	1199	98,76%
	235 indivíduos com 5 imagens		
2	11 indivíduos com 4 imagens	644	97,13%
	120 indivíduos com 5 imagens		

4.4 EXTRAÇÃO DE CARACTERÍSTICAS

Após a etapa de obtenção da ROI, descrita na subseção anterior, cada imagem será representada por uma matriz de característica, obtidas pelos métodos $(2D)^2FDA$ e $DiaFDA+2DFDA$. A Figura 4.2 ilustra o processo de extração de característica. A matriz de característica é utilizada na etapa de classificação.

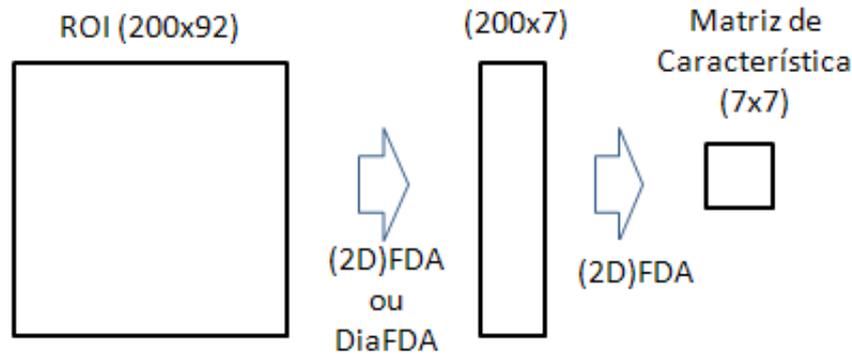


Figura 4.2 :Processo de obtenção da matriz de característica

4.5 EXECUÇÃO DOS EXPERIMENTOS

Dado a base de dados de imagens UBIRIS, levando em consideração que as imagens da íris já segmentadas e normalizadas por Lima (2008) e que cada imagem está agrupada em sua respectiva classe, isto é $[\mathbf{A}_{11}, \mathbf{A}_{12}, \mathbf{A}_{13}, \mathbf{A}_{14}, \mathbf{A}_{15}, \mathbf{A}_{21}, \dots, \mathbf{A}_{25}, \dots, \mathbf{A}_{mn}]$, onde m indica a classe do indivíduo e n indica a imagem pertencente à classe do indivíduo. Tem-se por objetivo primeiramente representar cada imagem da base por sua matriz de característica correspondente. Para isso, encontram-se vetores de projeção por intermédio do método $(2D)^2FDA$ ou DiaFDA+2DFDA (processo de treinamento), cujos detalhes estão descritos no Capítulo 3. No entanto, antes de se aplicar um dos métodos, retira-se uma imagem da base de dados (imagem de teste) e utilizam-se as demais no processo de treinamento. De posse dos vetores de projeção, projetam-se todas as imagens da base, inclusive a imagem de teste, nos referidos vetores.

De posse de todas as matrizes de característica, o próximo passo é calcular a similaridade (distância) entre a matriz de característica da imagem de teste e cada matriz de característica das imagens da base. As distâncias são obtidas pela métrica da distância Euclidiana da seguinte forma: sejam duas imagens \mathbf{A}_1 e \mathbf{A}_2 representadas por suas matrizes de característica $\mathbf{Y}_1 = [\mathbf{y}_1^1, \dots, \mathbf{y}_q^1]$ e $\mathbf{Y}_2 = [\mathbf{y}_1^2, \dots, \mathbf{y}_q^2]$, respectivamente. A distância $d(\mathbf{Y}_1, \mathbf{Y}_2)$ entre elas é definida por:

$$d(\mathbf{Y}_1, \mathbf{Y}_2) = \sum_{k=1}^q \|\mathbf{y}_k^1 - \mathbf{y}_k^2\| \quad (4.1)$$

onde, $\| \mathbf{y}_k^1 - \mathbf{y}_k^2 \|$ denota a distância Euclidiana entre dois vetores.

Cada distância calculada entre duas imagens é armazenada em um vetor da seguinte forma: se a distância calculada for entre imagens do mesmo indivíduo, então a distância é armazenada no vetor denotado de autêntico; caso contrário é armazenado no vetor denotado de impostor.

Define-se como um ciclo do experimento o processo de separação da imagem de teste da base de dados, aplicação do método de extração de características (obtenção dos vetores de projeção), projeção da base de imagens nos vetores de projeção e, por último, os cálculos das distâncias entre a imagem de teste e todas as imagens restantes da base, sendo as distâncias armazenadas nos vetores autêntico e impostor. O ciclo se repete até que todas as imagens da base de dados sejam empregadas como imagem de teste. Ratificando, o vetor autêntico contém todas as distâncias entre imagens de mesma classe (indivíduo). O vetor impostor contém todas as distâncias entre imagens de classes (indivíduos) diferentes. Esses vetores são empregados como entrada para a obtenção da curva ROC.

5 RESULTADOS E DISCUSSÕES

5.1 INTRODUÇÃO

Este capítulo apresenta os resultados dos experimentos, os quais são apresentados primeiramente a partir da análise ROC relativas aos métodos empregados e Seções da base UBIRIS. Em seguida os resultados são apresentados pela síntese da curva ROC, que são a taxa de erro equivalente (EER) e a área sobre a curva ROC (AUC). Na parte final do capítulo são apresentadas as discussões dos resultados.

5.2 ANÁLISE ROC: CURVA ROC

5.2.1 MÉTODO (2D)²FDA - SEÇÃO 1 DA BASE UBIRIS

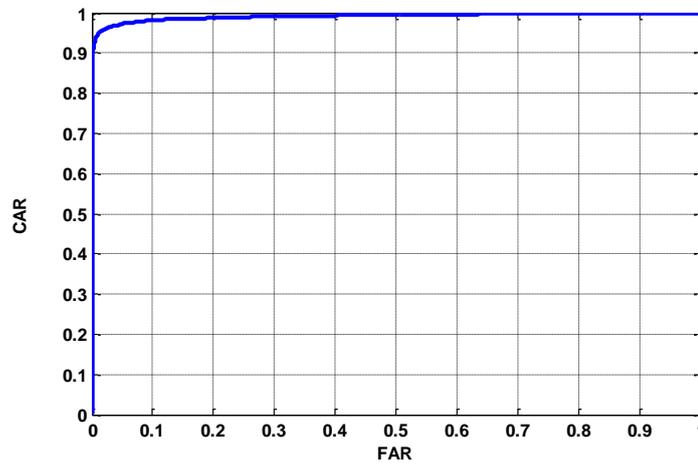


Figura 5.1: Curva ROC – método (2D)²FDA - projeção em 5 autovetores da Seção 1 do UBIRIS

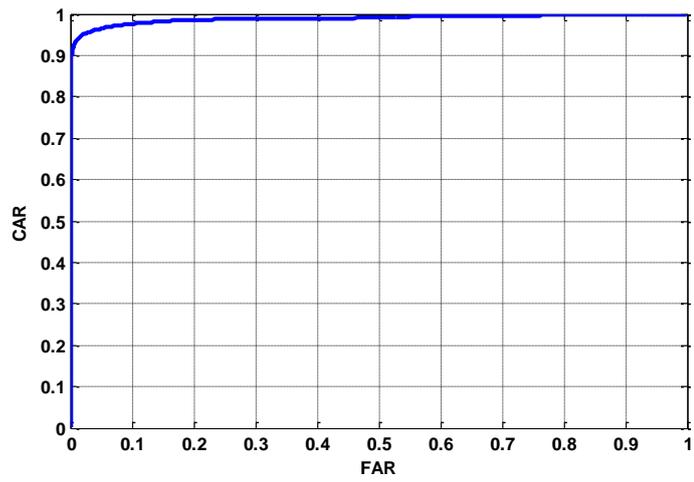


Figura 5.2: Curva ROC – método $(2D)^2FDA$ - projeção em 7 autovetores da Seção 1 do UBIRIS

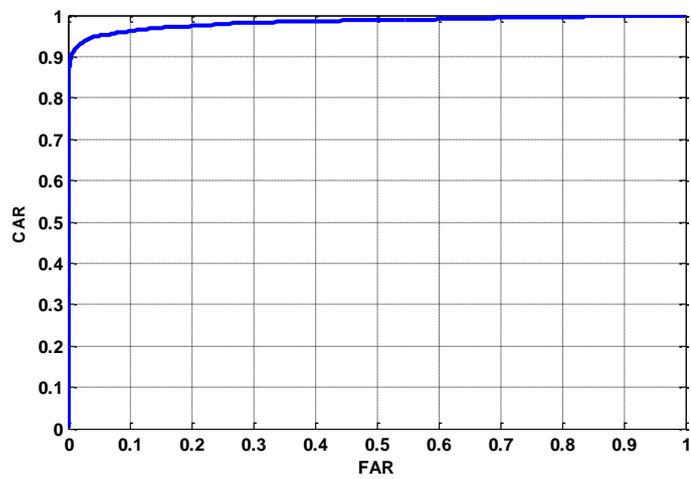


Figura 5.3: Curva ROC - método $(2D)^2FDA$ - projeção em 10 autovetores da Seção 1 do UBIRIS

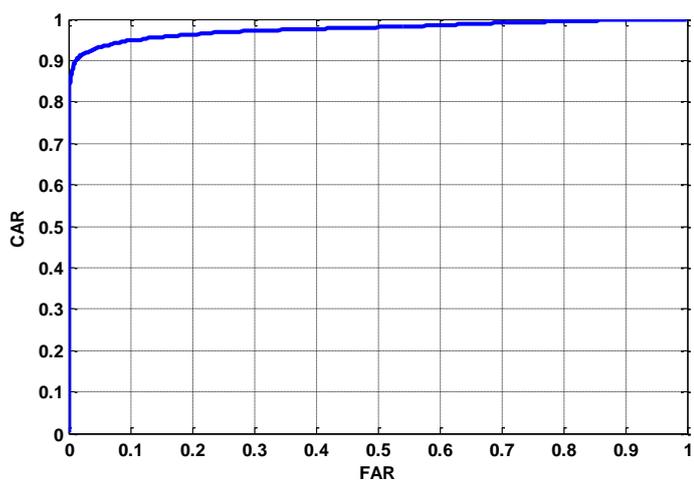


Figura 5.4: Curva ROC - método $(2D)^2FDA$ - projeção em 15 autovetores da Seção 1 do UBIRIS

5.2.2 MÉTODO $(2D)^2FDA$ - SEÇÃO 2 DA BASE UBIRIS

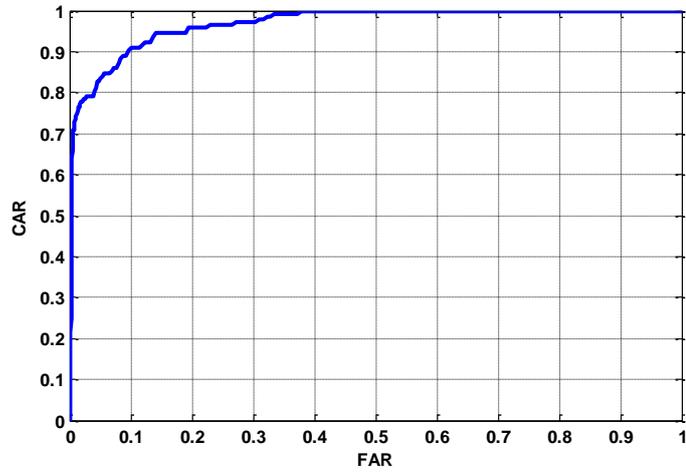


Figura 5.5: Curva ROC - método $(2D)^2FDA$ - projeção em 5 autovetores da Seção 2 do UBIRIS

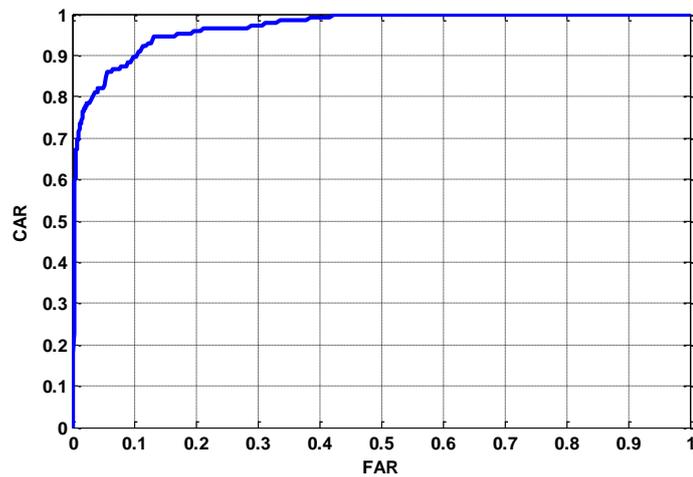


Figura 5.6: Curva ROC - método $(2D)^2FDA$ - projeção em 7 autovetores da Seção 2 do UBIRIS

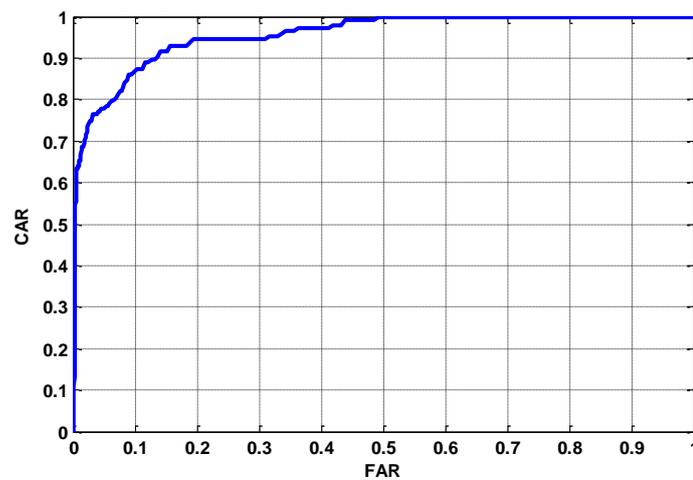


Figura 5.7: Curva ROC - método $(2D)^2FDA$ - projeção em 10 autovetores da Seção 2 do UBIRIS

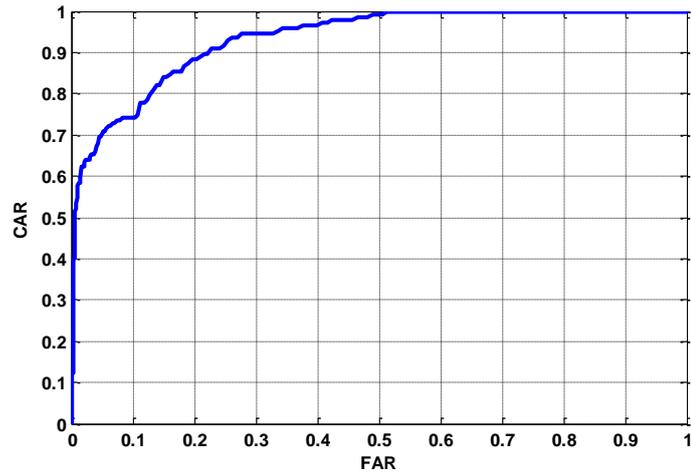


Figura 5.8: Curva ROC - método $(2D)^2FDA$ - projeção em 15 autovetores da Seção 2 do UBIRIS

5.2.3 MÉTODO DiaFDA +2DFDA – SEÇÃO 1 DA BASE UBIRIS

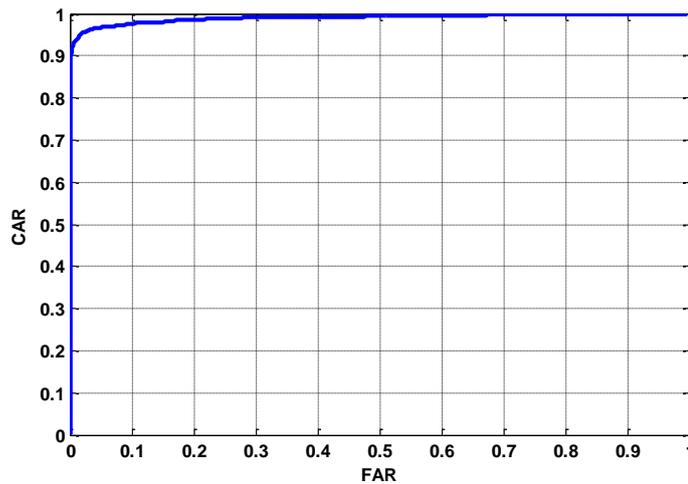


Figura 5.9: Curva ROC - método DiaLA+2DFDA - projeção em 5 autovetores da Seção 1 do UBIRIS

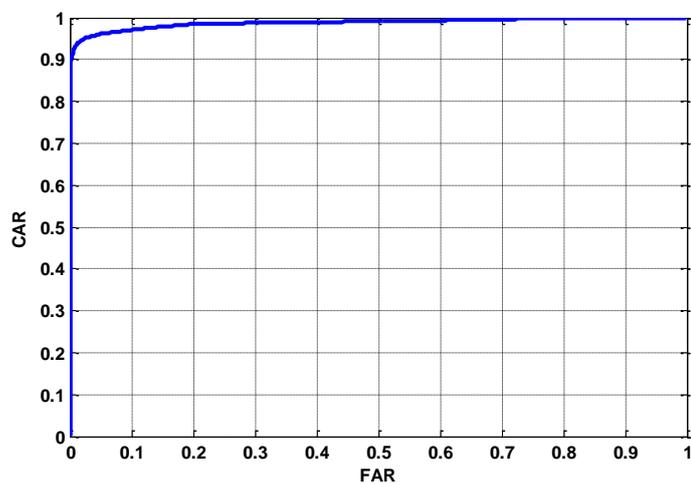


Figura 5.10: Curva ROC - método DiaFDA+2DFDA - projeção em 7 autovetores da Seção 1 do UBIRIS

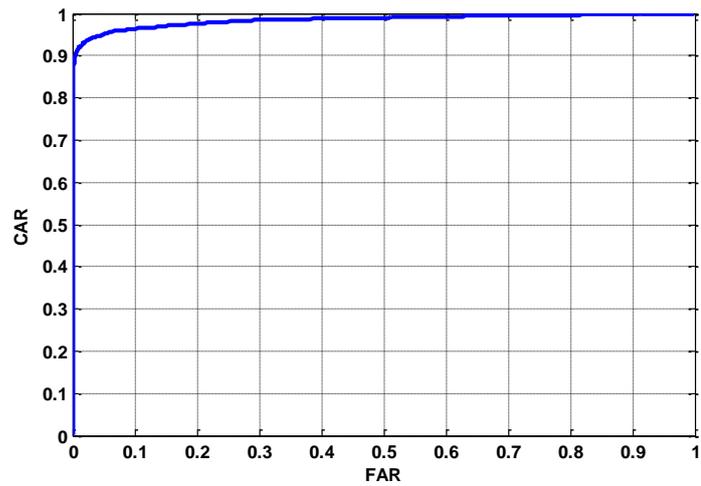


Figura 5.11: Curva ROC - método DiaFDA+2DFDA - projeção em 10 autovetores da Seção 1 do UBIRIS

5.2.4 MÉTODO DiaFDA +2DFDA – SEÇÃO 2 DA BASE UBIRIS

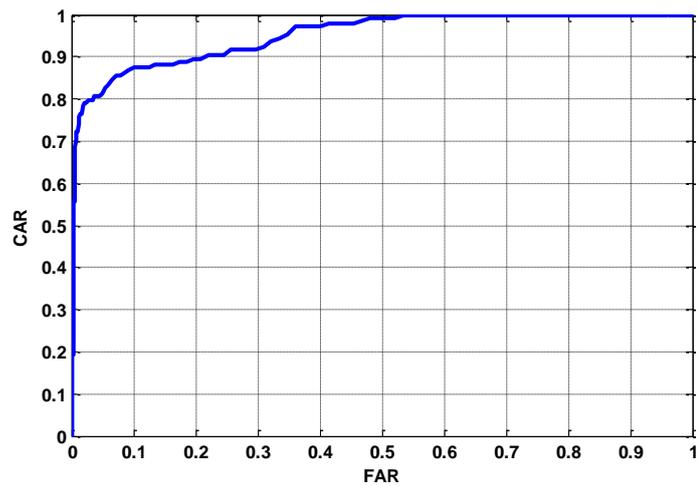


Figura 5.12: Curva ROC - método DiaFDA+2DFDA - projeção em 5 autovetores da Seção 2 do UBIRIS

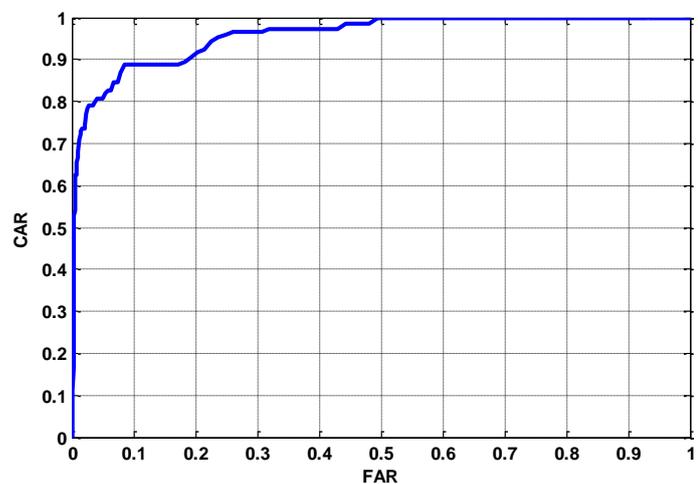


Figura 5.13: Curva ROC - método DiaFDA+2DFDA - projeção em 7 autovetores da Seção 2 do UBIRIS

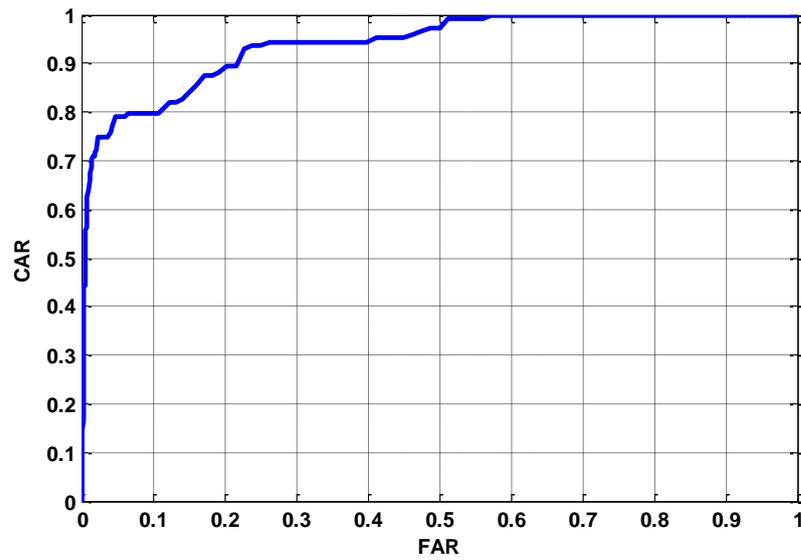


Figura 5.14: Curva ROC - método DiaFDA+2DFDA - projeção em 10 autovetores da Seção 2 do UBIRIS

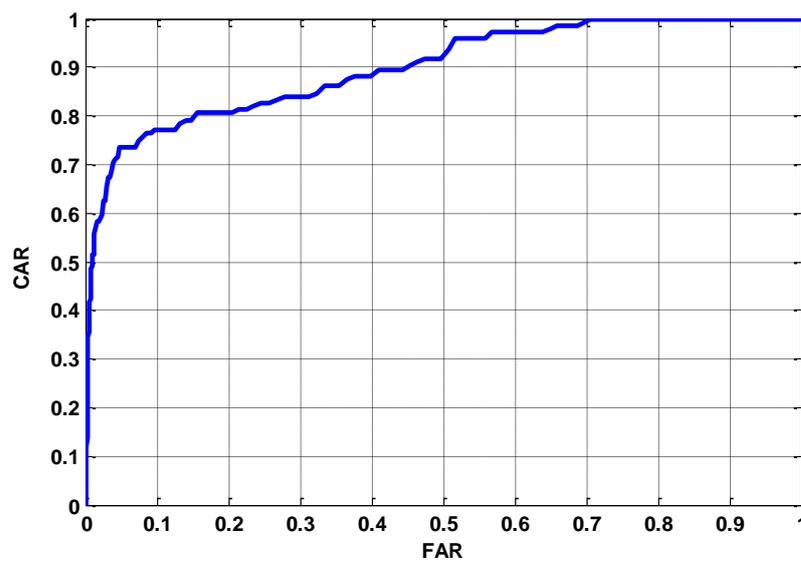


Figura 5.15: Curva ROC - método DiaFDA+2DFDA - projeção em 15 autovetores da Seção 2 do UBIRIS

5.3 ANÁLISE ROC: EER - AUC

Conforme mencionado no Capítulo 3, a EER e AUC são valores escalares que sintetizam a análise ROC, ou seja, demonstram o desempenho do sistema biométrico. A Tabela 5.1 mostra os resultados dos experimentos.

Tabela 5.1 : Valores obtidos de EER e AUC

Método	Dimensão da Matriz	Seção	EER (%)	AUC
(2D) ² FDA	5×5	1	3,49	0,99
		2	10,04	0,96
DiaFDA+2DFDA	5×5	1	3,79	0,99
		2	12,53	0,95
(2D) ² FDA	7×7	1	3,98	0,98
		2	10,68	0,96
DiaFDA+2DFDA	7×7	1	4,34	0,98
		2	11,52	0,95
(2D) ² FDA	10×10	1	5,01	0,98
		2	11,73	0,95
DiaFDA+2DFDA	10×10	1	4,98	0,98
		2	16,14	0,94
(2D) ² FDA	15×15	1	6,51	0,97
		2	16,09	0,93
DiaFDA+2DFDA	15×15	1	6,45	0,97
		2	19,46	0,89

5.4 DISCUSSÃO DOS RESULTADOS

De acordo com os resultados obtidos, apresentados na Tabela 5.1, pode-se verificar uma faixa de quantidade de vetores de projeção onde se obtém os melhores desempenhos de classificação e que, o desempenho cai, com o aumento da quantidade desses vetores. Esse comportamento foi verificado tanto no método (2D)²FDA como no DiaFDA+2DFDA para as Seções 1 e 2 da base UBIRIS. Verifica-se que entre as quantidades de vetores de projeção de 5×5 (5 vetores para projeção horizontal e 5 para vertical), 7×7 e 10×10, o desempenho dos classificadores não se altera significativamente para ambos os métodos e Seções da base.

Para o (2D)²FDA, o melhor desempenho ocorre com projeção em 5×5, em ambas as Seções da base. Para o método DiaFDA+2DFDA a projeção em 7×7 superou a projeção em 5×5 apenas na Seção 2 da base e no critério EER.

Como já esperado, em virtude da qualidade das imagens da Seção 1 ser superior a da Seção 2, os resultados de desempenho de ambos os métodos dos experimentos realizados na Seção 1 superou os da Seção 2 da base UBIRIS.

No que diz respeito à comparação de desempenho entre os dois métodos empregados nos experimentos, pode ser verificado que no critério de desempenho AUC, os valores para ambos os métodos são iguais ($AUC=0,99$) nos testes realizados na Seção 1 da base, com projeção em 5×5 . Comparando os resultados na Seção 2 da base, há uma pequena diferença de desempenho, sendo que o método $(2D)^2FDA$ superou o $DiaFDA+2DFDA$ em aproximadamente 1%. Conforme mencionado anteriormente, um classificador ideal tem AUC igual 1. Logo, podemos constatar o excelente desempenho de ambos os métodos.

No critério de desempenho EER, a diferença entre os métodos, para a Seção 1 é muito pequena (0,3%), sendo $EER=3,49\%$ para o método $(2D)^2FDA$ e $EER=3,79$ para o método $DiaFDA+2DFDA$. Nesse critério de desempenho, ainda existe uma alternância de desempenho, levando em conta a quantidade de vetores de projeção. Já na Seção 2 da base, levando em consideração a menor quantidade de vetores de projeção, ou seja, 5×5 , e que leva ao melhor desempenho de AUC, o método $(2D)^2FDA$ superou o $DiaFDA+2DFDA$ em 2,49%.

Em seguida, faz-se uma comparação com dois trabalhos realizados na base UBIRIS: Pinheiro (2010) e Chen *et al.* (2009). Estes trabalhos foram escolhidos para comparação pelo motivo de que o primeiro emprega o mesmo método de segmentação e normalização da íris que o método implementado nessa dissertação e que o segundo utiliza o mesmo procedimento em subespaço para a extração de características. A Tabela 5.2 apresenta os melhores resultados obtidos nos trabalhos mencionados como forma de comparação de desempenho.

Tabela 5.2 : Tabela comparativa de resultados de trabalhos relacionados

Trabalhos	Seção da Base	EER (%)	AUC	Matriz/Vetor de Característica
Implementado: $DiaFDA+2DFDA$	1	3,79	0,99	$5 \times 5 / 25$
	2	10,68	0,96	$7 \times 7 / 49$
Pinheiro (2010)	1	3,01	0,99	300
	2	5,18	0,97	300
Chen <i>et al.</i> (2009)	1	0,74	-	65
	2	-	-	-

Em Pinheiro (2010), seção 7, o autor menciona que seus melhores resultados foram com a transformada de *Wavelet* nível em 3, obtendo um vetor de características de dimensão 300, e em nível 4, um vetor de características de dimensão 78, sendo que, a transformada de *Wavelet* em nível 3 apresenta o melhor resultado. Avaliando os resultados em termos de memória para armazenamento do vetor de características, ressalta-se que os vetores de características em Pinheiro (2010) são binários, sendo necessários 38 *bytes* para armazenar 300 posições. Já o vetor de características do método implementado, não é binário, necessitando de 100 *bytes* para armazenar 25 posições.

No critério EER, o método apresentado em Chen *et al* (2009) apresentou o melhor resultado, com o valor de 0,74%, para a Seção 1 da base UBIRIS. Os autores não apresentam o resultado da EER para a Seção 2 da base, sendo que, o método apresentado em Pinheiro (2010) apresentou o melhor resultado para a Seção 2 da base, com o valor de 5,18%.

No de medida de desempenho AUC, o método DiaFDA+2DFDA e o apresentado em Pinheiro (2010) apresentam o mesmo desempenho para a Seção 1 da base, com o valor de 0,99. Para a Seção 2 da base, Pinheiro (2010) superou em 1% o método implementado com o valor de AUC de 0,97. O trabalho apresentado em Chen *et al* (2009) não apresenta o resultado da AUC.

Além da habilidade de classificação correta ou desempenho de reconhecimento de um sistema de reconhecimento de padrões, outro fator de grande importância, é o tamanho do vetor ou matriz de característica, visto que isso influencia tanto no tempo de processamento como no tamanho de memória requerida pelo sistema. Portanto, vamos abordar agora este critério. Pode-se verificar que o método implementado superou os dois métodos em comparação, com matriz de característica de 5×5 (vetor de dimensão 25), nos testes realizados na Seção 1 e 2 da base. Conforme já mencionado, o método implementado já foi aplicado no reconhecimento de faces em Noushath *et al* (2006), onde os autores conseguiram uma matriz de característica de 7×7 para uma taxa de reconhecimento de 98%.

É importante ratificar que a base UBIRIS contém algumas imagens com alto grau de ruído, e que mesmo assim foram utilizadas nos experimento. A Figura 5.16 mostra algumas dessas imagens.



Figura 5.16 :Exemplo de imagens da Seção 1 da base UBIRIS com alto grau de ruído empregadas nos experimentos

6 CONCLUSÃO

Métodos de extração de características baseados em subespaços têm sido amplamente empregados no reconhecimento de face, com bons resultados (RAO *et al.*, 2010). Também, encontram-se na literatura, alguns trabalhos aplicados a íris (Capítulo 2). Os métodos PCA e FDA são baseados em subespaços e têm sido muito empregados em problemas de reconhecimento de padrões na etapa de extração de características. O PCA tem como principal objetivo a redução de dimensão dos dados, sem que necessariamente esta redução altere a separação das classes. O FDA tem o mesmo objetivo, porém, se diferencia por também maximizar a separação das classes no seu espaço de projeção. O objetivo desse trabalho foi aplicar uma extensão do método FDA, denominado de DiaFDA+2DFDA e anteriormente aplicado em reconhecimento de face (Noushath *et al.* (2006)), no reconhecimento de íris, avaliando seu desempenho quando comparado ao método (2D)²FDA.

Pode-se verificar, pelos resultados apresentados, o grande poder de compressão de ambos os métodos. Por exemplo, os métodos implementados para fins de comparação chegaram a reduzir uma matriz de dimensão de 200×92 para 5×5 , alcançando uma AUC de 0,99. Isso traz grandes benefícios para aplicações em reconhecimento de padrões. Alguns dos benefícios são, viabilização de aplicações em sistemas embarcados, o emprego de classificadores tais como, redes neurais artificiais e classificadores estatísticos em aplicações nas quais se tem pequenas quantidades de amostras de treinamento e com o espaço original com grande dimensão. O desafio, portanto, é obter a redução de dimensão sem prejuízo à eficiência no processo de classificação, o que, pelos resultados apresentados, foi obtido.

O método implementado também foi comparado com outros dois métodos, implementados em Pinheiro (2010) e Chen *et al.* (2009) e que empregam a base UBIRIS em suas avaliações. Para o método implementado em Chen *et al.* (2009), que também é baseado em subespaço, com relação a Seção 1 da base, é reportado uma EER em torno de 0,74% que é inferior à obtida pelo método DiaFDA+2DFDA. No que diz respeito à redução de dimensão, no entanto, o DiaFDA+2DFDA foi mais eficiente, apresentando uma AUC de 0,99 com vetor de característica de dimensão 25, enquanto que o melhor resultado em Chen *et al.* (2009) foi necessário um vetor de dimensão 65.

Em comparação com o trabalho apresentado em Pinheiro (2010), os resultados revelam que o método DiaFDA+2DFDA foi superado no critério EER e apresentou os valores da AUC equivalentes. Com relação ao tamanho do vetor de características, a diferença a favor do DiaFDA+2DFDA foi bastante acentuada, pois para os melhores resultados em Pinheiro (2010) foi necessário um vetor de dimensão 300. No entanto, o método apresentado em Pinheiro (2010) necessita de menos memória para o armazenamento, uma vez que os vetores de característica do referido método é binário .

O método DiaFDA+2DFDA poderia ser descrito como “Pre-processamento+2DFDA+2DFDA” enquanto que o $(2D)^2FDA$ como “2DFDA+2DFDA”. Isto mostra que o método DiaFDA+2DFDA tem uma etapa a mais, implementada para tentar melhorar seu desempenho. De acordo as comparações realizadas, os resultados mostram que o desempenho do método DiaFDA+2DFDA é muito similar ao método $(2D)^2FDA$. Embora não tenha sido avaliado, pode ser conjecturado que devido ao pré-processamento (a diagonalização) o método DiaFDA+2DFDA demande mais tempo na execução da tarefa de verificação. Cabe aqui mencionar que, nos dois trabalhos que aplicam o pré-processamento, ou seja, Noushath *et al* (2006) e Zhang *et al* (2006), os autores não comparam os métodos implementados com os seus equivalentes, isto é, 2DFDA+2DFDA e 2DPCA+2DPCA. O que foi feito nesta dissertação.

Como trabalho futuro, poderiam ser implementados experimentos em que empregassem os algoritmos DiaFDA+2DFDA e o $(2D)^2FDA$ na etapa de extração de características e o vetor novidade, apresentado em Pinheiro (2010), na etapa de classificação do reconhecimento biométrico de íris. Esta proposta decorre do fato de que o trabalho apresentado nesta dissertação e o apresentado em Pinheiro (2010) têm o mesmo método de segmentação e normalização.

REFERÊNCIAS

AR, <http://www2.ece.ohio-state.edu/~aleix/ARdatabase.htm>, 1998

ATTARCHI, S.; FAEZ, K.; ASGHARI A.; “A Fast and Accurate Iris Recognition Method Using the Complex Inversion Map and 2DPCA”, Seventh IEEE/ACIS International Conference on Computer and Information Science, P.179-184, 2008.

BOWYER, K. W.; HOLLINGSWORTH K.; FLYNN P. J. “Image understanding for iris biometrics: A survey”, Computer Vision and Image Understanding, Vol. 110, P. 281-307, 2008.

CAMPOS, T. E. “Técnicas de Seleção de Características com Aplicações em Reconhecimento de Faces.” Dissertação de mestrado, Instituto de Matemática e estatística, Universidade de São Paulo, 2001

CASTELANO, C. R. “Estudo Comparativo da Transformada Wavelet no Reconhecimento de Padrões da Íris Humana.” Dissertação de mestrado, Escola de Engenharia de São Carlos, Universidade de São Paulo, 2006

CHEN, W. S.; CHUAN, C. A.; SHIH, S. W.; CHANG, S. H. “Iris Recognition Using 2DLDA+2DPCA”, IEEE, International Conference on Acoustics, Speech and Signal Processing, P.869-872, 2009.

DUDA, R. O.; HART, P. E.; STORK, D. G. Pattern Classification, 2nd Edition, Wiley-Interscience, United States of America, 2001

FALAH, E. A; RUAN, Q.; YUAN, B. T. “Face Recognition Using Diagonal 2D Linear Discriminant Analysis”, IEEE, 8th International Conference on Signal Processing, Vol. 3, 2006.

JAIN, A. K.; ROSS, A.; PRABHAKAR S. “An Introduction to Biometric Recognition”, IEEE Transactions on Circuits and Systems for Video Technology, Vol. 14, No. 1, 2004.

LIMA, L. O. Nova Proposta de Extração de Características da Íris Utilizando o Espaço HSI. 21º Congresso Brasileiro de Engenharia Biomédica, 2008.

LIMA, L. O. “ Segmentação da íris em imagens oculares para aplicações de reconhecimento biométrico de indivíduos - Uma nova abordagem utilizando rede neurais”, Dissertação de mestrado, PPGEE, UFAM, 2009

Li, M.; Yuan, B. “A statistical linear discriminant analysis for image matrix” Pattern Recognition Letters, Vol. 26, P. 527-532, 2005

MARANA, A. N.; FALGUERA, F. P.; FALGUERA, J. R.; JAIN, A. K. ”Biometrics for Human Identification.” RITA, Vol. VII, No. 1, 2001

NOUSHATH, S.; KUMAT, G. H.; SHIVAKUMARA, P. “Diagonal Fisher linear discriminant analysis for efficient face recognition”, Neurocomputing Letters, Vol. 69, P. 1711-1716, 2006

NOUSHATH, S.; KUMAT, G. H.; SHIVAKUMARA, P. “(2D)²LDA: An efficient approach for face recognition”, Pattern Recognition, Vol. 39, P. 1396-1400.

ORL, <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>, 2002

PINHEIRO, C. F. M. “Reconhecimento de indivíduos através da íris usando vetor novidade”, Dissertação de mestrado, PPGEE, UFAM, 2010

RAO, A.; NOUSHATH, S.; “Subspace methods for face recognition”, Computer Science Review, Vol. 4, P. 1-17, 2010.

THEODORIDIS, S.; KOUTROMBAS, K. “Pattern Recognition”. Elsevier, 2006

UBIRIS, Noisy Visible Wavelength Iris Image Databases, <http://iris.di.ubi.pt/>, 2009

VUK, M., CURK, T. "Roc curve, lift chart and calibration plot," Metodološki zvezki, Vol. 3, No. 1, P. 89-108, 2006.

WANG, M.; RUAN, Q. “Palmprint Recognition Based on Two-Dimensional Methods”, IEEE, 8th International Conference on Signal Processing, Vol. 4, 2006.

YALE, <http://vision.ucsd.edu/~leekc/ExtYaleDatabase/Yale%20Fase%20Database.html>, 2001.

YANG, J.; ZHANG, D.; FRANGI, A. F.; YANG, J-YU.; “Two-Dimensional PCA: A New Approach to Appearance-Based Face Representation and Recognition”, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 26, N. 1, 2004.

YANG, J.; ZHANG, D.; YONG, X.; YANG, J. “Two-dimensional discriminant transform for face recognition”, Pattern Recognition Society, Vol. 38, P. 1125-1129, 2005.

ZHANG, D.; ZHOU, Z. H.; CHEN, S. “Diagonal principal component analysis for face recognition”, Pattern Recognition, Vol. 39, P. 140-142, 2006.

Zhang, D.; Zhou, Z. “(2D)²PCA: Two-directional two-dimensional PCA for efficient face representation and recognition”, Neurocomputing, Vol. 69, P. 224–231, 2005

APÊNDICE

XXII CBEB (ISSN 2179-3220)

REPRESENTAÇÃO E CLASSIFICAÇÃO DE TEXTURAS DA ÍRIS BASEADO EM ANÁLISE DISCRIMINANTE LINEAR DIAGONAL

E. T. Assunção^{1,2}, J.R. G. Pereira², M. G. F. Costa^{1,2} e C. F. F. Costa Filho^{1,2}

¹Centro de Tecnologia Eletrônica e da Informação/UFAM, Manaus, AM, Brasil.

²Programa de Pós-graduação em Engenharia Elétrica/UFAM,

e-mail: eassunca@gmail.com

Abstract: Subspace methods are frequently used in pattern recognition problems and intend to reduce the space dimension by finding the projection vectors for that. This paper presents the subspace methods for feature extraction in iris image called two-dimensional linear discriminant analysis (2DLDA), diagonal linear discriminant analysis (DiaLDA) and their combination (DiaLDA+2DLDA). The methods were applied in UBIRIS image data base and the experimental results showed that DiaLDA+2DLDA overcame 2DLDA method in the recognition accuracy. Both methods are powerful in terms of dimension reduction and class discrimination.

Palavras-chave: reconhecimento de padrões, biometria da íris, redução de dimensão, extração de característica.

1. Introdução

Os recentes avanços da tecnologia da informação e os crescentes requisitos de segurança têm levado ao rápido desenvolvimento de técnicas de autenticação pessoal inteligente baseado em reconhecimento biométrico, tais como, de orelha, face, jeito de andar, geometria da mão e dedos, íris, impressão digital e da mão, retina, assinatura, voz entre outros [1]. A íris humana é uma parte interna do olho que se localiza entre a córnea e as lentes, tem uma complexa estrutura com muitas características, como fendas, sardas, criptas e radiações. Essas características visíveis, geralmente chamadas de textura da íris, são únicas para cada pessoa, mesmo para gêmeos idênticos [1]. O processo de reconhecimento da íris se resume basicamente em três partes: 1) pré-processamento da imagem - tem a finalidade de localizar e normalizar a região da íris, 2) extração de característica - tem a finalidade de codificar a imagem da íris e 3) classificação - tem a finalidade de classificar o código gerado associando a um determinado indivíduo [2]. A literatura exibe uma grande variedade de métodos de extração de características aplicados no processo de reconhecimento de imagens de íris [2], dentre eles os métodos baseado em subespaço.

Métodos de subespaço são uns dos mais empregados no processo de reconhecimento de face [3]. O objetivo da análise em subespaço é encontrar uma base de vetores que reduz a dimensão do espaço e,

em alguns casos, também otimiza a separação dos dados projetados em classes. Resumindo, um subespaço é um subconjunto de um espaço maior, que contém as propriedades deste.

Geralmente, imagens são de dimensão elevada, tipicamente \mathfrak{R}^m , onde m é muito grande. Por exemplo, se uma imagem de 100x100 pixels for concatenada em um vetor, sua dimensão será $m = 10000$. Isto leva a problemas, como por exemplo: custo computacional e dificuldades no processo de reconhecimento [3]. Se representarmos o conjunto de dados das imagens em

um subespaço \mathfrak{R}^q , onde $q \ll m$, os problemas citados podem ser reduzidos significativamente. Alguns dos métodos de subespaço mais conhecidos são Análise de Componentes Principais (PCA), Análise Discriminante Linear (LDA) e Análise de Componente Independente (ICA) [3]. Existem outros métodos baseado em subespaço, aplicado a imagens, que são variações destes métodos como: 1) Análise de Componentes Principais Bi-dimensional (2DPCA), aplicado a face [4] e aplicado a íris [5]; 2) Análise Discriminante Linear Bi-dimensional (2DLDA), aplicado a face [6] e aplicado a íris [7]; 3) Análise de Componentes Principais Diagonal (DiaPCA), aplicado a face [8].

O método DiaLDA+2DLDA é apresentado no processo de reconhecimento de face em [9]. Não foi encontrado na literatura, a aplicação do método DiaLDA+2DLDA no processo de extração de característica de imagens de íris. Dessa forma, este artigo apresenta o processo de reconhecimento de indivíduos através da íris utilizando um processo de extração de características baseado em subespaço, mais especificamente, utilizando-se o método DiaLDA+2DLDA.

2. Materiais e Métodos

2.1. Materiais

Neste trabalho utilizam-se imagens do banco de dados de imagens UBIRIS v.1 [10], processadas por um método automático de segmentação e normalização da íris utilizando o espaço de cores HSI e redes neurais artificiais desenvolvidos em [11]. A Figura 1 ilustra o

processamento da imagem realizado pelo método proposto em [11].

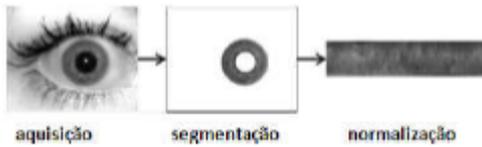


Figura 1: Etapas de segmentação e normalização da imagem da íris

O banco de dados imagens UBIRIS v.1 é composto de duas seções. A Seção 1 é composta de 241 classes ou indivíduos, com um total 1214 imagens, com as imagens feitas em ambiente controlado e com a cooperação dos indivíduos. A Seção 2 é composta de 132 classes com um total de 663 imagens que, ao contrário da Seção 1, as imagens são feitas em ambiente não controlado e com pouca cooperação dos indivíduos. Algumas das imagens do Banco não foram empregadas no estudo, em virtude de oclusão total dos olhos, por exemplo. A Tabela 1 mostra informações do total de imagens utilizadas na validação do método proposto.

Tabela 1: Total de imagens utilizadas no experimento.

Seção	Imagens por indivíduos	Total de imagens utilizadas	Percentual de imagens utilizadas
1	6 indivíduos com 4 imagens	1199	98,76%
	235 indivíduos com 5 imagens		
2	11 indivíduos com 4 imagens	644	97,13%
	120 indivíduos com 5 imagens		

As imagens do banco UBIRIS são "true color" 32 bits com resolução de 600×800 pixels. As imagens normalizadas são imagens de intensidade com resolução de 200×92 pixels.

2.2. Extração de característica com 2DLDA

O 2DLDA tem a finalidade de reduzir a dimensão do espaço de imagem otimizando a separação das classes. Sua origem é o método conhecido como *image matrix-based linear discriminant analysis* (IMLDA), o qual é baseado no critério de *Fisher*, aplicado à matriz que descreve a imagem [6].

Sejam c o número de classes de padrões, N o total de amostras de treinamento, N_i o número de amostras da classe i , $A_j^{(i)}$ a j -ésima imagem da classe i de dimensão $m \times n$, $\bar{A}_i^{(i)}$ a média das imagens da classe i , e \bar{A} a média total das imagens de treinamento.

Baseado nas matrizes de imagens de treinamento, a matriz de dispersão entre classes e matriz de dispersão dentro da classe são dadas, respectivamente, por:

$$S_B = \frac{1}{N} \sum_{i=1}^c N_i (\bar{A}_i - \bar{A})^T (\bar{A}_i - \bar{A}) \quad (1)$$

e

$$S_W = \frac{1}{N} \sum_{i=1}^c \sum_{j=1}^{N_i} (A_j^{(i)} - \bar{A}^{(i)})^T (A_j^{(i)} - \bar{A}^{(i)}) \quad (2)$$

em que S_B e S_W são positiva definida.

O critério generalizado de *Fisher* visa obter uma matriz de projeção H que maximize o seguinte quociente

$$\phi(H) = \frac{H^T S_B H}{H^T S_W H} \quad (3)$$

A solução de (3) é a matriz $H = [h_1, h_2, \dots, h_q]$ formada pelos autovetores de $S_W^{-1} S_B$ correspondentes aos q maiores autovalores. A matriz H é um transformador linear, convencionalmente chamada de matriz de projeção. No IMLDA, fazendo $B = AH$, obtém-se B de dimensão $m \times q$, com $q < n$, a qual é empregada para descrever a imagem A na etapa de classificação. O IMLDA, como apresentado, realiza uma redução de dimensão na direção horizontal da matriz de imagem original.

No 2DLDA é aplicada uma segunda vez o IMLDA, visando agora uma redução na direção vertical da matriz B . Aplicar IMLDA na direção vertical consiste em construir a matriz de dispersão entre classes G_B e a matriz de dispersão dentro da classe G_W tendo como entrada as matrizes B :

$$G_B = \frac{1}{N} \sum_{i=1}^c N_i (\bar{B}_i - \bar{B})(\bar{B}_i - \bar{B})^T \quad (4)$$

$$G_W = \frac{1}{N} \sum_{i=1}^c \sum_{j=1}^{N_i} (B_j^{(i)} - \bar{B}^{(i)})(B_j^{(i)} - \bar{B}^{(i)})^T \quad (5)$$

onde, $B_j^{(i)} = A_j^{(i)} H$, $\bar{B}^{(i)} = \bar{A}^{(i)} H$ e $\bar{B} = \bar{A} H$.

Em seguida emprega-se o critério de *Fisher* para otimização e obtenção da matriz de projeção $V = [v_1, v_2, \dots, v_p]$, que é formada pelos autovetores de $G_W^{-1} G_B$ correspondentes aos p maiores

autovalores. Desta forma, a matriz de característica C que representa a imagem A na etapa de classificação, é obtida pela seguinte transformação:

$$C = V^T B = V^T A H \quad (6)$$

onde C é de dimensão $p \times q$, sendo muito menor que a matriz de imagem original A de dimensão $m \times n$.

2.3. Extração de característica com DiaLDA

A idéia do método DiaLDA é pré-processar a imagem original A de dimensão $m \times n$ obtendo-se uma matriz D de mesma dimensão, que integra informações de linhas e colunas de A , de maneira a descrever conjuntamente as variações das informações entre linhas e colunas [9]. As Figuras 2 e 3 ilustram o procedimento para os casos de $m \leq n$ e $m > n$, respectivamente.

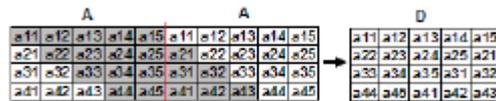


Figura 2: Método de pré-processamento quando $m \leq n$

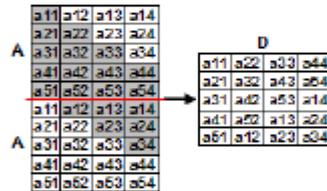


Figura 3: Método de pré-processamento quando $m > n$

Aplicando-se o método IMLDA nas imagens pré-processadas, obtendo-se a matriz de projeção $W = [w_1, w_2, \dots, w_q]$ de dimensão $n \times q$. Após a projeção obtém-se a matriz de característica $E = DW$, de dimensão $m \times q$.

2.4. Extração de característica com DiaLDA+2DLDA

Obtida a matriz de projeção $W = [w_1, w_2, \dots, w_q]$, deve-se obter a matriz de projeção $V = [v_1, v_2, \dots, v_p]$, de dimensão $n \times p$, através da aplicação do método IMLDA na direção vertical na imagem original A . O resultado final do método DiaLDA+2DLDA, é a obtenção da matriz de

característica Y , a qual é obtida projetando a imagem original A nas duas matrizes de projeção W e V , como segue:

$$Y = V^T A W \quad (7)$$

A Figura 4 ilustra o processo do método de transformação proposto, onde A é a matriz de imagem original, D é a matriz diagonal, W é a matriz de projeção do método IMLDA na direção horizontal, E é a matriz D projetada em W , V é a matriz de projeção do método IMLDA na direção vertical e Y é a matriz de características a ser empregada na classificação.

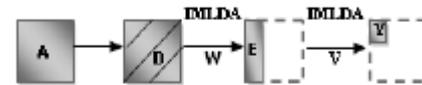


Figura 4: Diagrama de blocos do método DiaLDA+2DLDA

2.5. Classificação

Na etapa de classificação foi utilizado um classificador do vizinho mais próximo, com a métrica da distância euclidiana. Sejam duas imagens A_1 e A_2 representadas por suas matrizes de característica $Y_1 = [y_1^1, \dots, y_q^1]$ e $Y_2 = [y_1^2, \dots, y_q^2]$. A similaridade $d(Y_1, Y_2)$ entre elas é definida por:

$$d(Y_1, Y_2) = \sum_{k=1}^q \|y_k^1 - y_k^2\|, \quad (8)$$

onde $\|y_k^1 - y_k^2\|$ denota a distância Euclidiana entre dois vetores.

3. Resultados

Nos experimentos realizados, comparamos o método proposto somente com o 2DLDA, uma vez que são os dois métodos discutidos que realizam redução nas duas direções (horizontal e vertical). Apresentamos nesta seção os resultados obtidos empregando os métodos 2DLDA e DiaLDA+2DLDA aplicados na Seção 1 (S1) e na Seção 2 (S2) do banco de dados UBIRIS. Na execução dos experimentos para verificação do desempenho dos métodos foi empregada a validação cruzada *leave one out* [12]. Na Tabela 2 são mostrados os resultados para as taxas de acerto (TA) e as dimensões das matrizes de características. A TA corresponde a porcentagem de classificação correta de indivíduos e as dimensões apresentadas são as reduções com as quais se obteve os melhores

resultados de classificação, sendo 5, 7 e 10 o número de vetores de projeções.

Tabela 2: Taxas de Acertos e Dimensão da Matriz

Método	Dimensão	S1	S2
		TA (%)	TA (%)
2DLDA	5×5	98,83	96,58
DiaLDA+2DLDA	5×5	98,41	95,80
2DLDA	7×7	98,75	97,05
DiaLDA+2DLDA	7×7	98,91	96,42
2DLDA	10×10	98,16	96,58
DiaLDA+2DLDA	10×10	99,08	96,58

4. Discussão e Conclusões

Apresentou-se neste artigo a implementação do método proposto DiaLDA+2DLDA aplicados à imagens de íris. Para fins de comparação, também foi implementado o método 2DLDA. Os resultados mostraram que, para a Seção 1, os melhores resultados foram obtidos com a redução 10×10 e, neste caso, o método proposto apresentou resultado superior ao 2DLDA. Ainda para a Seção 1, com a redução para 7×7 o método proposto também foi superior, enquanto que para 5×5 o 2DLDA obteve melhor desempenho. Com relação à Seção 2, o método proposto obteve resultado equivalente ao 2DLDA com a redução para 10×10 e foi superado por este com as reduções para 7×7 e 5×5.

Deve ser observado que as taxas de acerto dos métodos comparados apresentam valores muito próximos, o que pode sugerir estudos complementares para uma melhor avaliação dos desempenhos destes métodos, possivelmente empregando também outros bancos de dados e critérios adicionais de comparação. Ainda assim, estes resultados sugerem que o método proposto tem potencial para ser empregado na identificação de indivíduos baseado em imagens da íris.

Uma observação importante, em ambos os métodos apresentados e comparados, é a grande redução da dimensão do espaço, por exemplo, de 200×92 para 7×7. Isso é um grande benefício para aplicações em reconhecimento de padrões nas quais se tem poucas amostras de treinamento e alta dimensão do espaço. Obter a redução de dimensão sem prejuízo à eficiência no processo de classificação foi um dos aspectos exibidos pelo método proposto. Adicionalmente, tem-se que a elevada redução do espaço viabiliza a utilização de outros classificadores tais como redes neurais artificiais e classificadores estatísticos.

Referências

[1] Jain, A. K., Ross, A., Prabhakar S. (2004), "An Introduction to Biometric Recognition", IEEE

Transactions on Circuits and Systems for Video Technology, v. 14, n. 1.

- [2] Bowyer, K. W., Hollingsworth K., Flynn P. J. (2008), "Image understanding for iris biometrics: A survey", *Computer Vision and Image Understanding*, v. 110, p. 281-307.
- [3] Rao, A., Noushath, S. (2010), "Subspace methods for face recognition", *Computer Science Review*, v. 4, p. 1-17.
- [4] Yang, J., Zhang, D., Frangi, A. F., Yang, J.-yu. (2004), "Two-Dimensional PCA: A New Approach to Appearance-Based Face Representation and Recognition", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 26, n. 1.
- [5] Attarchi, S., Faez, K., Asghari A. (2008), "A Fast and Accurate Iris Recognition Method Using the Complex Inversion Map and 2DPCA", *Seventh IEEE/ACIS International Conference on Computer and Information Science*, p.179-184.
- [6] Yang, J., Zhang, D., Yong, X., Yang, J. (2005), "Two-dimensional discriminant transform for face recognition", *Pattern Recognition Society*, v. 38, p. 1125-1129.
- [7] Chen, W. S., Chuan, C. A., Shih, S. W., Chang, S. H. (2009), "Iris Recognition Using 2DLDA+2DPCA", *2009 IEEE International Conference on Acoustics, Speech and Signal Processing*, p.869-872.
- [8] Zhang, D., Zhou, Z. H., Chen, S. (2006), "Diagonal principal component analysis for face recognition", *Pattern Recognition*, v. 39, p. 140-142.
- [9] Noushath, S., Kumat, G. H., Shivakumara, P. (2006), "Diagonal Fisher linear discriminant analysis for efficient face recognition", *Neurocomputing Letters*, v. 69, p. 1711-1716.
- [10] Banco de dados UBIRIS. Disponível em <http://iris.di.ubi.pt/>. Acesso em 03 março de 2010.
- [11] Lima, L. O., Costa, M. G. F., Costa Filho, C.F. F. (2008), "Nova Proposta de Extração de Características da Íris Utilizando o Espaço HSI", *21º Congresso Brasileiro de Engenharia Biomédica* ISBN: 978-85-60064-13-7.
- [12] Theodoridis, S., Koutroumbas, K. (2003), *Pattern Recognition*, United State of America: Elsevier.