



UNIVERSIDADE FEDERAL DA PARAÍBA

CENTRO DE INFORMÁTICA

PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

# **ANÁLISE DE TÉCNICAS DE NORMALIZAÇÃO APLICADAS AO RECONHECIMENTO FACIAL**

IGOR LUCENA PEIXOTO ANDREZZA

JOÃO PESSOA – 2015

IGOR LUCENA PEIXOTO ANDREZZA

# **ANÁLISE DE TÉCNICAS DE NORMALIZAÇÃO APLICADAS AO RECONHECIMENTO FACIAL**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Informática do Centro de Informática da Universidade Federal da Paraíba – UFPB, como requisito parcial para obtenção do título de Mestre em Informática.

Orientador: Prof. Dr. Leonardo Vidal Batista

JOÃO PESSOA – 2015

## ATA DA SESSÃO PÚBLICA

*Dedico este trabalho aos meus pais que sempre me apoiaram e incentivaram ao longo de toda minha vida.*

## **AGRADECIMENTOS**

A Deus.

Aos meus pais por todos os ensinamentos, que me fizeram ser quem sou.

Ao meu irmão, por aguentar meu mau humor enquanto estudava.

Ao meu orientador, o professor doutor Leonardo Vidal Batista, por seus ensinamentos durante os três anos como petiano e mais os dois anos como mestrando.

Aos meus amigos por estarem sempre presentes nos momentos bons e ruins da minha vida.

Aos meus colegas de curso, que conviveram comigo ao longo do curso, me dando suporte sempre que necessário.

A morte do homem começa no instante em que ele desiste  
de aprender.  
(Albino Teixeira)

## RESUMO

A biometria oferece um mecanismo de autenticação confiável, que identifica os usuários por intermédio de suas características físicas e comportamentais. O problema do reconhecimento facial não é trivial, pois existem muitos fatores que influenciam na detecção e no reconhecimento de face como, por exemplo, a iluminação, a posição da face, cabelo, barba, etc. Este trabalho se propõe a analisar os efeitos de técnicas de normalização geométrica e de iluminação sobre métodos de reconhecimento de face, visando adequar esses métodos para ambientes não controlados. Os resultados mostram que a presença do plano de fundo no processo de normalização contribui para aumentar as taxas de erro no reconhecimento de face, fato que ocorre em vários trabalhos presentes na literatura. Nesta dissertação, verificou-se que a aplicação de técnicas de normalização de iluminação e normalização geométrica, quando realizadas com pontos precisos dos centros dos olhos, efetivamente ajuda na tarefa de reconhecimento facial.

Palavras-chave: Normalização Geométrica, Normalização de Iluminação, Reconhecimento de Face, Biometria.

## **ABSTRACT**

Biometrics offers a reliable authentication mechanism that identifies the users through their physical and behavioral characteristics. The problem of face recognition is not trivial because there are many factors that affect the face detection and recognition, as for example, lighting, face position, hair, beard, etc. This work proposes to analyze the effects of geometric and lighting normalization on face recognition techniques, aiming to adapt them to uncontrolled environments. The results show that the utilization of background information in the normalization process increases the face recognition error rates and this happens in many papers in the literature. The lighting and geometric normalization methods, when performed with precise points of the eyes centers, effectively help in face recognition.

**Keywords:** Biometrics, Face recognition, Illumination Normalization, Geometric Normalization.



## LISTA DE FIGURAS

|                                                                                                                                                                                                                                                                                                        |    |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1: Processamento digital e imagens e áreas correlatas. Fonte: Batista, 2005. ....                                                                                                                                                                                                               | 19 |
| Figura 2: Ilustração dos métodos de reconhecimento de faces. (a) Método holístico (PCA); (b) Método não-holístico. Fonte: Adaptado de Xu, Z.; Lu L. and Shi P., 2008.....                                                                                                                              | 21 |
| Figura 3: Processos de sistema de reconhecimento de face. ....                                                                                                                                                                                                                                         | 22 |
| Figura 4: Ilustração das curvas FAR e FRR e do ponto EER .....                                                                                                                                                                                                                                         | 23 |
| Figura 5: Resultado da detecção de face realizada pelo ASM .....                                                                                                                                                                                                                                       | 24 |
| Figura 6: Resultado do filtro de equalização de histograma. a) imagem original b) imagem equalizada .....                                                                                                                                                                                              | 25 |
| Figura 7: Método LogAbout. Adaptado de [Liu et al., 2002] .....                                                                                                                                                                                                                                        | 26 |
| Figura 8: Normalização com o método LogAbout. (1) Imagem Original (2) Imagem resultante do Log (3) Imagem Resultante do LogAbout. [LIU et. al., 2002] .....                                                                                                                                            | 27 |
| Figura 9: Resultado da aplicação do MSR [Zia-ur R. et al., 2004] .....                                                                                                                                                                                                                                 | 28 |
| Figura 10: Operador LBP básico [Ahonen et al, 2004].....                                                                                                                                                                                                                                               | 29 |
| Figura 11: Operador LBP com vizinhanças (8, 1), (16, 2) e (8, 2) [Ahonen et al, 2004] .....                                                                                                                                                                                                            | 29 |
| Figura 12: Mudança abrupta de nível de cinza. (a) Imagem original (b) DCT .....                                                                                                                                                                                                                        | 32 |
| Figura 13: Mudança suave de níveis de cinza. (a) Imagem original (b) DCT .....                                                                                                                                                                                                                         | 32 |
| Figura 14: Demonstração gráfica de como o algoritmo knn funciona (k=5). ....                                                                                                                                                                                                                           | 33 |
| Figura 15: Ilustração do deixe-um-de-fora.....                                                                                                                                                                                                                                                         | 34 |
| Figura 16: Amostras do Banco de Faces GTAV .....                                                                                                                                                                                                                                                       | 37 |
| Figura 17: Indivíduo 1 com suas 11 amostras .....                                                                                                                                                                                                                                                      | 38 |
| Figura 18: Amostras do banco de Yale Face Database B.....                                                                                                                                                                                                                                              | 38 |
| Figura 19: Exemplo de imagem do Banco VSOFT.....                                                                                                                                                                                                                                                       | 39 |
| Figura 20: Arquitetura do sistema de reconhecimento.....                                                                                                                                                                                                                                               | 41 |
| Figura 21: Pontos fornecidos pelo ASM .....                                                                                                                                                                                                                                                            | 42 |
| Figura 22: Segmento que une os dois olhos .....                                                                                                                                                                                                                                                        | 42 |
| Figura 23: Histograma da distância dos olhos.....                                                                                                                                                                                                                                                      | 43 |
| Figura 24: Recortes. A) Imagem original. B) Recorte 1. C) Recorte 2. D) Recorte 3. ..                                                                                                                                                                                                                  | 44 |
| Figura 25: Resultado dos métodos de normalização de iluminação nas imagens originais. A) Imagem original; B) Equalização de histograma; C) Equalização de histograma local; D) Filtro logarítmico; E) LogAbout; F) Retinex; G) Retinex seguido do filtro de expansão de histograma.....                | 45 |
| Figura 26: Resultado dos métodos de normalização de iluminação nas imagens resultantes do Recorte 1. A) Imagem original; B) Equalização de histograma; C) Equalização de histograma local; D) Filtro logarítmico; E) LogAbout; F) Retinex; G) Retinex seguido do filtro de expansão de histograma..... | 46 |

|                                                                                                                                                                                                                                                                                                             |    |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 27: Resultado dos métodos de normalização de iluminação sobre as imagens resultantes do Recorte 2. A) Imagem original; B) Equalização de histograma; C) Equalização de histograma local; D) Filtro logarítmico; E) LogAbout; F) Retinex; G) Retinex seguido do filtro de expansão de histograma..... | 47 |
| Figura 28: Resultado dos métodos de normalização de iluminação sobre as imagens resultantes do Recorte 3. A) Imagem Original; B) Equalização de histograma; C) Equalização de histograma local; D) Filtro logarítmico; E) LogAbout; F) Retinex; G) Retinex seguido do filtro de expansão de histograma..... | 48 |
| Figura 29: Gráfico FRR x FAR do YALEA normalizado .....                                                                                                                                                                                                                                                     | 49 |
| Figura 30: Estudo da precisão do ASM.....                                                                                                                                                                                                                                                                   | 57 |

## LISTA DE TABELAS

|                                                                                                                                                                                        |    |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Tabela 1: Taxa de EER de cada técnica de normalização para o classificador baseado em DCT .....                                                                                        | 50 |
| Tabela 2: Taxa de EER de cada técnica de normalização para o classificador baseado em LBP .....                                                                                        | 51 |
| Tabela 3: Taxa de acerto para o reconhecimento com leave-one-out para o classificador baseado em DCT .....                                                                             | 52 |
| Tabela 4: Taxas de acerto para o reconhecimento com um elemento de treinamento, utilizando o classificador baseado em DCT .....                                                        | 53 |
| Tabela 5: Taxa de acerto para o reconhecimento com leave-one-out e o classificador baseado em LBP .....                                                                                | 54 |
| Tabela 6: Taxas de acerto para o reconhecimento com um elemento de treinamento, utilizando o classificador baseado em LBP.....                                                         | 55 |
| Tabela 7: Taxas de EER dos métodos LBP e DCT com os olhos detectados manualmente e através do ASM.....                                                                                 | 58 |
| Tabela 8: Taxas de acerto para o reconhecimento com leave-one-out, utilizando os classificadores baseados em LBP e DCT com detecção dos olhos manual e através do ASM .....            | 60 |
| Tabela 9: Taxas de acerto para o reconhecimento com uma imagem de treinamento, utilizando os classificadores baseados em LBP e DCT com detecção dos olhos manual e através do ASM..... | 61 |

## LISTA DE EQUAÇÕES

|                                             |    |
|---------------------------------------------|----|
| Equação do FRR.....                         | 23 |
| Equação FAR.....                            | 23 |
| Equação da equalização de histograma .....  | 24 |
| Equação de Expansão de histograma.....      | 25 |
| Função Logarítmica.....                     | 26 |
| Equação do Multi-Scale Retinex .....        | 27 |
| Função local do Multi-Scale Retinex .....   | 27 |
| Equação do LBP .....                        | 29 |
| Função de <i>thresholding</i> do LBP .....  | 29 |
| Transformada cosseno discreta.....          | 31 |
| Transformada cosseno discreta inversa ..... | 31 |
| Equação do fator de escala .....            | 43 |

## LISTA DE SIGLAS

|        |                                                       |
|--------|-------------------------------------------------------|
| AAM    | <i>Active Appearance Model</i>                        |
| API    | <i>Application Programming Interface</i>              |
| ASM    | <i>Active Shape Model</i>                             |
| BMP    | <i>Bitmap Image File</i>                              |
| CDF    | <i>Cumulative Distribution Function</i>               |
| CT-LBP | <i>Local Binary Patterns with Circle Threshold</i>    |
| EBGM   | <i>Elastic Bunch Graph Matching</i>                   |
| EER    | <i>Equal Error Rate</i>                               |
| FAR    | <i>False Acceptance Rate</i>                          |
| FN     | <i>False Negative</i>                                 |
| FP     | <i>False Positive</i>                                 |
| FRR    | <i>False Rejection Rate</i>                           |
| DCT    | <i>Transformada Cosseno Discreta</i>                  |
| JPEG   | <i>Joint Photographic Experts Group</i>               |
| LBP    | <i>Local Binary Patterns</i>                          |
| LVQ    | <i>Learning Vector Quantisation</i>                   |
| MSR    | <i>Multi-Scale Retinex</i>                            |
| OpenCV | <i>Open Computer Vision Library</i>                   |
| ORL    | <i>Olivetti Research Lab</i>                          |
| PCA    | <i>Principal Component Analysis</i>                   |
| PGM    | <i>Portable Gray Map Image</i>                        |
| PDI    | <i>Processamento Digital de Imagem</i>                |
| PNG    | <i>Portable Network Graphics</i>                      |
| SDRF   | <i>Sistema para Detecção e Reconhecimento de Face</i> |
| SQI    | <i>Self Quotient Image</i>                            |
| TN     | <i>True Negative</i>                                  |
| TP     | <i>True Positive</i>                                  |
| KNN    | <i>K-Nearest Neighbor</i>                             |

## SUMÁRIO

|        |                                                  |    |
|--------|--------------------------------------------------|----|
| 1.     | INTRODUÇÃO.....                                  | 11 |
| 1.1.   | Trabalhos Relacionados .....                     | 13 |
| 1.2.   | Objetivos .....                                  | 17 |
| 1.3.   | Estrutura da Dissertação.....                    | 17 |
| 2.     | FUNDAMENTAÇÃO TEÓRICA .....                      | 18 |
| 2.1.   | Imagens e Processamento Digital de Imagens ..... | 18 |
| 2.2.   | Biometria.....                                   | 19 |
| 2.3.   | Detecção e Reconhecimento de Faces .....         | 20 |
| 2.3.1. | Métricas de Avaliação .....                      | 22 |
| 2.4.   | Active Shape Model .....                         | 23 |
| 2.5.   | Normalização da Face .....                       | 24 |
| 2.5.1. | Equalização de Histograma .....                  | 24 |
| 2.5.2. | Expansão de Histograma .....                     | 25 |
| 2.5.3. | Função Logarítmica.....                          | 26 |
| 2.5.4. | <i>LogAbout</i> .....                            | 26 |
| 2.5.5. | <i>Multi-Scale Retinex</i> .....                 | 27 |
| 2.6.   | <i>Local Binary Pattern</i> .....                | 28 |
| 2.7.   | Transformada Cosseno Discreta.....               | 30 |
| 2.8.   | <i>K Vizinhos Mais Próximos</i> .....            | 32 |
| 2.9.   | Validação Cruzada .....                          | 34 |
| 3.     | MATERIAIS .....                                  | 36 |
| 3.1.   | Open Computer Vision Library.....                | 36 |
| 3.2.   | Bancos de Faces .....                            | 36 |
| 3.2.1. | GTAV Face Database .....                         | 37 |
| 3.2.2. | <i>Yale Face Database A</i> .....                | 37 |
| 3.2.3. | <i>Extended Yale Face Database B</i> .....       | 38 |
| 3.2.4. | VSOFT .....                                      | 38 |
| 3.3.   | Classificadores .....                            | 39 |
| 4.     | PROCEDIMENTOS METODOLÓGICOS .....                | 41 |
| 4.1.   | Normalização Geométrica.....                     | 41 |
| 4.2.   | Normalização de Iluminação.....                  | 45 |
| 5.     | RESULTADOS E DISCUSSÃO .....                     | 49 |
| 5.1.   | Testes 1-para-1 .....                            | 49 |
| 5.2.   | Testes 1-para-N .....                            | 52 |
| 5.3.   | Avaliação do ASM.....                            | 56 |
| 5.4.   | Testes com Detecção Manual dos Olhos.....        | 57 |
| 6.     | CONCLUSÃO.....                                   | 64 |
|        | REFERÊNCIAS .....                                | 66 |

## 1. INTRODUÇÃO

A Visão Computacional<sup>1</sup> permite aos sistemas digitais extraírem informações de imagens. As informações extraídas podem ser utilizadas para diversos fins, entre eles está o reconhecimento de padrões complexos, como texturas, objetos, textos, padrões biométricos, entre outros [Jain, Hong e Pankanti, 2000]. Sistemas de reconhecimento biométricos que utilizam características humanas singulares, como impressões digitais, íris, voz e face, permitindo a diferenciação entre seres humanos [Zhao *et al.* 2003] [Maltoni *et al.*, 2003], são exemplos de sistemas que utilizam técnicas de Visão Computacional.

A proliferação de serviços que necessitam de autenticação gerou uma demanda por novos métodos para estabelecer a identidade dos usuários. Métodos tradicionais para estabelecer a identidade de um usuário incluem mecanismos baseados em conhecimento (por exemplo, senhas) e mecanismos baseados em *tokens* (por exemplo, cartões de identidade). Porém, tais mecanismos podem ser perdidos, roubados ou até manipulados com o objetivo de burlar sistemas. Neste contexto, a verificação e a identificação por biometria surgem como alternativas [Ross *et al.*, 2006].

A autenticação biométrica oferece um mecanismo mais confiável utilizando traços físicos (como a íris ou impressão digital) ou comportamentais (como o modo de escrever) que permitem identificar usuários baseados em suas características naturais. Assim, é possível estabelecer a identidade de um usuário com base em quem ele é ao invés do que ele possui ou do que ele lembra. Dentre os diversos traços biométricos físicos, o reconhecimento biométrico baseado na face é um dos menos intrusivos [Marinho, 2012].

A área de análise de faces pode ser dividida em diversas subáreas, como reconhecimento de face, detecção/localização de face, reconhecimento de expressões faciais, análise de poses, etc. [Zhao *et al.* 2003]. É importante diferenciar detecção e reconhecimento. O reconhecimento de face consiste em identificar um indivíduo por intermédio da análise de sua face, comparando-a com outras faces pré-rotuladas. A

---

<sup>1</sup> Visão Computacional está sendo utilizado nesse texto no sentido de análise de imagem. [Marques Filho e Vieira Neto, 1999]

detecção/localização de faces é a determinação da presença e posição espacial de cada face existente em uma imagem. A detecção/localização de face frequentemente é utilizada como uma etapa inicial para o reconhecimento [Omaia *et al.*, 2009].

O reconhecimento de faces possui um abrangente campo de utilização, podendo ser utilizado desde aplicações comerciais a aplicações voltadas à segurança. Na área comercial, por exemplo, o atendimento ao cliente pode ser personalizado, a partir do momento que suas preferências são conhecidas previamente, o que pode ser realizado por intermédio do reconhecimento automático do cliente realizado por um sistema biométrico ligado à câmera presente na entrada do estabelecimento. Há também uma grande variedade de aplicações voltadas para segurança, desde a autorização de acesso físico ou virtual até as mais sofisticadas aplicações de rastreamento de suspeitos. Uma relevante aplicação de segurança corresponde à autenticação em tempo real de portadores de documentos pessoais, como passaporte, carteira de identidade, carteira de motorista, cartão de crédito e outros. O reconhecimento de face também pode ser associado a outras aplicações, como interação homem-máquina, programas de treinamento e realidade virtual [Zhao *et al.*, 2003] [Omaia *et al.*, 2009].

Reconhecimento de faces pode ser abordado de duas formas: identificação e verificação [Abate *et al.*, 2007] [Jain, Hong e Pankanti, 2000]. Na identificação, a imagem face de uma pessoa é comparada a uma base de imagens de faces, tendo como objetivo determinar a pessoa representada na imagem da face investigada. Na verificação, a imagem da face investigada e seu suposto representante são previamente informados e o objetivo é verificar a informação declarada, comparando a face investigada com uma galeria de faces para confirmar que a mesma corresponde ao indivíduo declarado [Matos 2008].

O problema do reconhecimento facial não é trivial, pois existem muitos fatores que influenciam na detecção e no reconhecimento como: iluminação, posição da face na imagem, plano de fundo, expressões faciais, presença e variação da barba e do cabelo, tom da pele, utilização de acessórios como *piercings*, óculos, maquiagem, etc. [Zhao *et al.*, 2003] [Ruiz-Del-Solar, 2008] [Omaia *et al.*, 2009] Pela maior simplicidade, é mais comum encontrar na literatura sistemas de reconhecimento de face que exigem ambientes controlados.

Os métodos de reconhecimento de face se dividem em métodos holísticos, métodos não holísticos (também chamados de analíticos ou geométricos) e híbridos. Os métodos não holísticos utilizam como característica discriminatória entre os indivíduos



as dimensões dos elementos da face (boca, nariz, olhos, etc.) e as distâncias entre eles [Zhao, Chellappa, Phillips e Rosenfeld, 2003]. Os métodos holísticos são aqueles que analisam a face como um todo, normalmente gerando modelos de faces e realizando comparações entre esses modelos para efetuar o reconhecimento facial. Como exemplos temos métodos que utilizam Transformada Cosseno Discreta (*Discrete Cosine Transform* - DCT) [Khayam, 2003] [Omaia *et al.*, 2009] [Marinho, 2012] [Hafed e Levine, 2001], Análise de Componentes Principais (*Principal Component Analysis* - PCA) [Mendonça *et al.*, 2007] ou Padrões Binários Locais (*Local Binary Patterns* - LBP) [Huang *et.al.*, 2011] [Li *et al*, 2013]. Já os métodos híbridos são combinações entre métodos holísticos e não holísticos.

Alguns métodos de reconhecimento facial possuem taxas de acerto que se aproximam de 100% em ambientes controlados [Omaia, 2009] [Mendonça *et al.*, 2007] [Marinho 2012], mas possuem baixa performance em ambientes não controlados. Esses métodos devem ser investigados e adaptados para qualquer tipo de ambiente, se se pretende utilizá-los numa gama maior de aplicações.

Este trabalho apresenta um estudo sobre como métodos de normalização geométrica e de iluminação podem auxiliar na adaptação dos métodos de reconhecimento a ambientes não controlados. Foram avaliados seis tipos de normalização de iluminação diferentes, três tipos de recorte de face e duas técnicas de reconhecimento facial.

Neste trabalho são utilizados apenas métodos holísticos de reconhecimento facial, pois não foi encontrado nenhum algoritmo de código livre preciso o suficiente, no que diz respeito à detecção dos pontos fiduciais da face, para a implementação de um algoritmo não holístico. Apesar de não ter sido utilizado para a realização de reconhecimento, o algoritmo ASM foi utilizado para a detecção dos olhos e para a realização do recorte da estrutura da face.

## **1.1. Trabalhos Relacionados**

Nos parágrafos seguintes, são resumidamente descritos alguns trabalhos relacionados a esta pesquisa.

Hafed e Levine (2001) desenvolveram um sistema de reconhecimento facial holístico que utiliza a DCT. A imagem recebe um pré-processamento onde é

normalizada geometricamente (tamanho, rotação e posição) através da posição dos olhos (a detecção dos olhos é realizada de forma manual) e quanto à iluminação por intermédio do método descrito no trabalho de Hummel (1975). A partir da imagem normalizada é gerada a DCT, de onde são selecionados 49 coeficientes de uma região quadrada situada na região de mais baixa frequência do espectro, os quais são utilizados para o reconhecimento usando o classificador do vizinho mais próximo. Esse trabalho obteve uma taxa de acerto de 92,5% no banco de faces ORL (Olivetti Research Lab) [Samaria e Harter 1994], utilizando cinco imagens como treinamento e cinco imagens para testes.

Em seu trabalho, Matos *et al.*(2008) também utilizam DCT para realizar o reconhecimento facial e implementam um classificador de vizinho mais próximo que utiliza como medida de similaridade a distância de Minkowski de ordem um. A menor distância é utilizada para classificar uma face. Nesse trabalho, etapas prévias de normalização são dispensadas. Para testar o algoritmo foi utilizado o procedimento de validação cruzada *leave-one-out*, ou seja, todas as imagens, com exceção de uma, são utilizadas para treinamento. O método obteve uma taxa de acerto de 99,5% no banco ORL utilizando 36 coeficientes.

O Sistema para Detecção e Reconhecimento de Face (SDRF) descrito por Omaia *et al.* (2009), seleciona coeficientes de baixas frequências da DCT em uma região elíptica, sendo uma variação do trabalho de Matos *et al.* (2009). Bem como no trabalho de Matos *et al.* (2009), onde não há nenhuma normalização nas imagens. Utilizando o classificador *K*-vizinhos mais próximos (*K-Nearest Neighbor* - KNN) e o procedimento *leave-one-out*, o método obteve uma taxa de 99,75% de acerto no banco ORL.

Kar *et al.* (2006) desenvolveram uma técnica que utiliza a correlação nos níveis de cinza, PCA e DCT. O reconhecimento é realizado sequencialmente com cada uma das técnicas. Em um banco próprio de 109 imagens de 43 indivíduos o algoritmo consegue uma taxa de 89% de acerto.

Short *et al.*(2004) compararam cinco técnicas de normalização fotométricas (Retinex, PCA, filtro homomórfico, suavização isotrópica e anisotrópica) indicando que a equalização de histograma ajudou a aumentar as taxas de acerto em todos os casos.

Shermina (2011) utiliza a normalização das componentes da DCT para corrigir a variação de iluminação na imagem da face, e chega à conclusão que essa técnica pode melhorar a taxa acerto de qualquer sistema de reconhecimento de faces.

Mendonça *et al.* (2007) comparam três métodos de normalização de iluminação, filtro homomórfico, wavelet e LogAbout. Usando o um sistema de reconhecimento que utiliza PCA e rede neural Aprendizagem por Quantização Vetorial (*Learning Vector Quantisation* - LVQ) sobre o banco *Yale Face Database B*, todos os métodos conseguiram melhorar a taxa de acerto em relação aos testes realizados sem normalização fotométrica. Em seu trabalho, Levine *et al.* (2004) propuseram um método de normalização que combina Retinex com equalização de histograma, o qual obteve uma taxa de acerto de 99,84% sobre o banco *Yale Face Database B* usando o classificador Máquinas de Vetores de Suporte (*Support vector machine* - SVM).

No trabalho de Gao *et al.* (2009) a face é detectada utilizando o Modelos de Aparência Ativa (*Active Appearance Model* - AAM) e, a partir dessa informação, normaliza-se geometricamente as faces utilizando deformamento (*warping*) e realiza-se um recorte oval em seu entorno. Utilizando essa normalização com um sistema de reconhecimento que utiliza DCT e o classificador do vizinho mais próximo, a técnica apresenta uma melhoria na taxa de acerto do sistema. A melhoria após a normalização geométrica também é identificada por Chai *et al.* (2003).

A utilização do LBP para análise facial tem sido uma das aplicações de mais sucesso nos últimos anos. A representação facial pelo LBP tem sido explorada, de forma bem-sucedida, para diferentes tarefas, que incluem detecção de face, reconhecimento facial, análise de expressão facial, análise demográfica (gênero, raça, sexo, idade, etc.), classificação, etc. [Huang *et al.*, 2011].

Ahonen *et al* (2004) apresentam uma variação do LBP, desenvolvida exatamente para ser utilizada no problema de reconhecimento de face. Através dessa nova abordagem é utilizada tanto a informação da textura, quanto a informação espacial para representar a face. O reconhecimento é realizado através do algoritmo do vizinho mais próximo. O método foi testado nas imagens das faces completamente frontais do banco de faces FERET. As imagens são pré-processadas a partir da posição dos olhos, sendo recortadas com uma área elíptica para remover toda a informação não pertencente à face e então é aplicada a equalização de histograma. Os testes mostraram que o método desenvolvido no trabalho é superior ao PCA, Classificador Bayesiano e Combinação de Grafos em Grupos Elásticos (*Elastic Bunch Graph Matching* - EBGM).

Maturama *et al.* (2009) propõem um algoritmo que lida com a variação de pose, variação de iluminação e com o desalinhamento da face nas imagens. O método utiliza um descritor baseado nos histogramas do LBP e realiza a classificação com Casamento

de Pirâmides Espaciais (*Spatial Pyramid Matching* - SPM). Em seus testes, demonstrou ser superior aos métodos que utilizam *fisherfaces* e *eigenfaces*.

Uma abordagem para o reconhecimento facial invariante a iluminação foi apresentada por Li *et al.* (2013). O trabalho consiste em dois passos: o pré-processamento da imagem aplicando o filtro de branqueamento no domínio logarítmico e a extração das características LBP das imagens filtradas. O LBP é aplicado nas regiões não sobrepostas da imagem e depois tem seus histogramas concatenados. No cálculo do LBP foram utilizados oito *pixels* vizinhos e um raio igual a um e a imagem foi dividida em regiões de tamanho 21x21. O método foi testado sobre as imagens de faces frontais presentes no banco Yale Face Database B, nesses testes o seu desempenho foi superior aos métodos baseados em DCT e *Self Quotient Image* (SQI).

Xu, Li e Xie (2013) para resolverem o problema de reconhecimento facial em condições de variação de iluminação, propuseram uma variação do LBP, o Padrões Binários Locais com Limiar Circular (*Local Binary Patterns with Circle Threshold* - CT-LBP). No trabalho foi utilizado o PCA para realizar a classificação. Para teste, foram utilizadas as imagens de faces frontais do banco *Yale Face Database B*. As imagens foram alinhadas manualmente e recortadas afim de manter apenas a informação da face, excluindo inclusive o contorno da face. O trabalho conseguiu uma taxa média de reconhecimento de 98%, se saindo melhor que os métodos que utilizam equalização de histograma, LBP básico e PCA puro.

## **1.2. Objetivos**

O objetivo deste trabalho é pesquisar e desenvolver técnicas de normalização geométrica e fotométrica sobre o reconhecimento facial em ambientes não controlados, visando adequar esses métodos para ambientes não controlados.

Os objetivos específicos deste trabalho são:

1. Pesquisar, desenvolver e avaliar métodos de normalização geométrica de imagens de face.
2. Pesquisar, desenvolver e avaliar o estado da arte em normalização de iluminação em sistemas de reconhecimento facial.
3. Pesquisar, desenvolver e avaliar métodos de delimitação da região de interesse para reconhecimento de face.
4. Avaliar a influência de cada método de normalização nas taxas de reconhecimento.
5. Pesquisar, desenvolver e avaliar métodos para identificação e autenticação utilizando normalização geométrica e de iluminação.

## **1.3. Estrutura da Dissertação**

No Capítulo 2 é feita uma revisão de literatura, onde são mostrados conceitos acerca de Processamento Digital de Imagens, Visão Computacional, Biometria e os algoritmos utilizados neste trabalho. No Capítulo 3 são descritos os materiais utilizados no trabalho. No Capítulo 4 é apresentado um detalhamento da metodologia empregada no desenvolvimento do trabalho desenvolvido e os testes utilizados. No Capítulo 5 são descritos os resultados obtidos, bem como a discussão sobre os mesmos. Por fim, no Capítulo 6 estão as conclusões acerca do trabalho, algumas considerações finais e elencados os trabalhos futuros.

## 2. FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta os conceitos teóricos necessários para o entendimento do trabalho.

### 2.1. Imagens e Processamento Digital de Imagens

Uma imagem monocromática é uma função  $f(x, y)$  onde  $x$  e  $y$  representam as suas coordenadas espaciais e o valor de  $f(x, y)$  representa um valor de intensidade luminosa, geralmente chamada nível de cinza. Para serem representadas no computador é necessário digitalizar as imagens. Para gerar uma imagem digital é feita uma amostragem (normalmente uniforme) de  $f(x, y)$  nas direções  $x$  e  $y$ , gerando uma matriz de  $N \times M$  amostras, seguida de uma quantização do valor de  $f(x, y)$  em  $L$  níveis inteiros de cinza. Nesta matriz, cada elemento  $p(x, y)$ ,  $x = 0, 1, \dots, M-1$  e  $y = 0, 1, \dots, N-1$ , é chamado *pixel* (i.e. uma abreviação de *picture elements*). Dizemos então que a imagem tem dimensão  $M$  *pixels* na horizontal (eixo  $x$ ) e  $N$  *pixels* na vertical (eixo  $y$ ). O resultado de tais processos é uma imagem digital monocromática, representada da seguinte forma:


$$\begin{pmatrix} f(0,0) & \cdots & f(0,C-1) \\ \vdots & \ddots & \vdots \\ f(L-1,0) & \cdots & f(L-1,C-1) \end{pmatrix}$$

Os valores  $L$  e  $C$  representam, respectivamente, o número máximo de linhas e colunas da imagem digitalizada, e são determinados no processo de digitalização. Cada elemento da matriz  $f(i, j)$  é conhecido como *pixel*, e, como dito, representa o valor do nível de cinza naquele ponto. O número total de níveis de cinza  $N$  também é determinado no processo de digitalização. O menor valor é zero, e representa o preto, enquanto o maior valor,  $N - 1$ , representa o branco.

O Processamento Digital de Imagens (PDI) é o campo da Ciência da Computação que se dedica ao processamento de imagens digitais em um computador [Gonzales *et al*, 2004]. Em síntese, pode-se dizer que o PDI consiste em qualquer forma de processamento de dados na qual a entrada e saída são imagens tais como fotografias ou quadros de vídeo. Ao contrário do tratamento de imagens, que preocupa-se somente com a manipulação de figuras para sua representação final, o PDI é um estágio para

novos processamentos de dados tais como aprendizagem de máquina ou reconhecimento de padrões.

O Processamento Digital de Imagens é altamente multidisciplinar, e tem relações muito próximas com as áreas de Computação Gráfica e Visão Computacional, como mostra a Figura 1. Muitas vezes um sistema de PDI exerce tarefas dessas duas áreas ao mesmo tempo. Outros exemplos de áreas ligadas ao PDI são Inteligência Artificial, Animação, Reconhecimento de Padrões e a Indústria do Entretenimento.



**Figura 1: Processamento digital e imagens e áreas correlatas. Fonte: Batista, 2005.**

## 2.2. Biometria

O termo Biometria refere-se ao uso de características físicas ou comportamentais, tais como face, íris, impressão digital, voz e *keystroke* (forma de digitar), para identificar pessoas automaticamente. Uma vez que os identificadores biométricos não podem ser facilmente extraviados, forjados, ou compartilhados, métodos de identificação biométricos são considerados mais confiáveis do que métodos baseados em *tokens* (como *smartcards*) ou senhas [Maltoni, Maio, Jain e Prabhakar, 2009]. Assim, os sistemas de reconhecimento biométrico estão sendo cada vez mais implantados em um grande número de aplicações governamentais e civis.

O reconhecimento do usuário em sistemas biométricos pode ser abordado de duas maneiras: verificação ou identificação. A verificação é uma abordagem dita 1-para-1 (um para um), pois neste caso é feita apenas a comparação entre um dado biométrico apresentado pelo usuário e uma referência previamente definida por outro elemento. A verificação exige menos processamento e é mais utilizada em aplicações que atrelam a informação de uma característica biométrica ao uso de *logins* por parte do usuário [Alves, 2007].

A identificação é uma abordagem dita 1-para-N (um para muitos), pois neste caso é feita a comparação entre um dado biométrico apresentado por um indivíduo e vários outros dados biométricos armazenados. A comparação pode ser feita com todos os dados armazenados, e posteriormente ser escolhido o dado mais semelhante ao apresentado inicialmente, levando-se em consideração uma margem de erro. Este é um processo que exige mais processamento e que é mais complexo que a verificação [Alves, 2007].

De acordo com Jafri (2009) a identificação por face supera os demais métodos à medida que não é necessária a cooperação e participação dos indivíduos na coleta de dados, por exemplo. O reconhecimento por voz está sujeito a ruído sonoro presente em toda parte. Quando é usada como referência a impressão da mão ou dos dedos é necessário fazer a leitura da mão num *hardware* dedicado, o que depende de proximidade, o compartilhamento de dispositivo, que possibilita a transmissão de germes. Já a “leitura” dos dados faciais pode ser feita à distância por câmera fotográfica, o que elimina a necessidade de proximidade e colaboração do sujeito, sendo totalmente não intrusiva. Isto é particularmente de grande benefício em sistemas de segurança. Além de proximidade e colaboração não serem empecilho, a coleta de dados pode ser realizada através de uma simples *webcam*, o que dispensa os altos gastos com *hardware* específico usado em outros sistemas biométricos, como os baseados em retina e íris, por exemplo.

### **2.3. Detecção e Reconhecimento de Faces**


Detecção e reconhecimento de faces são dois conceitos distintos, sendo importante diferenciá-los. O conceito de detecção de faces também pode ser compreendido como localização de faces e está ligado à determinação da presença e posição espacial de cada face existente em uma imagem [Omaia, 2009]. Geralmente



esta etapa é utilizada como a etapa que antecede o reconhecimento. O reconhecimento de faces consiste no processo de identificar um indivíduo analisando sua face e comparando-a com outras faces pré-rotuladas.

O processo de reconhecimento de faces pode ser abordado de duas maneiras: identificação e verificação [Abate *et al.*, 2007]. Na identificação, a face de uma pessoa é comparada a uma galeria de faces tendo como objetivo determinar a pessoa proprietária da face investigada. Na verificação, a face investigada e seu suposto proprietário são previamente informados e o objetivo é certificar a informação declarada, comparando a face investigada com uma galeria de faces para confirmar que a mesma corresponde ao proprietário declarado [OMAIA, 2009].

Conforme apresentado na introdução desta dissertação, os sistemas de reconhecimento de faces podem ser classificados em dois grupos: holísticos e não holísticos. Estes podem ser diferenciados na Figura 2.



**Figura 2: Ilustração dos métodos de reconhecimento de faces. (a) Método holístico (PCA); (b) Método não-holístico. Fonte: Adaptado de Xu, Z.; Lu L. and Shi P., 2008**

Os métodos baseados na aparência utilizam as características holísticas e são aplicados ou na face inteira ou em regiões específicas. Alguns métodos bastante utilizados são os baseados em PCA [Mendonça *et al.*, 2007], LBP [Huang *et al.*, 2011] [Ahonen *et al.*, 2004] e DCT [Omaia, 2009].

A maioria dos métodos baseados em características usa o comprimento da cabeça, a distância entre os olhos e dos olhos com a boca, etc., ou as distâncias e ângulos entre os cantos dos olhos, os extremos da boca, nariz, etc. [Zhao, Chellappa, Phillips e Rosenfeld, 2003] no processo de reconhecimento.

Geralmente, o fluxo para a resolução do problema de reconhecimento de faces envolve a detecção da face na imagem a partir de uma cena que pode conter várias pessoas (Detecção), o processamento da imagem (Normalização de iluminação, Recorte, normalização de escala, etc.) e a autenticação (reconhecimento). A Figura 3 ilustra este processo.




Figura 3: Processos de sistema de reconhecimento de face.

### 2.3.1. Métricas de Avaliação

Para avaliar a abordagem um-para-um, que avalia o desempenho do método em relação à verificação, é necessário a escolha de um limiar e a cada comparação entre duas faces é gerado um valor, caso este valor seja menor que o limiar as faces são consideradas pertencentes a um mesmo indivíduo, caso contrário, as faces são consideradas de indivíduos distintos. Variando o limiar escolhido previamente podem ser geradas curvas que representam a Taxa de Falsa Rejeição (*False Rejection Rate* - FRR), a qual indica a taxa de amostras rejeitadas que deveriam ser aceitas que é definida pela equação 1, e a Taxa de Falsa Aceitação (*False Acceptance Rate* - FAR), a qual indica a taxa de amostras aceitas que deveriam ser rejeitadas que é definida pela equação 2. O ponto de encontro entre essas curvas (como é mostrado na Figura 4) é denominado de Taxa de Erro Igual (*Equal Error Rate* - EER) e é comumente utilizada para avaliar os métodos.

$$FRR = \frac{FN}{(TP + FN)} \quad (1)$$

$$FAR = \frac{FP}{(TN + FP)} \quad (2)$$




Figura 4: Ilustração das curvas FAR e FRR e do ponto EER

## 2.4. *Active Shape Model*

O Modelo Ativo de Forma (*Active Shape Model* - ASM) é um modelo estatístico da forma de objetos que se deforma iterativamente para satisfazer a um exemplo do objeto em uma nova imagem. As deformações são limitadas por um conjunto de treinamento de exemplos rotulados, sendo essa uma de suas vantagens com relação a outros métodos. A forma do objeto é representada por um conjunto de pontos [Cootes 1995]. O ASM pode ser utilizado para detectar a face em uma imagem, fornecendo as posições de pontos específicos da face (Figura 5).



**Figura 5: Resultado da detecção de face realizada pelo ASM**

## 2.5. Normalização da Face

Em um processo de reconhecimento, as imagens geralmente passam por um processo de normalização logo após a detecção. Este processo pode ser dividido em normalização geométrica e normalização de iluminação (fotométrica). O processo de normalização geométrica consiste em alinhar a altura dos olhos, igualar a escala das faces e corrigir a posição das faces com relação à imagem. O processo de normalização de iluminação consiste em melhorar as condições da imagem de modo que ruídos, sombras e variações de contraste ou de brilho não afetem o processo de reconhecimento.

### 2.5.1. Equalização de Histograma

O objetivo da Equalização de Histograma é redistribuir os valores de tons de cinza dos *pixels* em uma imagem, de modo a obter um histograma mais uniforme. Para obter este resultado, utiliza-se uma função auxiliar denominada função de transformação. A forma mais comum de se equalizar um histograma é utilizar a Função de Distribuição Acumulada (*Cumulative Distribution Function* - CDF) da distribuição de probabilidades que pode ser expressa por [Marques e Vieira, 1999]:

$$S_k = T(r_k) = \sum_{j=0}^k \frac{n_j}{n} = \sum_{j=0}^k P_r(r_j) \quad (3)$$

Onde:

$n$  é o número total de *pixels* na imagem,

$$0 < r_k < 1$$

$K = 0, 1, \dots, L-1$ , onde  $L$  é o número de níveis de cinza da imagem digitalizada,

$P_r(r_j)$  é a probabilidade do  $j$ -ésimo nível de cinza.



**Figura 6: Resultado do filtro de equalização de histograma. a) imagem original b) imagem equalizada**

### 2.5.2. Expansão de Histograma

Operação que consiste em alterar o histograma de maneira a repartir da melhor forma as intensidades na escala dos valores disponíveis. Isto equivale a estender o histograma para que o valor de menor intensidade seja levado para zero e que o de maior intensidade seja levado para o valor máximo [Gomes, 2001]. Esta operação aumenta o contraste da imagem para que os níveis de cinza ocupem toda a faixa de valores disponíveis.

$$s = T(r) = \text{round} \left( \frac{r - r_{\min}}{r_{\max} - r_{\min}} (L - 1) \right) \quad (4)$$

Sendo:

$r_{\min}$  o menor nível de cinza presente na imagem de entrada

$r_{\max}$  o maior nível de cinza presente na imagem de entrada

$L$  é o limite superior da escala de cinza

*round* significa arredondamento para o inteiro mais próximo

### 2.5.3. Função Logarítmica

A função logarítmica pode estender os níveis de cinza mais baixos e comprimir os níveis de cinza mais altos, o que pode melhorar a iluminação deficiente na sua essência. É muito útil para sombras e imagens não uniformes [LIU *et al.*, 2002], como mostrado na Figura 8.

A Equação **Erro! Fonte de referência não encontrada.** define a função logarítmica utilizada em [LIU *et al.*, 2002].

$$g(x, y) = a + \frac{\ln(f(x, y) + 1)}{b \ln c} \quad (5)$$

Sendo:

$f(x, y)$  a imagem de entrada

$g(x, y)$  a imagem de saída

$a$  constante igual a 10

$b$  constante igual a 0,017

$c$  constante igual a 10

### 2.5.4. LogAbout

O método *LogAbout* foi proposto por Liu *et al.* (2002) com o objetivo de tentar resolver problemas de compensação de iluminação em detecção de faces. Este método consiste na aplicação de um filtro passa-alta na imagem original, seguida da função logarítmica da Equação **Erro! Fonte de referência não encontrada.**, como ilustrado na Figura 7.




Figura 7: Método LogAbout. Adaptado de [Liu *et al.*, 2002]

O filtro passa-alta é definido pela seguinte máscara de convolução:

$$A = \begin{pmatrix} -1 & -1 & -1 \\ -1 & 9 & -1 \\ -1 & -1 & -1 \end{pmatrix}$$

Os resultados obtidos por Liu et al. (2002) são ilustrados na Figura 8 e demonstram que o método *LogAbout* pode compensar a iluminação eficientemente até em imagens com fundos complexos [Mendonça, 2007].



Figura 8: Normalização com o método LogAbout. (1) Imagem Original (2) Imagem resultante do Log (3) Imagem Resultante do LogAbout. [LIU et. al., 2002]

#### 2.5.5. Multi-Scale Retinex

Algoritmo de melhoria de imagem que é usado para melhorar o contraste, brilho e nitidez de uma imagem essencialmente através da compressão da variação dinâmica. Consegue remover os efeitos causados por diferentes fontes de iluminação na cena, [Hines et al. 2004] como pode ser visto na Figura 9.

A forma básica do *Multi-Scale Retinex* (MSR) é dada por:

$$R_i(x_1, x_2) = \sum_{k=1}^k W_k (\log I_i(x_1, x_2) - \log [F_k(x_1, x_2) * I_i(x_1, x_2)]) \quad i = 1, \dots, N \quad (6)$$

Em que o índice  $i$  representa a  $i$ -ésima banda espectral,  $N$  é o número de bandas espectrais ( $N=1$  para imagens monocromáticas e  $N=3$  para imagens coloridas típicas),  $I$  é a imagem,  $R$  é o resultado do MSR,  $F_k$  representa a  $k$ -ésima função local,  $W_k$  são os pesos associados com  $F_k$ ,  $K$  é número de funções locais, ou escalas, e  $*$  é o operador de convolução. As funções  $F_k$  são dadas por:

$$F_k(x_1, x_2) = k \exp\left[-\frac{(x_1^2 + x_2^2)}{\sigma_k^2}\right] \quad (7)$$

Em que  $\sigma_k$  são as escalas que a extensão do função local. [Zia-ur R. *et al.*, 2004].



Figura 9: Resultado da aplicação do MSR [Zia-ur R. *et al.*, 2004]

## 2.6. *Local Binary Pattern*

Assumindo que uma textura é formada por padrões locais, Ojala, Pietikäinen e Harwood (1996) introduziram o operador Padrão Binário Local (*Local Binary Pattern* - LBP). O LBP é definido como uma medida de textura invariante a escala de cinza, derivado de uma definição geral de textura em uma vizinhança local. É um poderoso meio de descrição de textura, tendo como propriedades em aplicações do mundo real o seu poder de discriminação, simplicidade computacional e tolerância contra mudanças em escala de cinza monotônicas [Ylioinas, Hadid e Pietikäinen 2011].

A proposta original do LBP baseia-se no deslocamento de uma janela 3×3 na imagem. Para cada um dos oito *pixels* vizinhos, é aplicada uma limiarização (função que retorna 1 se o *pixel* tiver intensidade maior ou igual ao limiar, ou 0, caso contrário) com relação ao *pixel* central, binarizando a imagem.



Depois, estes valores binários são concatenados formando um dentre  $2^8 = 256$  possíveis resultados (Figura 10). O histograma desses 256 valores pode ser usado como descritor de textura.




Figura 10: Operador LBP básico [Ahonen *et al*, 2004]

Anos depois, o LBP foi estendido para ser utilizado com vizinhanças de tamanhos diferentes. Para isso, é utilizada a vizinhança circular e a interpolação bilinear dos valores não inteiros das coordenadas dos *pixels*. A generalização do LBP se dá através da notação  $LBP_{P,R}$ , representando uma vizinhança de  $P$  pontos igualmente espaçados e com distância  $R$  do centro. A Figura 11 exemplifica como a vizinhança é determinada para certos parâmetros.




Figura 11: Operador LBP com vizinhanças (8, 1), (16, 2) e (8, 2) [Ahonen *et al*, 2004]

O valor do código do LBP para o *pixel*  $(x_c, y_c)$  é dado por:

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (8)$$

Onde  $g_c$  corresponde ao nível de cinza do *pixel*  $(x_c, y_c)$ ,  $g_p$  se refere ao nível de cinza de  $P$  *pixels* igualmente espaçados num círculo de raio  $R$ , e  $s$  define uma função de limiarização igual a:

$$s(x) = \begin{cases} 1, & \text{se } x \geq 0 \\ 0, & \text{caso contrário} \end{cases} \quad (9)$$

Em [Ahonen *et al*, 2004], os autores propuseram uma variação para o LBP. Pensando no problema de reconhecimento facial, possuir informação espacial da face é desejável. Com esse propósito, eles dividiram a imagem em regiões e são gerados os histogramas de cada região individualmente. O próximo passo é concatenar todos os histogramas gerados na imagem. Dessa maneira, incorpora-se a informação local da imagem ao LBP tradicional.

Com a divisão da imagem em regiões é esperado que algumas regiões possuam mais informações úteis do que outras para a classificação. Por exemplo, olhos são uma informação muito importante para o reconhecimento. Para tirar vantagem disso, pesos podem ser atribuídos a cada região, com base na importância que a informação presente em cada região possui.

## 2.7. Transformada Cosseno Discreta

As transformadas geram um conjunto de coeficientes a partir dos quais é possível restaurar as amostras originais do sinal. Em muitas situações é conveniente aplicar uma operação matemática genericamente denominada de transformada sobre um sinal a ser processado, convertendo-o para outro domínio (comumente o da frequência), efetuar o processamento do sinal neste domínio e, finalmente, converter o sinal processado de volta ao domínio original.

Existem diversas transformadas na literatura e a escolha entre elas depende da natureza do problema. A Transformada Cosseno Discreta é uma das transformadas capazes de converter um sinal do domínio do espaço para o domínio da frequência. Assim como outras transformadas, a DCT tenta descorrelacionar dados. Ela parte da ideia de que qualquer sinal discreto  $x[n]$  pode ser decomposto em um somatório de  $n$  funções cosseno, cada função cosseno com sua amplitude, frequência e fase. A DCT, então, transforma um sinal discreto  $x$  em um conjunto de coeficientes  $X$  em que cada coeficiente  $X[k]$  expressa a importância de uma onda cosseno para a formação do sinal original [Khayam, 2003].

Seja  $f[m, n]$  um sinal discreto dado, a transformação para o domínio da frequência pela DCT-2D produz uma sequência,  $F[k, l]$ , dada pela Equação **Erro! Fonte de referência não encontrada.**).

$$F[k, l] = c_k c_l \sum_{m=0}^{L-1} \sum_{n=0}^{C-1} f[m, n] \cos \frac{(2m+1)k\pi}{2L} \cos \frac{(2n+1)l\pi}{2C} \quad (10)$$

Sendo:

$L$  o número de linhas da imagem.

$C$  o número de colunas da imagem.

$$0 \leq k \leq L-1$$

$$0 \leq l \leq C-1$$

$$C_k = \begin{cases} \frac{1}{\sqrt{L}}, & \text{se } k = 0 \\ \sqrt{2/L}, & \text{se } 1 \leq k \leq L-1 \end{cases}$$

$$c_l = \begin{cases} \frac{1}{\sqrt{C}}, & \text{se } l = 0 \\ \sqrt{2/C}, & \text{se } 1 \leq l \leq C-1 \end{cases}$$

O sinal original  $f[m, n]$  pode ser obtido a partir da transformação inversa IDCT, dada pela Equação **Erro! Fonte de referência não encontrada.**):

$$f[m, n] = c_m c_l \sum_{k=0}^{L-1} \sum_{l=0}^{C-1} F[k, l] \cos \frac{(2k+1)m\pi}{2L} \cos \frac{(2l+1)n\pi}{2C} \quad (11)$$

Sendo:

$L$  o número de linhas da imagem.

$C$  o número de colunas da imagem.

$$0 \leq i \leq L-1$$

$$0 \leq n \leq C-1$$

$$c_m = \begin{cases} \frac{1}{\sqrt{L}}, & \text{se } m = 0 \\ \sqrt{2/L}, & \text{se } 1 \leq m \leq L-1 \end{cases}$$

$$c_n = \begin{cases} \frac{1}{\sqrt{C}}, & \text{se } n = 0 \\ \sqrt{2/C}, & \text{se } 1 \leq n \leq C-1 \end{cases}$$

Os coeficientes mais próximos da origem gerados pela DCT-2D referem-se às frequências mais baixas do sinal, que representam as características gerais, normalmente as mais representativas do sinal original. Os últimos coeficientes referem-se às frequências mais altas do sinal, que geralmente representam os detalhes, as bordas ou o ruído presente no sinal. Assim, se o nível de cinza de uma imagem muda vagarosamente ao longo de suas colunas, então essa imagem seria representada no domínio DCT como uma imagem contendo predominantemente cossenos de baixas frequências, como mostrado na Figura 12.



**Figura 12: Mudança abrupta de nível de cinza. (a) Imagem original (b)DCT [Omaia, 2009]**

Algo que muda de nível de cinza abruptamente, como uma borda, será representado por cossenos de alta frequência, como mostrado na Figura 12 [Khayam, 2003].



**Figura 13: Mudança suave de níveis de cinza. (a) Imagem original (b) DCT [Omaia, 2009]**

## 2.8. *K* Vizinhos Mais Próximos


É um dos mais simples de todos os algoritmos de aprendizado de máquina. Baseado na analogia, um objeto é classificado pelo voto da maioria de seus vizinhos.

Este processo de classificação pode ser computacionalmente exaustivo se considerado um conjunto com muitos dados. Por isso, a grande desvantagem é o tempo de computação para a obtenção dos  $k$  vizinhos mais próximos. O KNN possui apenas um parâmetro livre (o número de  $k$  vizinhos) que é controlado pelo usuário com o objetivo de obter uma melhor classificação. O melhor valor de  $k$  pode ser determinado experimentalmente [Bedê *et al.*, 2010].

Basicamente, uma base de dados de treinamento composta por um conjunto de tuplas  $\{a_1, \dots, a_n, c_l\}$ , onde  $c_l$  é a classe à qual pertencem as tuplas  $\{a_1, \dots, a_n\}$ , é usada para classificar um novo caso  $c_0$  (representado como  $c_0 = (a_1(c_0), \dots, a_n(c_0))$ .) A classificação é realizada da seguinte maneira [Theodoridis e Koutroumbas 2006]:

- Inicialmente estabelece-se um valor para  $k$  (geralmente se determina um valor ímpar para  $k$ , de forma que este valor não seja múltiplo do número total de classes);
- Calculam-se as distâncias  $x$  do caso  $c_0$  às tuplas de treinamento;
- Identifica-se os  $k$  vizinhos mais próximos, independentemente do rótulo de classe;
- Dentro das  $k$ -tuplas identificadas, identificar o número de tuplas que pertencem a cada classe;
- Classifica-se o caso  $c_0$  associando-se a ele a classe mais frequente, ou seja, a classe que a maioria das  $k$ -tuplas pertence;

O problema se resume então à definição de um valor para  $k$  e de como é calculada a distância  $x$ . As métricas mais comuns no cálculo de distância entre as tuplas são a distância Euclidiana (mais usada), a distância de Manhattan e a distância de Minkowski. A Figura 14 ilustra o funcionamento do algoritmo.



**Figura 14: Demonstração gráfica de como o algoritmo knn funciona ( $k=5$ ).**

O método do vizinho mais próximo pode ser visto como um caso especial do KNN, onde o  $k = 1$ .


## 2.9. Validação Cruzada

Para validar um classificador deve-se testar a sua eficácia. A validação cruzada é uma técnica muito utilizada para isso quando há um número reduzido de amostras para treinamento e testes. Para tal, o banco de dados utilizado é dividido em dois grupos disjuntos, um para treinamento e outro para testes de classificação. Várias rodadas de classificação são realizadas com diferentes divisões dos grupos, a fim de se obter um resultado médio [Omaia 2009].

Um caso especial da Validação Cruzada é a técnica do deixe-um-de-fora (*leave-one-out*). Como o próprio nome sugere, essa técnica deixa uma amostra de cada classe fora do conjunto de treinamento. Esta será a amostra de teste ou de classificação, e o treinamento é realizado com as demais. O processo é repetido  $N$  vezes, onde  $N$  é a quantidade de amostras no banco de dados, até que todas as amostras do banco tenham ficado de fora do treinamento. A média dos resultados de classificação destas repetições será o resultado final [Omaia 2009].

A Figura 15 ilustra a abordagem do deixe-um-de-fora, onde a cada rodada, um elemento (em cinza) é classificado, e os demais elementos (em branco) são utilizados no

treinamento. A cada rodada modifica-se o conjunto de treinamento e o elemento a ser classificado, até que todos os elementos tenham ficado uma vez de fora.



**Figura 15: Ilustração do deixe-um-de-fora**

### 3. MATERIAIS

Este capítulo descreve os recursos utilizados para o desenvolvimento deste trabalho.

#### 3.1. Open Computer Vision Library

A *Open Computer Vision Library* (OpenCV) é uma biblioteca multiplataforma para o desenvolvimento de aplicativos na área de visão computacional. Foi originalmente desenvolvida pela Intel, entretanto é totalmente livre ao uso acadêmico e comercial, desde que siga a licença BSD da Intel. A maior parte de suas funções é implementada em C/C++, porém há suporte a outras linguagens. Esta biblioteca possui módulos de processamento de imagens e vídeo, interface gráfica básica, controle de periféricos (mouse/teclado), além de diversos algoritmos de visão computacional, como segmentação de imagens, detecção de objetos, detecção de movimento e outros diversos filtros [Bradski e Kaehler, 2008].

Essa biblioteca é utilizada neste trabalho nos módulos de captura de vídeo, detecção de face, e no módulo de exibição.

#### 3.2. Bancos de Faces

Esta sessão descreve os bancos de imagens de faces utilizados para desenvolver o trabalho e para realização dos testes. Os bancos de imagens utilizados foram: *GTAV Face Database*, *Yale Face Database A*, *Extended Yale Face Database B* e *VSOFT*. Outros bancos de imagens citados na literatura não foram utilizados por já possuírem as faces recortadas ou normalizadas, ou por não possuírem a quantidade necessária de amostras por indivíduo para permitir os testes 1-para-N, como os bancos *ORL* [AT&T Laboratorie] e *LFW* [Huang *et al* 2007].



### 3.2.1. GTAV Face Database

Banco de imagens criado para testar a robustez dos algoritmos de reconhecimento de face com relação à variação da pose e da iluminação. É composto por 44 indivíduos e cada indivíduo possui 27 imagens. Dentre as imagens há variações de expressão facial e fotos com o indivíduo utilizando óculos [Tarrés e Rama]. As imagens que compõem esse banco são do tipo *bmp* e possuem dimensão igual a 320 x 240. Para o trabalho foram utilizadas apenas as imagens frontais disponíveis no banco, com exceção das imagens que os indivíduos escondiam a boca ou os olhos com as mãos. Exemplos de imagens são mostradas na Figura 16.



Figura 16: Amostras do Banco de Faces GTAV

### 3.2.2. Yale Face Database A

O Banco de Faces da Universidade de YALE. Possui imagens de 15 pessoas em 11 situações diferentes para representar cada pessoa, totalizando 165 imagens. As imagens possuem diferentes expressões faciais ou configurações como: diferentes centros de iluminação, óculos, expressão de felicidade, expressão de tristeza, expressão de sono, iluminação à esquerda, iluminação à direita, etc. As imagens já se encontram em tons de cinza, com dimensão igual a 320x243 e são do formato *bmp*, como é demonstrado na Figura 17.



Figura 17: Indivíduo 1 com suas 11 amostras

### 3.2.3. Extended Yale Face Database B

Possui 16128 imagens no formato *pgm*, de 28 indivíduos diferentes, sendo 9 posições diferentes sobre 64 formas de iluminação diferentes [Georghiades *et al.* 2001]. Foram selecionadas 10 imagens frontais de cada indivíduo ou com pouca inclinação e com alguma variação de iluminação para serem utilizadas nesse trabalho. As imagens selecionadas foram as das posições 01, 02, 03, 04 e 05, com a iluminação frontal e a imagem da posição 00 com iluminação frontal e com as variações de iluminação identificadas pelas seguintes nomenclaturas: A+005E+10, A+005E-10, A-005E+10 e A-005E-10. Através desta seleção, criou-se um banco de 256 imagens, todas com dimensão igual a 640x480, já em níveis de cinza. A Figura 18 apresenta algumas imagens deste banco.



Figura 18: Amostras do banco de Yale Face Database B

### 3.2.4. VSOFT

O banco de faces Vsoft-Faces [Marinho, 2012] possui seis imagens de cada um dos 14 indivíduos presentes no banco, totalizando 84 imagens com 250 *pixels* de altura e 250 *pixels* de largura. Nesse banco encontramos variação da posição da cabeça,

pequenas variações de iluminação e a presença de indivíduos utilizando óculos (Figura 19). Todas as imagens do banco estão no formato *jpg*.



**Figura 19: Exemplo de imagem do Banco VSOF**

### **3.3. Classificadores**

Neste trabalho foram utilizados dois classificadores holísticos para o reconhecimento de face, um baseado em DCT [Omaia, 2009] e outro baseado em LBP [Ahonen *et al.*, 2004].

Não foi possível realizar testes com classificadores baseados em geometria, pois o método utilizado para detecção dos pontos fiduciais da face (olhos, boca, nariz, sobrancelhas, etc.) não possui precisão suficiente para que seja possível utilizar essa informação para a distinção de dois indivíduos. Por esse motivo só foram utilizados métodos holísticos.

Outros métodos holísticos foram descartados por apresentarem características que inviabilizam sua utilização prática. Por exemplo, o classificador baseado em PCA precisa ser treinado novamente sempre que um novo elemento é adicionado ao sistema, impedindo que o mesmo seja utilizado durante esse processo. Outra característica que impediu a utilização de outros métodos é que eles possuem ótimas taxas de acerto em classificação fechada (informar a qual indivíduo do banco de treinamento a face de entrada pertence, sabendo previamente que a face pertence a alguém que esteja no banco), porém não conseguem informar se esta face pertence a alguém já cadastrado no sistema ou não. Ou seja, eles sempre informam o indivíduo mais semelhante.

O método de Omaia (2009) utiliza os coeficientes de baixa frequência da DCT como atributos para o reconhecimento. Essa região é definida por uma elipse, em que o centro está localizado no *pixel* de coordenada (0,0) da imagem. A elipse utilizada nesse trabalho possui um eixo horizontal de tamanho igual a nove, e um eixo vertical de tamanho igual a dez. Diferentemente do que foi apresentado em [Omaia 2009], que utilizava o KNN, foi utilizado o classificador Vizinho Mais Próximo para realizar a comparação entre as componentes das DCTs das duas faces que estão sendo analisadas. Essa modificação foi necessária porque o teste 1-para-1 só permite haver uma amostra de cada indivíduo no banco de treinamento, o que inviabiliza a utilização do KNN, e não seria interessante usar um classificador diferente para cada teste.

Dentre as variações de LBP que são utilizadas para classificação de textura, foi escolhida a apresentada no trabalho de Ahonem *et al.*(2004). Essa variação foi escolhida por ter sido pensada especificamente para o problema de reconhecimento facial, dessa maneira utilizando características espaciais para realizar o reconhecimento. Para realizar a comparação entre os histogramas gerados pelo LPB foi utilizado um método da biblioteca OpenCV específico para isso, o *compareHist*. Esse método oferece quatro métricas diferentes para realizar essa tarefa. A métrica utilizada neste trabalho foi a Correlação e os parâmetros utilizados para a geração do LBP foram quatro e um, *pixels* de vizinhança e raio, respectivamente.

## 4. PROCEDIMENTOS METODOLÓGICOS

Neste capítulo é descrito o desenvolvimento, fundamentado no referencial teórico, que se adotou para analisar o efeito das técnicas de normalização em sistemas de reconhecimento facial em ambientes não controlados. O trabalho consiste em desenvolver um pré-processamento que retire a variação geométrica, de iluminação e toda a informação não pertencente à face das imagens, para então serem classificadas. O pré-processamento consiste em uma normalização geométrica, seguida de um recorte e posteriormente, de uma normalização de iluminação. A Figura 20 apresenta a arquitetura do sistema de reconhecimento.




Figura 20: Arquitetura do sistema de reconhecimento

### 4.1. Normalização Geométrica

A normalização consiste na retirada da variação da posição, rotação e escala entre as imagens das faces. Todo processo proposto de normalização geométrica se baseia na posição dos olhos, por isso, uma detecção precisa é fundamental para os próximos passos.


Foram avaliados dois dos mais utilizados métodos de detecção de olhos da literatura: a detecção de olhos "em cascata" (*cascade*) do OpenCV e o ASM. Nos testes realizados, o ASM mostrou uma precisão melhor na detecção dos centros dos olhos. Por procurar regiões semelhantes aos modelos, ele consegue aproximar a localização dos olhos até quando estão oclusos, como nas imagens onde as pessoas estão usando óculos escuros. Além dos olhos, o ASM utilizado fornece 57 pontos (como demonstrado na

Figura 21), nos quais se encontram as posições da boca, das sobrancelhas, do nariz e contorno da face, sendo assim mais uma vantagem em relação ao método nativo do OpenCV.



**Figura 21: Pontos fornecidos pelo ASM**

Com as posições dos olhos, já é possível iniciar o processo da normalização geométrica. A normalização se inicia com o alinhamento dos olhos (normalização da rotação), que consiste na eliminação, se houver, da inclinação do segmento de reta que une os dois olhos (Figura 22). A partir das coordenadas dos dois olhos calcula-se a inclinação e então aplica a operação de rotação para alinhá-los.




**Figura 22: Segmento que une os dois olhos**

O passo seguinte é normalizar a escala. Esse processo é realizado com o objetivo de deixar todas as imagens com a mesma distância entre os olhos, e dessa maneira fazer com que todas fiquem com a mesma distância em relação à câmera. Essa operação é feita através do redimensionamento da imagem de acordo com um fator de escala, que é dado por:

$$fatorDeEscala = \frac{D_{padr\tilde{a}o}}{D_i} \quad (12)$$

Em que,  $D_{padr\tilde{a}o}$  é a distância padrão escolhida e  $D_i$  é a distância entre os olhos da face em questão.

Para realizar essa etapa é necessário escolher a distância padrão entre os olhos, para isso foi realizado um levantamento das distâncias entre os olhos de todas as imagens dos bancos utilizados. Este levantamento resultou em um histograma de distâncias de olhos (Figura 23). Através da análise do gráfico gerado, foi escolhida a distância de 48 *pixels*. Esse valor foi escolhido por ser maior que a distância encontrada em 75% das faces, e nesse caso é melhor reduzir as imagens do que adicionar dados espúrios aumentando-as por interpolação. Essa quantidade, 75%, foi escolhida arbitrariamente e a investigação desse valor pode melhorar os resultados alcançados neste trabalho.




**Figura 23: Histograma da distância dos olhos**

Na etapa de normalização geométrica também é interessante fazer o recorte da imagem para a retirada da informação que não pertence à face (cabelo, camisa, pescoço, *background*, etc.), dessa maneira, o classificador não sofrerá influência de tais

informações, tornando-se robusto quanto ao ambiente e às informações de algumas características irrelevantes, como o corte e o tingimento do cabelo. Nessa etapa também é realizada a padronização das dimensões da imagem, sendo esse um pré-requisito dos métodos holísticos utilizados no trabalho.

Foram realizados três tipos distintos de recorte a partir das imagens originais. O primeiro recorte gerou imagens de 127 *pixels* de largura por 147 *pixels* de altura, os olhos ficaram a 38 *pixels* da borda lateral mais próxima e a 49 *pixels* da borda superior da imagem. O segundo recorte consiste na retirada da informação não pertencente à face das imagens resultantes do primeiro recorte. Isso é feito utilizando os pontos fornecidos pelo ASM que correspondem ao contorno da face. Os pontos da imagem que não se encontram dentro da região delimitada por esses pontos são pintados de cinza. O terceiro recorte gera imagens com dimensões iguais a 88 x 100 *pixels*, com os olhos a uma distância de 20 *pixels* da borda lateral e superior mais próxima. Os resultados dos recortes podem ser vistos na Figura 24.



**Figura 24: Recortes. A) Imagem original. B) Recorte 1. C) Recorte 2. D) Recorte 3.**




Os Recortes 1 e 2 foram realizados em todos os bancos utilizados nesse trabalho, mas o Recorte 3 só foi utilizado em apenas um banco de imagens. O Recorte 3 só foi realizado em conjunto com a normalização geométrica que utilizou as coordenadas dos centros dos olhos marcadas manualmente, e o único banco de imagens que foi marcado através deste processo foi o *Yale Face Database A*.

## 4.2. Normalização de Iluminação


A normalização de iluminação, ou normalização fotométrica, visa retirar a variação de iluminação da imagem. Essa etapa é utilizada com o objetivo de tornar o sistema de reconhecimento robusto à variação de iluminação na cena.

Foram implementados e testados seis métodos de normalização de iluminação para face: equalização de histograma, equalização local de histograma, filtro logarítmico, LogAbout, Retinex e Retinex seguido de expansão de histograma. Esses algoritmos foram escolhidos por já terem sido utilizados na literatura e terem mostrado bons resultados [Short *et al.*, 2004] [Mendonça *et al.*, 2007].




**Figura 25: Resultado dos métodos de normalização de iluminação nas imagens originais. A) Imagem original; B) Equalização de histograma; C) Equalização de histograma local; D) Filtro logarítmico; E) LogAbout; F) Retinex; G) Retinex seguido do filtro de expansão de histograma**

Os métodos de normalização de iluminação foram aplicados tanto nas imagens originais quanto nas imagens resultantes da normalização geométrica, inclusive nas imagens resultantes dos três recortes apresentados anteriormente na Figura 24.




**Figura 26: Resultado dos métodos de normalização de iluminação nas imagens resultantes do Recorte 1. A) Imagem original; B) Equalização de histograma; C) Equalização de histograma local; D) Filtro logarítmico; E) LogAbout; F) Retinex; G) Retinex seguido do filtro de expansão de histograma**


As imagens A das figuras Figura 25, Figura 26, Figura 27 e Figura 28 estão sem nenhum filtro de normalização fotométrica, servindo para entender o efeito de cada método. As imagens B são resultantes da equalização de histograma, as imagens C são resultantes da equalização de histograma local, as imagens D são resultantes do filtro logarítmico, as imagens E são resultantes do filtro LogAbout, as imagens F são resultado do filtro Retinex e, finalmente, as imagens G foram obtidas através do Retinex e em seguida da aplicação do filtro de expansão de histograma.



**Figura 27: Resultado dos métodos de normalização de iluminação sobre as imagens resultantes do Recorte 2. A) Imagem original; B) Equalização de histograma; C) Equalização de histograma local; D) Filtro logarítmico; E) LogAbout; F) Retinex; G) Retinex seguido do filtro de expansão de histograma**

Os resultados apresentados na Figura 28, como já citado anteriormente, só foram gerados para o *Yale Face Database A*.





**Figura 28: Resultado dos métodos de normalização de iluminação sobre as imagens resultantes do Recorte 3. A) Imagem Original; B) Equalização de histograma; C) Equalização de histograma local; D) Filtro logarítmico; E) LogAbout; F) Retinex; G) Retinex seguido do filtro de expansão de histograma**

## 5. RESULTADOS E DISCUSSÃO

Para avaliar a eficiência dos métodos de normalização investigados nesse trabalho foram realizados testes com os bancos de faces originais individualmente e com a união deles. Isso foi feito para poder avaliar os métodos nas situações mais variadas possíveis. A união dos bancos só foi impossibilitada quando são utilizadas as imagens não normalizadas geometricamente, pois cada banco possui uma dimensão padrão diferente, o que impossibilita a utilização dos classificadores utilizados.

### 5.1. Testes 1-para-1

A primeira bateria de teste foi relacionada ao teste 1-para-1, que avalia o desempenho de cada um dos métodos em relação à verificação. Nesse teste é escolhido um valor, que é chamado de limiar, e a cada comparação entre duas faces é verificado se o valor resultante da comparação é menor que o limiar, se assim for, as duas faces são consideradas da mesma pessoa. Se o resultado for maior ou igual ao limiar, as faces são classificadas como sendo de pessoas diferentes. Através da variação do limiar é gerado um gráfico que mostra a Razão de Falsa Rejeição (*False Rejection Rate* - FRR) e Razão de Falsa Aceitação (*False Acceptance Rate* - FAR). A Figura 29 é o gráfico gerado pelo banco YALEA com normalização geométrica e o primeiro recorte.




Figura 29: Gráfico FRR x FAR do YALEA normalizado

Os gráficos gerados por todos os métodos de normalização estudados são muito semelhantes, o comportamento de ambas as curvas é praticamente o mesmo, o que difere é o ponto de encontro das duas curvas. O ponto de encontro entre as curvas é chamado de Taxa de Erro Igual (*Equal Error Rate* - EER) e é uma das formas de avaliar o gráfico.

Nas Tabelas mencionadas abaixo, na coluna Recorte, a menção de algum tipo de Recorte implicará na utilização da normalização geométrica no processo e a não realização de qualquer tipo de Recorte implicará a não realização de normalização geométrica.

A Tabela 1 se refere às taxas de EER obtidas com a utilização do classificador baseado em DCT.

**Tabela 1: Taxa de EER de cada técnica de normalização para o classificador baseado em DCT**

| <b>Recorte</b>   | <b>Norm. de Iluminação</b>          | <b>GTAV</b> | <b>VSOFT</b> | <b>YALEA</b> | <b>YALEB</b> | <b>ALL</b> |
|------------------|-------------------------------------|-------------|--------------|--------------|--------------|------------|
| -                | -                                   | 23%         | 10%          | 23%          | 6,8%         | -          |
| -                | <b>Log</b>                          | 24%         | 9%           | 13%          | 9%           | -          |
| -                | <b>LogAbout</b>                     | 24%         | 8,5%         | 13,2%        | 7,7%         | -          |
| -                | <b>Equalização</b>                  | 25,5%       | 13%          | 23%          | 7%           | -          |
| -                | <b>Equalização Local</b>            | 28,5%       | 20%          | 29,3%        | 16%          | -          |
| -                | <b>Retinex</b>                      | 25%         | 15%          | 21%          | 27%          | -          |
| -                | <b>Retinex + Exp. de Histograma</b> | 25%         | 12,6%        | 21%          | 26%          | -          |
| <b>Recorte 1</b> | -                                   | 34%         | 45%          | 37%          | 31%          | 28%        |
| <b>Recorte 1</b> | <b>Log</b>                          | 31%         | 40%          | 32%          | 33%          | 28%        |
| <b>Recorte 1</b> | <b>LogAbout</b>                     | 33%         | 42%          | 33%          | 34%          | 27%        |
| <b>Recorte 1</b> | <b>Equalização</b>                  | 34%         | 44%          | 35%          | 33%          | 28%        |
| <b>Recorte 1</b> | <b>Equalização Local</b>            | 37%         | 42%          | 40%          | 35%          | 36%        |
| <b>Recorte 1</b> | <b>Retinex</b>                      | 35%         | 41%          | 37%          | 36%          | 38%        |
| <b>Recorte 1</b> | <b>Retinex + Exp. de Histograma</b> | 33%         | 42%          | 41%          | 42%          | 33%        |
| <b>Recorte 2</b> | -                                   | 41%         | 46%          | 40%          | 37%          | 35%        |
| <b>Recorte 2</b> | <b>Log</b>                          | 39%         | -            | 39%          | 40%          | 37%        |
| <b>Recorte 2</b> | <b>LogAbout</b>                     | 41%         | 46%          | 39%          | 40%          | 36%        |

|                  |                                     |      |     |     |     |     |
|------------------|-------------------------------------|------|-----|-----|-----|-----|
| <b>Recorte 2</b> | <b>Equalização</b>                  | 42%  | 42% | 43% | 37% | 34% |
| <b>Recorte 2</b> | <b>Equalização Local</b>            | 40%  | 39% | 40% | 36% | 35% |
| <b>Recorte 2</b> | <b>Retinex</b>                      | 40 % | 42% | 41% | 42% | 40% |
| <b>Recorte 2</b> | <b>Retinex + Exp. de Histograma</b> | 43%  | 42% | 42% | 40% | 33% |

A Tabela 2 representa as taxas de EER obtidas pela utilização do classificador baseado em LBP.

**Tabela 2: Taxa de EER de cada técnica de normalização para o classificador baseado em LBP**

| <b>Recorte</b>   | <b>Norm. de Iluminação</b>          | <b>GTAV</b> | <b>VSOFT</b> | <b>YALEA</b> | <b>YALEB</b> | <b>ALL</b> |
|------------------|-------------------------------------|-------------|--------------|--------------|--------------|------------|
| -                | -                                   | 28%         | 17%          | 26%          | 8%           | -          |
| -                | <b>Log</b>                          | 30,9%       | 16,1%        | 30%          | 12%          | -          |
| -                | <b>LogAbout</b>                     | 27%         | 30%          | 35%          | 19%          | -          |
| -                | <b>Equalização</b>                  | 31%         | 32%          | 33,5%        | 9%           | -          |
| -                | <b>Equalização Local</b>            | 34%         | 42%          | 34%          | 8,7%         | -          |
| -                | <b>Retinex</b>                      | 26%         | 8,1%         | 27%          | 12%          | -          |
| -                | <b>Retinex + Exp. de Histograma</b> | 26%         | 8,2%         | 29%          | 11,5%        | -          |
| <b>Recorte 1</b> | -                                   | 32%         | 42,5%        | 36,5%        | 34%          | 29%        |
| <b>Recorte 1</b> | <b>Log</b>                          | 32%         | 41,3%        | 36,4%        | 33,5%        | 29%        |
| <b>Recorte 1</b> | <b>LogAbout</b>                     | 30%         | 39,3%        | 36,7%        | 32,4%        | 23,7%      |
| <b>Recorte 1</b> | <b>Equalização</b>                  | 34%         | 40%          | 37,5%        | 32,7%        | 29,2%      |
| <b>Recorte 1</b> | <b>Equalização Local</b>            | 29,8%       | 35%          | 36,3%        | 33%          | 27,4%      |
| <b>Recorte 1</b> | <b>Retinex</b>                      | 29,5%       | 34%          | 34%          | 30%          | 26%        |
| <b>Recorte 1</b> | <b>Retinex + Exp. de Histograma</b> | 29,5%       | 36%          | 33,5%        | 30%          | 27%        |
| <b>Recorte 2</b> | -                                   | 41%         | 44%          | 41,5%        | 37%          | 35%        |
| <b>Recorte 2</b> | <b>Log</b>                          | 39%         |              | 43%          | 37%          | 36,2%      |
| <b>Recorte 2</b> | <b>LogAbout</b>                     | 42%         | 45%          | 44%          | 41%          | 39%        |
| <b>Recorte 2</b> | <b>Equalização</b>                  | 40,5%       | 46%          | 43,6%        | 38%          | 36%        |
| <b>Recorte 2</b> | <b>Equalização Local</b>            | 42,9%       | 45,5%        | 43,6%        | 40%          | 39%        |
| <b>Recorte 2</b> | <b>Retinex</b>                      | 39,2%       | 40%          | 40,8%        | 36%          | 34,7%      |

|                  |                                     |     |       |     |     |       |
|------------------|-------------------------------------|-----|-------|-----|-----|-------|
| <b>Recorte 2</b> | <b>Retinex + Exp. de Histograma</b> | 40% | 43,3% | 42% | 37% | 35,5% |
|------------------|-------------------------------------|-----|-------|-----|-----|-------|

Através da análise dos gráficos gerados pelo teste 1-para-1 e das Tabelas 1 e 2, percebe-se que os algoritmos avaliados apresentam valores elevados para o EER. Em ambas as tabelas, os resultados obtidos com imagens sem normalização geométrica tem resultados melhores que os testes com imagens resultantes dessa normalização, e que a utilização de imagens com o Recorte 1 resultam em melhores taxas que a utilização do Recorte 2.

Se forem analisados apenas os testes com o mesmo tipo de recorte (sem recorte, recorte um ou recorte dois), o resultado obtido com o banco de imagens sem normalização de iluminação é superado em 82% dos casos por um dos resultados advindos de um ou mais métodos de normalização de iluminação.

## 5.2. Testes 1-para-N

A segunda bateria de teste foi para avaliar o desempenho dos métodos para reconhecimento, realizando testes 1-para-n. Em todos os testes foi utilizada a técnica de validação cruzada [Haykin, 2008].

As Tabelas 3 e 4 são referentes aos testes realizados com o classificador baseado em DCT.

**Tabela 3: Taxa de acerto para o reconhecimento com leave-one-out para o classificador baseado em DCT**

| <b>Recorte</b> | <b>Norm. de Iluminação</b> | <b>GTAV</b> | <b>VSOFT</b> | <b>YALEA</b> | <b>YALEB</b> | <b>ALL</b> |
|----------------|----------------------------|-------------|--------------|--------------|--------------|------------|
| -              | -                          | 86%         | 100%         | 90,9%        | 99,1%        | -          |
| -              | <b>Log</b>                 | 87,2%       | 100%         | 96,1%        | 99,1%        | -          |
| -              | <b>LogAbout</b>            | 89,5%       | 100%         | 98%          | 99,6%        | -          |
| -              | <b>Equalização</b>         | 77,3%       | 100%         | 83,7%        | 98,75%       | -          |
| -              | <b>Equalização Local</b>   | 72%         | 98,7%        | 79,2%        | 99,58%       | -          |
| -              | <b>Retinex</b>             | 83,1%       | 100%         | 97%          | 98,3%        | -          |
| -              | <b>Retinex + Exp. de</b>   | 73,8%       | 98,7%        | 98%          | 95,8%        | -          |



|                  | Histograma                          |       |       |       |       |       |
|------------------|-------------------------------------|-------|-------|-------|-------|-------|
| <b>Recorte 1</b> | -                                   | 56,4% | 55,1% | 68,2% | 72,1% | 55,2% |
| <b>Recorte 1</b> | <b>Log</b>                          | 62,2% | 51,3% | 77,2% | 66,7% | 60,4% |
| <b>Recorte 1</b> | <b>LogAbout</b>                     | 66,8% | 56,4% | 80,5% | 69,7% | 65,1% |
| <b>Recorte 1</b> | <b>Equalização</b>                  | 51,7% | 57,7% | 70,8% | 72,2% | 55,2% |
| <b>Recorte 1</b> | <b>Equalização Local</b>            | 57,5% | 59%   | 66,2% | 68,8% | 56%   |
| <b>Recorte 1</b> | <b>Retinex</b>                      | 60,4% | 55,1% | 72%   | 64,1% | 59,6% |
| <b>Recorte 1</b> | <b>Retinex + Exp. de Histograma</b> | 57%   | 51,3% | 66,2% | 62,5% | 52,8% |
| <b>Recorte 2</b> | -                                   | 31,4% | 41%   | 56,5% | 43,3% | 34,6% |
| <b>Recorte 2</b> | <b>Log</b>                          | 22%   | 34,6% | 48,7% | 34,6% | 23,7% |
| <b>Recorte 2</b> | <b>LogAbout</b>                     | 32%   | 37,2% | 53,2% | 44,6% | 32%   |
| <b>Recorte 2</b> | <b>Equalização</b>                  | 30,2% | 37,2% | 55,2% | 56,2% | 35,1% |
| <b>Recorte 2</b> | <b>Equalização Local</b>            | 27,3% | 48,7% | 51,9% | 64,6% | 38%   |
| <b>Recorte 2</b> | <b>Retinex</b>                      | 30,8% | 33,3% | 57,1% | 42,0% | 29,7% |
| <b>Recorte 2</b> | <b>Retinex + Exp. de Histograma</b> | 14%   | 24,3% | 43,5% | 28,7% | 20,3% |

As Tabelas 5 e 6 são referentes aos testes realizados com o classificador baseado em LBP.

**Tabela 4: Taxas de acerto para o reconhecimento com um elemento de treinamento, utilizando o classificador baseado em DCT**

| <b>Recorte</b>   | <b>Norm. de Iluminação</b>          | <b>GTAV</b> | <b>VSOFT</b> | <b>YALEA</b> | <b>YALEB</b> | <b>ALL</b> |
|------------------|-------------------------------------|-------------|--------------|--------------|--------------|------------|
| -                | -                                   | 59,4%       | 98,2%        | 73,4%        | 88,4%        | -          |
| -                | <b>Log</b>                          | 65,3%       | 96,4%        | 80,9%        | 86,8%        | -          |
| -                | <b>LogAbout</b>                     | 63,3%       | 98,7%        | 83,2%        | 87,3%        | -          |
| -                | <b>Equalização</b>                  | 47,6%       | 91%          | 67,2%        | 86,4%        | -          |
| -                | <b>Equalização Local</b>            | 39,5%       | 89%          | 60%          | 83,3%        | -          |
| -                | <b>Retinex</b>                      | 58%         | 96,4%        | 78%          | 72,2%        | -          |
| -                | <b>Retinex + Exp. de Histograma</b> | 46,3%       | 83,5%        | 72,4%        | 69,5%        | -          |
| <b>Recorte 1</b> | -                                   | 30,8%       | 26,9%        | 31,7%        | 36,1%        | 30,4%      |
| <b>Recorte 1</b> | <b>Log</b>                          | 36,6%       | 28,7%        | 41,1%        | 32,3%        | 33,8%      |

|                  |                                     |       |       |       |       |       |
|------------------|-------------------------------------|-------|-------|-------|-------|-------|
| <b>Recorte 1</b> | <b>LogAbout</b>                     | 36,8% | 30,5% | 43,3% | 34,7% | 33,7% |
| <b>Recorte 1</b> | <b>Equalização</b>                  | 26,5% | 31,3% | 35,2% | 35,1% | 27%   |
| <b>Recorte 1</b> | <b>Equalização Local</b>            | 24,6% | 27,9% | 29,7% | 31,4% | 26,5% |
| <b>Recorte 1</b> | <b>Retinex</b>                      | 33,1% | 28,4% | 38,2% | 28,7% | 30,5% |
| <b>Recorte 1</b> | <b>Retinex + Exp. de Histograma</b> | 27,1% | 23,8% | 32,8% | 26,1% | 25,5% |
| <b>Recorte 2</b> | <b>-</b>                            | 12,2% | 23%   | 27,3% | 22,1% | 14,8% |
| <b>Recorte 2</b> | <b>Log</b>                          | 11,4% | 17,7% | 25,1% | 17%   | 13%   |
| <b>Recorte 2</b> | <b>LogAbout</b>                     | 15,7% | 23,3% | 28,7% | 21,3% | 15,6% |
| <b>Recorte 2</b> | <b>Equalização</b>                  | 9,1%  | 26,1% | 29,7% | 25,6% | 16,4% |
| <b>Recorte 2</b> | <b>Equalização Local</b>            | 13,7% | 29,2% | 27,1% | 29,6% | 18,8% |
| <b>Recorte 2</b> | <b>Retinex</b>                      | 17%   | 23,6% | 28%   | 19,4% | 14,6% |
| <b>Recorte 2</b> | <b>Retinex + Exp. de Histograma</b> | 8%    | 13%   | 21,3% | 14,4% | 9,7%  |

As Tabelas 3 e 5 exibem o resultado do teste utilizando o processo *leave-one-out*, onde uma amostra de cada indivíduo é utilizada como teste e o restante é utilizado para treinamento.

**Tabela 5: Taxa de acerto para o reconhecimento com leave-one-out e o classificador baseado em LBP**

| <b>Recorte</b>   | <b>Norm. de Iluminação</b>          | <b>GTAV</b> | <b>VSOFT</b> | <b>YALEA</b> | <b>YALEB</b> | <b>ALL</b> |
|------------------|-------------------------------------|-------------|--------------|--------------|--------------|------------|
| -                | -                                   | 83,1%       | 100%         | 96,7%        | 99,6%        | -          |
| -                | <b>Log</b>                          | 90,7%       | 94,9%        | 81,1%        | 100%         | -          |
| -                | <b>LogAbout</b>                     | 89,5%       | 93,6%        | 76,6%        | 100%         | -          |
| -                | <b>Equalização</b>                  | 89,5%       | 100%         | 76,6%        | 100%         | -          |
| -                | <b>Equalização Local</b>            | 69,1%       | 93,6%        | 79,2%        | 100%         | -          |
| -                | <b>Retinex</b>                      | 91,8%       | 98,7%        | 85%          | 100%         | -          |
| -                | <b>Retinex + Exp. de Histograma</b> | 91,8%       | 98,7%        | 79,9%        | 100%         | -          |
| <b>Recorte 1</b> | -                                   | 66,8%       | 70,5%        | 81,1%        | 83,3%        | 72,6%      |
| <b>Recorte 1</b> | <b>Log</b>                          | 66,8%       | 70,5%        | 82,5%        | 84,6%        | 72,4%      |
| <b>Recorte 1</b> | <b>LogAbout</b>                     | 78,5%       | 75,6%        | 77,9%        | 85,4%        | 77,6%      |

|                  |                                     |       |       |       |       |       |
|------------------|-------------------------------------|-------|-------|-------|-------|-------|
| <b>Recorte 1</b> | <b>Equalização</b>                  | 65,1% | 69,2% | 79,9% | 83,7% | 71,1% |
| <b>Recorte 1</b> | <b>Equalização Local</b>            | 79%   | 80,7% | 77,9% | 84,6% | 78,1% |
| <b>Recorte 1</b> | <b>Retinex</b>                      | 75%   | 80,7% | 87%   | 85,4% | 79,1% |
| <b>Recorte 1</b> | <b>Retinex + Exp. de Histograma</b> | 75%   | 78,2% | 87%   | 85,4% | 78,6% |
| <b>Recorte 2</b> | <b>-</b>                            | 29,6% | 55,1% | 61%   | 59,1% | 39%   |
| <b>Recorte 2</b> | <b>Log</b>                          | 32%   | 51,3% | 55,8% | 57,9% | 41,1% |
| <b>Recorte 2</b> | <b>LogAbout</b>                     | 21,5% | 33,3% | 40,2% | 34,6% | 28,4% |
| <b>Recorte 2</b> | <b>Equalização</b>                  | 33,1% | 52,5% | 58,4% | 54,6% | 40,6% |
| <b>Recorte 2</b> | <b>Equalização Local</b>            | 25%   | 41%   | 48%   | 50%   | 35,4% |
| <b>Recorte 2</b> | <b>Retinex</b>                      | 40,7% | 50%   | 52,6% | 52,1% | 46,3% |
| <b>Recorte 2</b> | <b>Retinex + Exp. de Histograma</b> | 41,8% | 47,4% | 52,6% | 54,1% | 45,3% |

Os resultados mostrados nas Tabelas 4 e 6 foram obtidos fazendo o inverso do teste anterior, ou seja, apenas uma amostra foi utilizada para treinamento e o restante serviu como teste. Esse último teste é o mais próximo do encontrado em situações reais, pois geralmente os sistemas comerciais possuem apenas uma amostra de cada indivíduo, já que sempre se busca economia de processamento e de armazenamento em sistemas comerciais.

**Tabela 6: Taxas de acerto para o reconhecimento com um elemento de treinamento, utilizando o classificador baseado em LBP.**

| <b>Recorte</b>   | <b>Norm. de Iluminação</b>          | <b>GTAV</b> | <b>VSOFT</b> | <b>YALEA</b> | <b>YALEB</b> | <b>ALL</b> |
|------------------|-------------------------------------|-------------|--------------|--------------|--------------|------------|
| -                | -                                   | 53,3%       | 91%          | 70%          | 88,5%        | -          |
| -                | <b>Log</b>                          | 58,3%       | 76,4%        | 55,6%        | 88,9%        | -          |
| -                | <b>LogAbout</b>                     | 65,5%       | 75,1%        | 52,7%        | 83,3%        | -          |
| -                | <b>Equalização</b>                  | 60,2%       | 71,3%        | 53,4%        | 89,1%        | -          |
| -                | <b>Equalização Local</b>            | 30,2%       | 57,2%        | 54,6%        | 92%          | -          |
| -                | <b>Retinex</b>                      | 67,4%       | 93,6%        | 61%          | 86,6%        | -          |
| -                | <b>Retinex + Exp. de Histograma</b> | 67,4%       | 92,8%        | 57,8%        | 86,6%        | -          |
| <b>Recorte 1</b> | -                                   | 32,9%       | 37,9%        | 42,8%        | 40,2%        | 38,3%      |

|                  |                                     |       |       |       |       |       |
|------------------|-------------------------------------|-------|-------|-------|-------|-------|
| <b>Recorte 1</b> | <b>Log</b>                          | 34,1% | 39,5% | 43,8% | 40,6% | 38,3% |
| <b>Recorte 1</b> | <b>LogAbout</b>                     | 46,9% | 44,6% | 35,8% | 45,3% | 46,6% |
| <b>Recorte 1</b> | <b>Equalização</b>                  | 33,3% | 42,8% | 43,3% | 40%   | 38,3% |
| <b>Recorte 1</b> | <b>Equalização Local</b>            | 38,4% | 47,4% | 37%   | 44,3% | 43,3% |
| <b>Recorte 1</b> | <b>Retinex</b>                      | 43,8% | 44,9% | 46,1% | 44,6% | 47,3% |
| <b>Recorte 1</b> | <b>Retinex + Exp. de Histograma</b> | 43,8% | 39,7% | 46,1% | 44,6% | 46,6% |
| <b>Recorte 2</b> | <b>-</b>                            | 13,4% | 26,7% | 26,5% | 23,2% | 18,5% |
| <b>Recorte 2</b> | <b>Log</b>                          | 13,8% | 23,6% | 24,3% | 24,8% | 21,6% |
| <b>Recorte 2</b> | <b>LogAbout</b>                     | 11,8% | 14,9% | 19,1% | 15,6% | 14,2% |
| <b>Recorte 2</b> | <b>Equalização</b>                  | 13,9% | 22%   | 25,7% | 23,9% | 20,2% |
| <b>Recorte 2</b> | <b>Equalização Local</b>            | 14,5% | 17,7% | 19,5% | 20,1% | 17,7% |
| <b>Recorte 2</b> | <b>Retinex</b>                      | 15,9% | 24,3% | 23,9% | 23,2% | 19,3% |
| <b>Recorte 2</b> | <b>Retinex + Exp. de Histograma</b> | 16,8% | 24,9% | 24,4% | 22,7% | 19,6% |

Nos testes 1-para-N ocorreu o mesmo que havia ocorrido nos testes anteriores (1-para-1), os resultados com as imagens com o Recorte 2 obtiveram desempenho inferior aos testes com as imagens com o Recorte 1, e ambos foram superados pelos testes com as imagens sem nenhum tipo de normalização geométrica.

Como era previsto [Omaia 2009] [Ramesha 2009], os resultados dos testes com mais imagens sendo utilizadas para treinamento são melhores que os testes que simulam um cenário mais próximo de aplicações reais típicas, com apenas uma imagem por indivíduo sendo usada como referência. Também como ocorreu nos testes 1-para-1, através de técnicas de normalização de iluminação foi possível melhorar a taxa de reconhecimento (em todos os casos na Tabela 3, em 86% dos casos na Tabela 4, em 71,5% dos casos na Tabela 5 e em 78,5% dos casos na Tabela 6).

### 5.3. Avaliação do ASM

Para garantir que a normalização geométrica está sendo bem feita, é necessário saber se a detecção do centro dos olhos está sendo bem realizada. Esta avaliação é feita através da comparação da detecção automática com a detecção manual. Sendo assim, foi necessário gabaritar um banco de imagens com as posições dos olhos marcadas

manualmente. Esse procedimento foi realizado com o banco de imagens *Yale Face Database A*.

O estudo realizado consiste em calcular a distância euclidiana entre as coordenadas informadas pelo ASM e as coordenadas dos pontos marcados manualmente. Para definir se o ASM detectou corretamente ou não a posição do olho é necessário definir uma distância de aceitação, ou seja, se a distância entre as duas coordenadas for menor que o valor definido, o algoritmo acertou. Dessa maneira foi gerado um gráfico (Figura 30) a partir da variação da distância de aceitação.

O método consegue uma taxa de acerto de 50%, 80% e 90% utilizando-se uma distância de aceitação igual a 6, 10 e 14, respectivamente. Em média, a diferença entre as duas coordenadas é de 6,83, tendo um desvio padrão igual a 5,15.




Figura 30: Estudo da precisão do ASM.

Essas taxas de erros de detecção em relação às marcações manuais são altas quando consideradas as dimensões das imagens utilizadas na avaliação (127 *pixels* de largura por 147 *pixels* de altura).

#### 5.4. Testes com Detecção Manual dos Olhos

Com os resultados obtidos através do estudo da precisão do ASM, resolveu-se repetir os testes de reconhecimento de face com as coordenadas dos olhos marcadas

manualmente. Isso foi feito a fim de ter conhecimento do impacto causado pelo erro da normalização geométrica nas taxas de reconhecimento, erro causado pela falha na detecção da posição do centro dos olhos.

Dessa maneira, foram refeitos os testes 1-para-1 e 1-para-N, nas variações do banco *Yale Face Database A* (variação de recorte e de normalização fotométrica). Avaliando os erros na detecção dos pontos dos olhos (sabendo que são mais precisos que os pontos do contorno da face detectados pelo ASM) e pelo resultado visual, também foi realizado um novo teste de recorte para retirar as informações não pertencentes à face (Recorte 3) sem a necessidade dos pontos do ASM. As tabelas apresentam os mesmos resultados para os testes com os bancos sem recortes, pois nestes não há normalização geométrica, portanto, a localização dos olhos não influencia no resultado.

A Tabela 7 mostra as taxas de EER do teste 1-para-1 de todos os bancos testados com as coordenadas dos centros dos olhos definidos manualmente e pelo algoritmo ASM e com ambos os classificadores, o baseado em LBP e o baseado em DCT.

**Tabela 7: Taxas de EER dos métodos LBP e DCT com os olhos detectados manualmente e através do ASM**

| <b>Recorte</b>   | <b>Norm. de Iluminação</b>          | <b>ASM-DCT</b> | <b>Manual-DCT</b> | <b>ASM-LBP</b> | <b>Manual-LBP</b> |
|------------------|-------------------------------------|----------------|-------------------|----------------|-------------------|
| -                | -                                   | 23%            | 23%               | 26%            | 26%               |
| -                | <b>Log</b>                          | 13%            | 13%               | 30%            | 30%               |
| -                | <b>LogAbout</b>                     | 13,2%          | 13,2%             | 35%            | 35%               |
| -                | <b>Equalização</b>                  | 23%            | 23%               | 33,5%          | 33,5%             |
| -                | <b>Equalização Local</b>            | 29,3%          | 29,3%             | 34%            | 34%               |
| -                | <b>Retinex</b>                      | 21%            | 21%               | 27%            | 27%               |
| -                | <b>Retinex + Exp. de Histograma</b> | 21%            | 21%               | 29%            | 29%               |
| <b>Recorte 1</b> | -                                   | 37%            | 30,5%             | 36,5%          | 20%               |
| <b>Recorte 1</b> | <b>Log</b>                          | 32%            | 18%               | 36,4%          | 18%               |
| <b>Recorte 1</b> | <b>LogAbout</b>                     | 33%            | 18%               | 36,7%          | 24,5%             |
| <b>Recorte 1</b> | <b>Equalização</b>                  | 35%            | 27%               | 37,5%          | 20%               |
| <b>Recorte 1</b> | <b>Equalização</b>                  | 40%            | 21,5%             | 36,3%          | 20,5%             |

|                  | Local                               |       |       |       |       |
|------------------|-------------------------------------|-------|-------|-------|-------|
| <b>Recorte 1</b> | <b>Retinex</b>                      | 37%   | 24%   | 34%   | 13%   |
| <b>Recorte 1</b> | <b>Retinex + Exp. de Histograma</b> | 41%   | 24%   | 33,5% | 14%   |
| <b>Recorte 2</b> | <b>-</b>                            | 40%   | 40%   | 41,5% | 31%   |
| <b>Recorte 2</b> | <b>Log</b>                          | 39%   | 31%   | 43%   | 32%   |
| <b>Recorte 2</b> | <b>LogAbout</b>                     | 39%   | 32%   | 44%   | 31,5% |
| <b>Recorte 2</b> | <b>Equalização</b>                  | 43%   | 37,5% | 43,6% | 30%   |
| <b>Recorte 2</b> | <b>Equalização Local</b>            | 40%   | 32,3% | 43,6% | 30%   |
| <b>Recorte 2</b> | <b>Retinex</b>                      | 41%   | 33%   | 40,8% | 31%   |
| <b>Recorte 2</b> | <b>Retinex + Exp. de Histograma</b> | 42%   | 30,5% | 42%   | 29%   |
| <b>Recorte 3</b> | <b>-</b>                            | 39,5% | 32%   | 40%   | 27,5% |
| <b>Recorte 3</b> | <b>Log</b>                          | 38%   | 29%   | 40%   | 22,3% |
| <b>Recorte 3</b> | <b>LogAbout</b>                     | 40%   | 29%   | 40%   | 24%   |
| <b>Recorte 3</b> | <b>Equalização</b>                  | 36%   | 30%   | 38%   | 25,5% |
| <b>Recorte 3</b> | <b>Equalização Local</b>            | 42%   | 26%   | 41%   | 23%   |
| <b>Recorte 3</b> | <b>Retinex</b>                      | 40,5% | 33%   | 41%   | 19%   |
| <b>Recorte 3</b> | <b>Retinex + Exp. de Histograma</b> | 41%   | 30%   | 40,5% | 19,4% |

Utilizando o classificador baseado em DCT, os resultados obtidos com o Recorte 1 são semelhantes aos resultados sem normalização geométrica, conseguindo taxas inferiores se comparados com o banco sem pré-processamento (sem normalização geométrica ou de iluminação). Os resultados conseguidos pelo novo recorte (Recorte 3) foram melhores que os resultados apresentados pelo Recorte 2, porém não conseguiu ter o mesmo desempenho apresentado pelo Recorte 1.

Nos testes realizados utilizando o classificador baseado em LBP, o desempenho do método foi melhor com o Recorte 1 em todos os casos. O Recorte 3 conseguiu taxas semelhantes ao Recorte 1 no caso médio, porém não alcançou os melhores resultados. Os resultados obtidos pelos testes com as imagens sem normalização geométrica e com o recorte dois são semelhantes e ambos são inferiores aos encontrados no Recorte 1 e 3.

A utilização da coordenada dos olhos detectados manualmente para a normalização geométrica implicou uma melhora nos resultados, gerando uma queda de até 50% na taxa de EER, se comparado com o mesmo teste que utilizou as coordenadas encontradas pelo algoritmo ASM. Como nos testes anteriores, a normalização de iluminação conseguiu melhorar o desempenho do método na maioria dos casos.

As Tabelas 8 e 9 se referem aos resultados obtidos por meio dos testes 1-para-N. Os testes foram realizados com os a versão original do banco e as três formas de recortes apresentadas anteriormente.

A Tabela 8 possui os resultados dos testes gerados utilizando técnica *leave-one-out*, ou seja, com uma amostra de cada indivíduo como teste e o restante como treinamento do sistema.

**Tabela 8: Taxas de acerto para o reconhecimento com *leave-one-out*, utilizando os classificadores baseados em LBP e DCT com detecção dos olhos manual e através do ASM**

| <b>Recorte</b>   | <b>Norm. de Iluminação</b>          | <b>ASM-DCT</b> | <b>Manual-DCT</b> | <b>ASM-LBP</b> | <b>Manual-LBP</b> |
|------------------|-------------------------------------|----------------|-------------------|----------------|-------------------|
| -                | -                                   | 90,9%          | 90,9%             | 96,7%          | 96,7%             |
| -                | <b>Log</b>                          | 96,1%          | 96,1%             | 81,1%          | 81,1%             |
| -                | <b>LogAbout</b>                     | 98%            | 98%               | 76,6%          | 76,6%             |
| -                | <b>Equalização</b>                  | 83,7%          | 83,7%             | 76,6%          | 76,6%             |
| -                | <b>Equalização Local</b>            | 79,2%          | 79,2%             | 79,2%          | 79,2%             |
| -                | <b>Retinex</b>                      | 97%            | 97%               | 85%            | 85%               |
| -                | <b>Retinex + Exp. de Histograma</b> | 98%            | 98%               | 79,9%          | 79,9%             |
| <b>Recorte 1</b> | -                                   | 68,2%          | 87,6%             | 81,1%          | 96,1%             |
| <b>Recorte 1</b> | <b>Log</b>                          | 77,2%          | 97,4%             | 82,5%          | 98%               |
| <b>Recorte 1</b> | <b>LogAbout</b>                     | 80,5%          | 98%               | 77,9%          | 92,2%             |
| <b>Recorte 1</b> | <b>Equalização</b>                  | 70,8%          | 92,8%             | 79,9%          | 96,7%             |
| <b>Recorte 1</b> | <b>Equalização Local</b>            | 66,2%          | 89,6%             | 77,9%          | 95,4%             |
| <b>Recorte 1</b> | <b>Retinex</b>                      | 72%            | 96,7%             | 87%            | 99,3%             |
| <b>Recorte 1</b> | <b>Retinex + Exp. de Histograma</b> | 66,2%          | 92,8%             | 87%            | 99,3%             |



|                  |                                         |       |       |       |       |
|------------------|-----------------------------------------|-------|-------|-------|-------|
| <b>Recorte 2</b> | <b>-</b>                                | 56,5% | 70,1% | 61%   | 61%   |
| <b>Recorte 2</b> | <b>Log</b>                              | 48,7% | 71,4% | 55,8% | 56,1% |
| <b>Recorte 2</b> | <b>LogAbout</b>                         | 53,2% | 72%   | 40,2% | 60,4% |
| <b>Recorte 2</b> | <b>Equalização</b>                      | 55,2% | 76%   | 58,4% | 77,2% |
| <b>Recorte 2</b> | <b>Equalização<br/>Local</b>            | 51,9% | 78,6% | 48%   | 74,6% |
| <b>Recorte 2</b> | <b>Retinex</b>                          | 57,1% | 77,9% | 52,6% | 64,9% |
| <b>Recorte 2</b> | <b>Retinex + Exp.<br/>de Histograma</b> | 43,5% | 66,9% | 52,6% | 80,5% |
| <b>Recorte 3</b> | <b>-</b>                                | 60,4% | 81,8% | 60,4% | 91,5% |
| <b>Recorte 3</b> | <b>Log</b>                              | 59,8% | 88,3% | 59,8% | 94,8% |
| <b>Recorte 3</b> | <b>LogAbout</b>                         | 65%   | 87,6% | 65%   | 89,6% |
| <b>Recorte 3</b> | <b>Equalização</b>                      | 63,3% | 87,6% | 63,6% | 93,5% |
| <b>Recorte 3</b> | <b>Equalização<br/>Local</b>            | 55,8% | 88,3% | 55,8% | 92,8% |
| <b>Recorte 3</b> | <b>Retinex</b>                          | 57,8% | 85%   | 57,8% | 97,4% |
| <b>Recorte 3</b> | <b>Retinex + Exp.<br/>de Histograma</b> | 47,4% | 83,7% | 47,4% | 94,8% |

A Tabela 9 apresenta os resultados dos testes que utilizam o inverso da técnica *leave-one-out*, com apenas uma amostra sendo utilizada para treinamento e o restante sendo utilizadas como teste.

**Tabela 9: Taxas de acerto para o reconhecimento com uma imagem de treinamento, utilizando os classificadores baseados em LBP e DCT com detecção dos olhos manual e através do ASM**

| <b>Recorte</b> | <b>Norm. de<br/>Iluminação</b> | <b>ASM-DCT</b> | <b>Manual-<br/>DCT</b> | <b>ASM-LBP</b> | <b>Manual-<br/>LBP</b> |
|----------------|--------------------------------|----------------|------------------------|----------------|------------------------|
| -              | -                              | 73,4%          | 73,4%                  | 70%            | 70%                    |
| -              | <b>Log</b>                     | 80,9%          | 80,9%                  | 55,6%          | 55,6%                  |
| -              | <b>LogAbout</b>                | 83,2%          | 83,2%                  | 52,7%          | 52,7%                  |
| -              | <b>Equalização</b>             | 67,2%          | 67,2%                  | 53,4%          | 53,4%                  |
| -              | <b>Equalização<br/>Local</b>   | 60%            | 60%                    | 54,6%          | 54,6%                  |
| -              | <b>Retinex</b>                 | 78%            | 78%                    | 61%            | 61%                    |
| -              | <b>Retinex + Exp.</b>          | 72,4%          | 72,4%                  | 57,8%          | 57,8%                  |

|                  | <b>de Histograma</b>                    |       |       |       |       |
|------------------|-----------------------------------------|-------|-------|-------|-------|
| <b>Recorte 1</b> | <b>-</b>                                | 31,7% | 63,5% | 42,8% | 84,4% |
| <b>Recorte 1</b> | <b>Log</b>                              | 41,1% | 78,1% | 43,8% | 83,7% |
| <b>Recorte 1</b> | <b>LogAbout</b>                         | 43,3% | 84,5% | 35,8% | 66,5% |
| <b>Recorte 1</b> | <b>Equalização</b>                      | 35,2% | 72,1% | 43,3% | 83,6% |
| <b>Recorte 1</b> | <b>Equalização<br/>Local</b>            | 29,7% | 72,9% | 37%   | 74,6% |
| <b>Recorte 1</b> | <b>Retinex</b>                          | 38,2% | 75,8% | 46,1% | 86,1% |
| <b>Recorte 1</b> | <b>Retinex + Exp.<br/>de Histograma</b> | 32,8% | 65%   | 46,1% | 86,1% |
| <b>Recorte 2</b> | <b>-</b>                                | 27,3% | 43,6% | 26,5% | 45,8% |
| <b>Recorte 2</b> | <b>Log</b>                              | 25,1% | 48,3% | 24,3% | 44,1% |
| <b>Recorte 2</b> | <b>LogAbout</b>                         | 28,7% | 49,7% | 19,1% | 38%   |
| <b>Recorte 2</b> | <b>Equalização</b>                      | 29,7% | 52%   | 25,7% | 46,5% |
| <b>Recorte 2</b> | <b>Equalização<br/>Local</b>            | 27,1% | 55%   | 19,5% | 42,8% |
| <b>Recorte 2</b> | <b>Retinex</b>                          | 28%   | 47,2% | 23,9% | 46,4% |
| <b>Recorte 2</b> | <b>Retinex + Exp.<br/>de Histograma</b> | 21,3% | 37%   | 24,4% | 48,9% |
| <b>Recorte 3</b> | <b>-</b>                                | 30%   | 57%   | 30%   | 66,9% |
| <b>Recorte 3</b> | <b>Log</b>                              | 31,8% | 62,8% | 31,8% | 69,6% |
| <b>Recorte 3</b> | <b>LogAbout</b>                         | 33,7% | 62%   | 33,7% | 64,5% |
| <b>Recorte 3</b> | <b>Equalização</b>                      | 36,3% | 69,6% | 36,3% | 66,1% |
| <b>Recorte 3</b> | <b>Equalização<br/>Local</b>            | 26,6% | 64,4% | 26,6% | 67,2% |
| <b>Recorte 3</b> | <b>Retinex</b>                          | 29,8% | 57,8% | 29,8% | 72,4% |
| <b>Recorte 3</b> | <b>Retinex + Exp.<br/>de Histograma</b> | 24,7% | 48,9% | 24,7% | 73,3% |

Analisando as Tabela 8 e Tabela 9 percebe-se um comportamento semelhante ao encontrado na Tabela 7. Nos resultados com o classificador baseado em DCT, o melhor resultado vem da utilização do Recorte 1 com normalização de iluminação, obtendo taxas ainda semelhantes ao caso sem normalização geométrica. Taxas de reconhecimento um pouco inferiores são encontradas nos testes com o Recorte 3, e os piores resultados são obtidos com o Recorte 2.

Os resultados obtidos com o classificador baseado em LBP também são compatíveis aos testes 1-para-1 realizados anteriormente. Em ordem crescente, as melhores taxas de reconhecimento foram do Recorte 1, Recorte 3, sem normalização geométrica e Recorte 2. A diferença encontrada está na Tabela 9, onde encontramos uma discrepância maior entre os resultados obtidos com o Recortes 1 e 3, o que não ocorre nas Tabelas 7 e 8.

É verificado, em ambas as tabelas, que a normalização de iluminação melhora as taxas de reconhecimento independente da normalização geométrica ou do tipo de recorte realizado. A utilização das coordenadas dos olhos, detectadas manualmente, melhora consideravelmente o resultado do reconhecimento em todos os casos, e na Tabela 9, que representa os testes com apenas uma imagem de treinamento. É constatada uma melhora superior a 100% em alguns casos. Como já havia sido verificado nos testes anteriores, a quantidade de amostras utilizadas para o treinamento influencia diretamente a taxa de reconhecimento.

## 6. CONCLUSÃO

Após o estudo sobre a precisão da detecção da posição dos olhos na imagem e a análise do efeito desse problema nas taxas de reconhecimento, chega-se à conclusão de que o ASM, da forma que foi utilizada, não é suficientemente preciso para ser utilizado e dessa maneira, influencia negativamente nos resultados. Com a utilização das coordenadas corretas dos olhos é possível melhorar o desempenho dos métodos. Dessa maneira, um dos pontos que precisa ser melhorado é a detecção automática das coordenadas dos centros dos olhos.

A utilização de métodos para a normalização de iluminação se mostrou importante para o melhoramento das taxas de reconhecimento em ambientes não controlados. Em todos os casos, houve ganhos através da sua utilização, apesar de não ser possível identificar um método que seja bom em todos os casos.

Os resultados mostram que quando a informação da imagem é restrita à face, piora o desempenho, o que leva à conclusão que muitos trabalhos (Hafed e Levine (2001), Matos *et al.*(2008), Omaia *et al.* (2009) e Marinho (2012) ), que não fazem o recorte da face, estão utilizando a informação do plano de fundo para realizar o reconhecimento. Como nos bancos testados, as condições das diferentes amostras de uma mesma pessoa são muito semelhantes (plano de fundo da foto, roupa, tamanho e estilo do cabelo e da barba, distância da câmera, etc.), os sistemas de reconhecimento acabam utilizando essas informações, aumentando a taxa de reconhecimento dos indivíduos.

Se for utilizado um detector de pupilas eficiente, o classificador baseado em LBP juntamente com as técnicas de normalização pode ser utilizado para reconhecimento de faces frontais, pois alcança uma taxa acima de 97% de acerto com o Recorte 3, o qual garante não utilizar nenhuma informação que não pertença à face. Porém, no estado atual só é possível afirmar qual face da base é a mais semelhante à face de teste, já que as taxas de EER demonstram não ser possível identificar, se ele pertence ou não ao grupo de treinamento, ou seja, o método tem bons resultados para classificação fechada e resultados ruins para classificação aberta.

Com os resultados obtidos, chega-se a conclusão que o SDRF (classificador baseado em DCT) ainda não está pronto para ser utilizado em algumas situações práticas, porém ele ainda é um sistema em desenvolvimento e, portanto, pode ser melhorado. Uma das melhorias que podem ser feitas é uma seleção de atributos com as imagens que estão sendo utilizadas para o reconhecimento - no caso deste trabalho, as imagens normalizadas e principalmente as recortadas, já que essas removem toda informação que não seja da face. Esse treinamento também deve ser realizado individualmente para cada tipo de método de normalização de iluminação, visando conseguir melhores resultados e aferir com mais precisão a eficácia de cada um desses algoritmos sobre o sistema de reconhecimento. Outra tarefa futura é testar outras técnicas além do classificador de vizinho mais próximo após a nova seleção de atributos.

A melhoria da detecção dos olhos também fica como trabalho futuro, sendo um dos testes mais imediatos o de utilizar a normalização fotométrica antes da utilização do algoritmo ASM. Testar as variantes do LBP, a variação de seus parâmetros e novos métodos de comparação dos histogramas do LBP são tarefas que também ficam para o futuro.

## REFERÊNCIAS

Abate, A. F, Nappi, M., Riccio D. e Sabatino, G (2007). **2D and 3D Face Recognition: A Survey**. Pattern Recognition Letter 28.

Ahonen, T., Hadid, A. e Pietikäinen M. (2004). **Face Recognition with Local Binary Patterns**. Computer Vision - ECCV 2004, 8th European Conference on Computer Vision. DOI: 10.1007/978-3-540-24670-1\_36.

AT&T Laboratories, Cambridge, UK. **The ORL Database of Faces** (AT&T TheDatabase of Faces). Disponível em: <[http://www.cl.cam.ac.uk/research/dtg/attarchive/pub/data/att\\_faces.zip](http://www.cl.cam.ac.uk/research/dtg/attarchive/pub/data/att_faces.zip)>. Acesso em: 20 jan. 2015.

Bedê, F. T. M., Dutra, L. V., Sandri, S. e Freitas, C. C. (2010) **Métodos Contextuais para Classificação Baseada em Casos e Classificação por Vizinhos mais Próximos: Estudo de caso para Mapeamento de Risco de Doenças Endêmicas no Brasil**. Workshop dos Cursos de Computação Aplicada do INPE, 10 (WORCAP).

Bradski, G. R.; Kaehler ( 2008). **A. Learning OpenCV: Computer Vision with the OpenCV Library**. O'Reilly.

Chai, X., Shan, S. e Gao W.(2003). **Pose Normalization for Robust Face Recognition Based on Statistical Affine Transformation**. Proceedings of the 2003 Joint Conference of the Fourth International Conference on Information, Communications and Signal Processing, 2003 and Fourth Pacific Rim Conference on Multimedia, vol. 3.

Cootes, T.F., Taylor, C.J., Cooper, D.H. e Graham, J. (1995). **Computer Vision and Image Understanding**, vol. 61.

Gao, H., Ekenel, H. K. e Stiefelhagen, R. (2009). **Pose Normalization for Local Appearance-Based Face Recognition**. ICB '09 Proceedings of the Third International Conference on Advances in Biometrics.

Huang, G. B., Ramesh, M., Berg, T. e Learned-Miller, E. (2007). **Labeled Faces in the Wild: A Database for Studying Face Recognition in Unconstrained Environments**. University of Massachusetts, Technical Report.

Georghiades, A., Belhumeur, P. e Kriegman, D. (2001). **From Few to Many: Illumination Cone Models for Face Recognition under Variable Lighting and Pose**, PAMI.

Gomes, O. F. M. (2001). **Processamento e Análise de Imagens Aplicados à Caracterização Automática de Materiais**. Dissertação de Mestrado - Ciências da Engenharia Metalúrgica, PUC/Rio, Rio de Janeiro.

GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. L (2004). **Digital Image Processing using MATLAB**. New Jersey, USA: Pearson Education.

Hafed, Z. M. e Levine, M. D. (2001). **Face Recognition Using the Discrete Cosine Transform**. International Journal of Computer Vision, n. 3.

Haykin, S. (2008). **Neural Networks And Learning Machines**. Prentice Hall , 3ª Edição.

Hines, G. D., Rahman, Z, Jobson, D. J. e Woodell, G. A. (2004). **Single-Scale Retinex Using Digital Signal Processors**. Global Signal Processing Expo.

Huang, D., Shan, C. Ardabilian, M., Wang, Y. e Chen, L. (2011). **Local Binary Patterns and Its Application to Facial Image Analysis: A Survey**. Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on (Volume:41 , Issue: 6 ). DOI:10.1109/TSMCC.2011.2118750.

Hummel, R. (1975). **Histogram modification techniques**. Computer Graphics and Image.

Jafri, R. e Arabnia, H.(2009) **A Survey of Face Recognition Techniques**. Journal of Information Processing Systems.

Jain, A. K. (1989). **Fundamentals of Digital Image Processing**. Prentice Hall, NJ, USA.

Jain, A., Hong, L. e Pankanti, S. (2000). **Biometric Identification**. Commun. ACM 43. DOI: 10.1145/328236.328110.

Kar, S., Hiremath, S., Joshi, D. G., Chadda V. K. e Bajpai, A. (2006). **A Multi-Algorithmic Face Recognition System**. International Conference on Advanced Computing and Communications.

Khayam, S. A. (2003). **The Discrete Cosine Transform (DCT): Theory and Application**. Michigan State University.

Levine, M. D., Gandhi, M. R. e Bhattacharyya, J. (2004). **Image Normalization for Illumination Compensation in Facial Images**. Department of Electrical & Computer Engineering & Center for Intelligent Machines, McGill University, Montreal, Canada, Unpublished Report. (<http://www.cim.mcgill.ca/~levine/reports.php>).

Li, S., Long, F. e Cheng, X. (2013). **Illumination Invariant Face Recognition with Whitening Filter and Local Binary Patterns**. Computational Intelligence and Design (ISCID), 2013 Sixth International Symposium, Volume 1. DOI: 10.1109/ISCID.2013.42.

Liu, H., Miao, J.; Li, J. e Gao, W. (2002). **A Novel Method to Compensate Variety of Illumination in Face Detection**. Conference on Information Sciences( ICCVPRIP).

Lordão, F. A. F. **Reconhecimento de Formas Utilizando Modelos de Compressão de Dados e Espaço de Escalas de Curvatura**. Dissertação – (Mestrado em Informática), Universidade Federal da Paraíba, João Pessoa, 2009.



Maltoni, D., Maio, D., Jain, A. e Prabhakar S. (2009). **Handbook of Fingerprint Recognition**. Editora Springer.

Marinho, A. S. (20012). **Uma nova versão de um sistema de detecção e reconhecimento de face utilizando a transformada cosseno discreta**. Dissertação de Mestrado - Curso de Pós-Graduação em Informática, UFPB, João Pessoa.

Marques Filho, O. e Vieira Neto, H. (1999). **Processamento Digital de Imagem**, Rio de Janeiro, Editora Brasport.

Matos, F. M. S. (2008). **Reconhecimento de Faces Utilizando Seleção de Coeficientes da Transformada Cosseno Discreta**. Dissertação de Mestrado - Curso de Pós-Graduação em Informática, UFPB, João Pessoa.

Matos, F. M. S., Batista, L. V., Poel, J. V. D..(2008) **Face Recognition using DCT Coefficients Selection**. ACM Symposium on Applied Computing, vol. III.

Maturama, D., Mery, D. e Soto, A.(2009). **Face Recognition with Local Binary Patterns, Spatial Pyramid Histograms and Naive Bayes Nearest Neighbor Classification**. SCCC '09 Proceedings of the 2009 International Conference of the Chilean Computer Science Society. doi:10.1109/SCCC.2009.21.

Mendonça, M. M., Denipote, J. G., Fernandes, R. A. S. e Paiva, M. S. V. (2007). **Illumination Normalization Methods for Face Recognition**. Brazilian Symposium on Computer Graphics and Image Processing.

Omaia, D. (2009). **Um Sistema para Detecção e Reconhecimento de Face em Vídeo Utilizando a Transformada Cosseno Discreta**. Dissertação de Mestrado - Curso de Pós-Graduação em Informática, UFPB, João Pessoa.

Omaia, D., Poel, J. V. D., Batista, L. V.(2009) **2D-DCT Distance Based Face Recognition Using a Reduced Number of Coefficients**. Brazilian Symposium on Computer Graphics and Image Processing.

Ojala, T., Pietikäinen, M. e Harwood, D. (1996). **A comparative study of texture measures with classification based on featured distributions.** Pattern Recognition, vol. 29, no. 1.

Poel, J. V.D., Mascena, E.N, Pires, G.M., Honorio, T.C.S, Medeiros, T.F.L, E Batista, L.V. **Um sistema para diagnóstico auxiliado por computador voltado para imagens mamográficas: desempenho da busca baseada em conteúdo na recuperação de achados.** *Anais do VII Workshop de Informática Médica*, 2007.

Ramesha, K., Srikanth, N., Raja, K. B., Venugopal, K. R. e Patnaik, L. M.(2009). **Advanced Biometric Identification on Face, Gender and Age Recognition.** International Conference on Advances in Recent Technologies in Communication and Computing.

Ross, A. A., Nandakumar, K. e Jain, A. K. (2006). **Handbook of Multibiometrics.** Secaucus: Springer-Verlag New York.

Ruiz-Del-Solar, J., Quinteros, J. (2008). **Illumination Compensation and Normalization in Eigenspace-based Face Recognition: A comparative study of different pre-processing approaches.** Journal Pattern Recognition Letters, vol 29, ed. 14.

Samaria, F. S. e Harter, A. C.(1994). **Parameterization of a stochastic model for human face identification.** IEEE Workshop on Applications of Computer Vision.

Shapiro, Linda G. & Stockman, George C. (2002). "**Computer Vision**".Prentice Hall.

Shermina, J. (2011). **Illumination invariant face recognition using discrete cosine transform and principal component analysis.** Proceedings of ICETECT 2011.

Short, J., Kittler, J. e Messer, K. (2004). **A comparison of photometric normalisation algorithm for face verification.** Proc. Int'l conf. AFGR.

Starovoitov, V. e Samal, D. (1999). **A geometric approach to face recognition**. IEEE-EURASIP Workshop on Nonlinear Signal and Image.

Tarrés, F. e Rama, A. **GTAV Face Database**. <http://gps-tsc.upc.es/GTAV/ResearchAreas/UPCFaceDatabase/GTAVFaceDatabase.htm>.

Theodoridis, S.e Koutroumbas, K. (2006) **Pattern recognition Academic Press**.

Walker, Helen (1931). **Studies in the History of the Statistical Method**. Baltimore, MD: Williams & Wilkins Co.

Xu, J., Li, X. e Xie, F. (2013). **Face recognition under varying illumination based on local binary patterns with circle threshold**. Computer Sciences and Applications (CSA), p. 329 - 332. DOI: 10.1109/CSA.2013.83.

Ylioinas, J., Hadid, A. e Pietikäinen, M.(2011). **Combining Contrast Information and Local Binary Patterns for Gender Classification**. Image Analysis, 17th Scandinavian Conference, SCIA 2011, Ystad, Sweden. p 676-686. Doi: 10.1007/978-3-642-21227-7\_63

Zhao, W., Chellappa, R., Phillips, P. J. e Rosenfeld (2003). **A. Face Recognition: A Literature Survey**. ACM Computing Surveys, vol. 35, nº .

Zia-ur, R., Daniel J. J. e Glenn A. W. (2004). **Retinex processing for automatic image enhancement**. J. Electron. Imaging. 13(1), p.100-110. doi:10.1117/1.1636183